



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**TÜMÖR TANILI FARKLI SEKANS
MANYETİK REZONANS GÖRÜNTÜLERİNİN
DERİN ÖĞRENME MODELLERİ İLE
SINIFLANDIRILMASI**

Türkan DOĞANALP

YÜKSEK LİSANS TEZİ

Biyomedikal Mühendisliği Anabilim Dalı

Şubat- 2022
KONYA
Her Hakkı Saklıdır

ÖZET

YÜKSEK LİSANS TEZİ

TÜMÖR TANILI FARKLI SEKANS MANYETİK REZONANS GÖRÜNTÜLERİNİN DERİN ÖĞRENME MODELLERİ İLE SINIFLANDIRILMASI

Türkan DOĞANALP

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Muhammet Üsame ÖZİÇ

2022, 187 Sayfa

Jüri

Dr. Öğr. Üyesi Muhammet Üsame ÖZİÇ
Dr. Öğr. Üyesi Mücahid BARSTUĞAN
Dr. Öğr. Üyesi Kemal ÇETİN

Beyin tümörü, beynin çeşitli bölgelerinde hücrelerin anormal büyümesi ve çoğalması sonucu oluşan kitlelerdir. İyi huylu ve kötü huylu olarak ikiye ayrılan bu tümörlerin, erken ve doğru teşhisi hastanın hayatının devamlılığı için önemlidir. Hastaya ait farklı sekans MR görüntüleri ile beyin tümörü teşhisi yapılabilmektedir. Tedavi süreci ve şekli uzman doktorun kontrolünde gerçekleşmektedir. MR görüntülerinin analizi uzun zaman almakta ve uzman radyologlar tarafından yapılmaktadır. Bilgisayar tabanlı karar destek sistemi ile görüntülerin analiz süresinin kısaltılması ve hata oranının en aza indirilmesi amaçlanarak bu alanda çalışmalar yapılmaktadır.

Bu tez çalışmasında, farklı derin öğrenme modelleri ile BRATS 2019 veri setinde yer alan MR görüntüleri kullanılarak 3 farklı senaryoda sınıflandırma uygulamaları yapılmıştır. 3 sınıf çıkışlı sınıflandırmada FLAIR, T1, T1CE ve T2 ağırlıklı MR görüntüleri HGG, LGG, normal olmak üzere 3 sınıfa ayrılmıştır. 4 sınıf çıkışlı sınıflandırmada ise HGG, LGG ve normal MR görüntüleri içerisinde o dereceye ait 4 modalite görüntüleri bulunmaktadır. 12 sınıf çıkışlı sınıflandırmada, tüm modalite ve dereceye sahip MR görüntüleri aynı anda sisteme verilmektedir. Eğitimler, AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve InceptionV3 derin öğrenme modelleri ile transfer öğrenme yöntemi kullanılarak gerçekleştirilmiştir. Eğitimlerin tümünde aynı hiper parametre değerleri kullanılarak eğitim süreleri ve performansları karşılaştırılmıştır. Veri seti %80 eğitim, %20 test olarak ayrılmış ve 5-kat çapraz doğrulama uygulanmıştır. 3 sınıf çıkışlı modellerin performans kriterleri değerlendirildiğinde, FLAIR modalitesinde kesinlik $0,9976 \pm 0,0014$, duyarlılık $0,9977 \pm 0,0014$, özgüllük $0,9988 \pm 0,0007$, doğruluk $0,9976 \pm 0,0014$ ve F1 puanı $0,9976 \pm 0,0014$ ile en yüksek performansı AlexNet modeli vermiştir. AlexNet modeli eğitimi toplamda 13 dk 44 sn sürmüştür. 4 sınıf çıkışlı eğitimlerin sonucunda $0,9968 \pm 0,0019$ ile en yüksek doğruluk değerini LGG dereceli görüntülerde InceptionV3 modeli vermiştir. Diğer performans değerleri $0,9967 \pm 0,0020$ kesinlik, $0,9967 \pm 0,0021$ duyarlılık, $0,9989 \pm 0,0006$ özgüllük ve $0,9967 \pm 0,0020$ F1 puanıyla yüksek başarı göstermiştir. Eğitim süresi 3 saat 12 dk 14 sn ile en fazla eğitim süresine sahiptir. 12 sınıf çıkışlı sınıflandırmada ise AlexNet modelinde $0,9840 \pm 0,0036$ doğruluk, $0,9843 \pm 0,0035$ kesinlik, $0,9841 \pm 0,0033$ duyarlılık, $0,9985 \pm 0,0003$ özgüllük ve $0,9842 \pm 0,0034$ F1 puanı ile tüm performans kriterlerinde en yüksek değerler elde edilerek eğitim 1 s 13 dk 29 sn sürmüştür. Tümör tanılı farklı sekans manyetik rezonans görüntülerinin derin modelleri ile sınıflandırılması güçlü bir bilgisayarlı karar destek sistemi için yüksek doğruluk oranları vermiştir.

Anahtar Kelimeler: Beyin tümörü, Derin öğrenme, Modalite, Sınıflandırma, Transfer öğrenme

ABSTRACT

MS THESIS

CLASSIFICATION OF TUMOR DIAGNOSED DIFFERENT SEQUENCE MAGNETIC RESONANCE WITH DEEP LEARNING MODELS

Türkan DOĞANALP

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN BIOMEDICAL ENGINEERING**

Advisor: Assist. Prof. Dr. Muhammet Üsâme ÖZİÇ

2022, 187 Pages

Jury

Assist. Prof. Dr. Muhammet Üsâme ÖZİÇ

Assist. Prof. Dr. Mücahid BARSTUĞAN

Assist. Prof. Dr. Kemal ÇETİN

Brain tumors are masses formed as a result of abnormal growth and proliferation of cells in various parts of the brain. Early and accurate diagnosis of these tumors, which are divided into benign and malignant, is important for the continuity of the patient's life. Brain tumor diagnosis can be made with different sequence MR images of the patient. The treatment process and method are carried out under the control of the specialist doctor. Analysis of MR images takes a long time and is done by expert radiologists. With the computer-based decision support system, studies are carried out in this area to reduce the analysis time of the images and minimize the error rate.

In this thesis, classification applications were made in 3 different scenarios by using different deep learning models and MR images in the BRATS 2019 dataset. In the classification with 3-class output, FLAIR, T1, T1CE, and T2-weighted MR images are divided into 3 classes HGG, LGG, and normal. In the classification with 4-class outputs, there are 4 modality images of that degree within the HGG, LGG, and normal MR images. In the 12-class output classification, MR images with all modalities and degrees are given to the system at the same time. With AlexNet, GoogleNet, ShuffleNet, SqueezeNet, and InceptionV3 deep learning models, the training was carried out using the transfer learning method. Training times and performances were compared by using the same hyperparameter values in all training. The data set was divided as 80% training 20% test and 5-fold cross-validation was applied. When the performance values of the models with 3-class output are examined, the AlexNet model has the highest performance with the FLAIR modality precision 0.9976 ± 0.0014 , sensitivity 0.9977 ± 0.0014 , specificity 0.9988 ± 0.0007 , accuracy 0.9976 ± 0.0014 , and F1 score of 0.9976 ± 0.0014 . has given. AlexNet model training took a total of 13 minutes and 44 seconds. As a result of training with 4-class output, the InceptionV3 model gave the highest accuracy value with 0.9968 ± 0.0019 in LGG graded images. Other performance values showed high success with 0.9967 ± 0.0020 precision, 0.9967 ± 0.0021 sensitivity, 0.9989 ± 0.0006 specificity, and 0.9967 ± 0.0020 F1 score. The training time has the maximum training time of 3 hours 12 minutes 14 seconds. In the 12-output classification, the AlexNet model achieved the highest values in all performance criteria with 0.9840 ± 0.0036 accuracy, 0.9843 ± 0.0035 precision, 0.9841 ± 0.0033 sensitivity, 0.9985 ± 0.0003 specificity, and 0.9842 ± 0.0034 F1 score. The training took 1 hour 13 minutes 29 seconds. Classification of tumor-diagnosed different sequence magnetic resonance images with deep models yielded high accuracy rates for a powerful computerized decision support system.

Keywords: Brain tumor, Classification, Deep learning, Modality, Transfer learning

ÖNSÖZ

Yüksek lisans tez çalışmamda, akademik bilgi birikimini ve tecrübelerini esirgemediğn öğrencileriyle paylaşan, tez süreci boyunca içtenlikle sorularımı cevaplayan, motivasyonum düştüğünde her zaman destek olan ve tez çalışmama yön veren danışmanım Dr. Öğretim Üyesi Muhammet Üsame ÖZİÇ'e, bizlere yol gösteren ve değerli bilgilerini aktaran bölüm başkanımız Prof. Ahmet AVCI'ya teşekkürü bir borç bilirim. Tez süresince zaman zaman ihmal ettiğim sevgili aileme ve değerli eşime anlayışları ve destekleri için teşekkür ederim.

Türkan DOĞANALP
KONYA-2022



İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
ÖNSÖZ	iii
İÇİNDEKİLER.....	iv
SİMGELER VE KISALTMALAR.....	vi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM.....	17
3.1. Beyin Tümörleri.....	17
3.2. Manyetik Rezonans Görüntüleme	18
3.2.1. T1 ağırlıklı modalite	19
3.2.2. T2 ağırlıklı modalite	20
3.2.3. T1CE modalitesi	21
3.2.4. FLAIR modalitesi	21
3.3. Veri Tabanı	22
3.4. Derin Öğrenme	24
3.4.1. Yapay sinir ağları.....	25
3.4.2. Evrişimli sinir ağları	29
3.4.3. AlexNet.....	34
3.4.4. GoogleNet.....	34
3.4.5. ShuffleNet.....	37
3.4.6. SqueezeNet	37
3.4.7. InceptionV3	38
3.5. Transfer Öğrenme	38
3.5.1. Transfer öğrenmede kullanılan hiper parametreler.....	40
3.6. Performans Değerlendirme Ölçütleri.....	42
3.6.1. 3 sınıf çıkışlı performans kriterleri	47
3.6.2. 4 sınıf çıkışlı performans kriterleri	52
3.6.3. 12 sınıf çıkışlı performans kriterleri	56
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	73
4.1. 3 Sınıf Çıkışlı Sınıflandırma Sonuçları.....	73
4.1.1. AlexNet.....	73
4.1.2. GoogleNet.....	80
4.1.3. ShuffleNet.....	87
4.1.4. SqueezeNet	94
4.1.5. Inception V3	101
4.2. 4 Sınıf Çıkışlı Sınıflandırma Sonuçları.....	108
4.2.1. AlexNet.....	108
4.2.2. GoogleNet.....	114
4.2.3. ShuffleNet.....	120

4.2.4. SqueezeNet	126
4.2.5. Inception V3	132
4.3. 12 Sınıf Çıkışlı Sınıflandırma Sonuçları.....	137
4.3.1. AlexNet.....	137
4.3.2. GoogleNet.....	139
4.3.3. ShuffleNet.....	141
4.3.4. SqueezeNet	143
4.3.5. Inception V3	145
5. SONUÇLAR VE ÖNERİLER.....	148
5.1 Sonuçlar	148
5.2. Öneriler	158
6. KAYNAKLAR	160
EKLER	165

SİMGELER VE KISALTMALAR

Simgeler

Σ	: Toplam
X_N	: Nöron giriş değeri
W_N	: Nöron ağırlık değeri

Kısaltmalar

AUC	: Area Under the Curve
BM	: Beyaz Madde
BMP	: BitMaP
BOS	: Beyin Omurilik Sıvısı
BRATS	: Multimodal Brain Tumor Image Segmentation Benchmark
CE	: Contrast-Enhanced
CPU	: Central Processing Unit
DICOM	: Digital Imaging and Communications in Medicine
dk	: Dakika
DL	: Deep Learning
DN	: Doğru Negatif
DP	: Doğru Pozitif
DVM	: Destek Vektör Makinesi
EKbHFV	: Entropy Kurtosis based High Feature Values
ELM	: Extreme Learning Machine
ESA	: Evrişimli Sinir Ağları
FLAIR	: Fluid Attenuated Inversion Recovery
FN	: False Negative
FP	: False Positive
FPR	: False Positive Rate
GB	: Gigabayt
Gd	: Gadolinyum
GM	: Gri Madde
GPU	: Graphics Processing Unit
H	: Hidrojen
HGG	: High Grade Glioma
HOG	: Histograms of Oriented Gradients
IARC	: Uluslararası Kanser Araştırmaları Ajansı
LBP	: Local Binary Pattern
LGG	: Low Grade Glioma
LOPO	: Leave One Patient Out
LSTM	: Long Short Term Memory
MGA	: Modified the Genetic Algorithm
MICCAI	: Medical Image Computing and Computer Assisted Interventions
MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme
ms	: Milisaniye
MS	: Multiple Sclerosis
MSMCNN	: Multiscale Multimodal Convolutional Neural Network
Nifti	: The Neuroimaging Informatics Technology Initiative

PNG	: Portable Network Graphic
RAM	: Random Access Memory
RELU	: Rectified Linear Unit
RF	: Radyo Frekansı
RMSProp	: Root Mean Squared Propagation
RNN	: Recurrent Neural Network
ROC	: Receiver Operating Characteristics
s	: Saat
SELU	: Scaled Exponential Linear Unit
SGD	: Stokastik Gradyan Düşüşü Scaled Exponential Linear Unit
SGDM	: Stochastic Gradient Descent with Momentum
sn	: Saniye
T	: Tesla
TCGA-GBM	: The Cancer Genome Atlas Glioblastoma Multiforme
TE	: Echo Time
TN	: True Negative
TP	: True Positive
TPR	: True Positive Rate
TR	: Repetition Time
VGGNet	: Visual Geometry Group Network
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı
YZ	: Yapay Zeka

1. GİRİŞ

Dünya düzeninin devamlılığını sağlayan temel unsur yaşamdır. Çevresel ve genetik faktörlerin etkisiyle insan yaşamı olumsuz etkilenerek yaşam standardı düşmekte ve süresi kısalmaktadır. Bu sebeplerden dolayı sağlığını koruyamayan insanlar çeşitli hastalıklara yakalanmaktadır. Günümüzde bu hastalıkların başında gelen kansere yakalanma oranı giderek artmaktadır. Kanser, vücuttaki hücrelerin normal bir şekilde büyümesini engelleyerek dokularda hasarların meydana gelmesine neden olur. Uluslararası Kanser Araştırmaları Ajansı (IARC) tarafından oluşturulan GLOBOCAN 2020 verilerine göre kanser insidansı ve mortalite oranları dünya çapında 185 ülkede yaklaşık 19,3 milyon yeni kanser vakası olduğunu göstermektedir. Kanser sebebiyle ölenlerin oranı yaklaşık 10 milyondur (Ferlay ve ark., 2021). Türkiye’de ise 2020 yılında yaklaşık 234 bin kanser vakası tespit edilmiştir (Özdoğan, 2021).

Beyin, insan vücudunun en önemli ve özel organlarından biridir. İnsan vücudunun temel işlevinin gerçekleşmesini kontrol ederek aynı zamanda sinir sisteminin merkezi olarak görev yapar. Beyin hücrelerindeki anormal büyümeler ve bölünmeler tümör olarak adlandırılmaktadır. Tümör dokuları genel olarak iyi huylu (benign) ve kötü huylu (malignant) olmak üzere iki sınıfa ayrılmaktadır. Kötü huylu tümörler, beyin kanserine neden olmaktadır (Dandıl, 2015). Beyin tümörü kadınlar ve erkekler için ölüm nedeni olarak 10. sırada gelmektedir. Beyin tümörleri yetişkinlerde olduğu gibi çocuklarda da görülmektedir (Anonim, 2021).

Beyin tümörü ölüm oranı, ilk sıralarda yer almasa da teşhis konulduktan sonra hastalığın ilerleme safhası oldukça hızlıdır. Bu yüzden hastalığın erken tanısı ve teşhisi tedavi için önemli bir faktördür. Manyetik Rezonans Görüntüleme (MRG) beyin tümörlerinin görüntülenmesinde en sık kullanılan tanısal görüntüleme yöntemidir. Yumuşak dokuları en net şekilde göstermesi, zararlı ışın içermemesi ve ilaçsız olarak da çekilebilmesi MRG’nin tümör tespitinde en yaygın yöntem olarak kullanılma nedenleridir (Öziç, 2013). Manyetik Rezonans (MR) görüntüleri uzman doktor ve radyologlar tarafından hastalığın kesin ve doğru teşhisinin yapılmasını sağlamaktadır. Doğru ve kesin bir şekilde tanı konulması hastalığın tedavisi ve seyrinin tahmin edilmesi için oldukça önemlidir. Tümörün özelliği ve bulunduğu yere göre farklı tedavi yöntemleri uygulanmaktadır.

MRG yöntemi, tümör bölgesinin en az üç farklı sekansta görüntüleme yapılmasına olanak sağlar. Görüntünün çözünürlüğü, kontrastı ve her dokudaki farklı


proton sayısı görüntülerin oluşmasında önemli etkenlerdir. Bu etkenler Radyo Frekansı (RF) darbelerine, gönderim aralıklarına ve sinyalin geri dönüş süresine göre değişmektedir. T1 ağırlıklı sekanslarda, yağ dokuları hiperintens (parlak) olduğu için anatomik olarak değerlendirmeyi sağlar. T2 ağırlıklı sekanslarda ise su içeren dokular parlak bir şekilde görülmektedir (Arı, 2019). Kontrast madde verilerek elde edilen T1 ağırlıklı görüntüler de T1 Contrast-Enhanced (CE) sekansını oluşturmaktadır. Su dokusunu baskılamak için null point değeri (1700-2250 ms) ayarlandığında sıvılardan gelen sinyaller baskılanır. Bu sekans Fluid Attenuated Inversion Recovery (FLAIR) su baskılama olarak adlandırılmaktadır.

MR görüntülerinin analizi, uzman doktorlar tarafından yapılmasına rağmen zaman alan ve zor bir işlemdir. MR sinyallerinden anlamlı bilgiler çıkarmak bu konuyla ilgili ciddi uzmanlık gerektirmektedir (Dandıl, 2015). Teknolojinin ilerlemesiyle medikal görüntülerde bilgisayar destekli otomatik veya yarı otomatik sistemler kullanılmaktadır. Böylece analiz süresinin kısaltılması ve hata oranının en aza indirilmesi amaçlanmıştır. Yapay Zeka (YZ) kavramının hayatımıza girmesi görüntülerden ve sinyallerden bilgisayarların anlam çıkarmasına olanak sağlamıştır. Çok büyük verilerin işlenerek gerekli bilgilerin elde edildiği, YZ tabanlı Deep Learning (DL) modelleriyle son dönemde literatürde sıklıkla çalışılmaktadır.

Bu tez çalışmasında, Multimodal Brain Tumor Image Segmentation Benchmark (BRATS) 2019 (EK-1, EK-2, EK-3) veri seti kullanılarak derin öğrenme ağları ile T1, T1CE, T2 ve FLAIR modaliteleri sınıflandırılmıştır. Her sekansa ait High Grade Glioma (HGG), Low Grade Glioma (LGG) ve normal olmak üzere 1000'er adet MR görüntü kesiti elde edilmiştir. Toplamda 12 bin görüntü ile farklı senaryolarda denemeler yapılmıştır. Sınıflandırmalarda modalitelere göre üçlü, dörtlü ve on ikili sınıflandırma değerlendirilmiştir. Görüntüler %80 eğitim, %20 test verisi olarak ayrılmıştır. 5 kat çapraz doğrulama işlemi ile veriler AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve InceptionV3 modelleri kullanılarak sınıflandırma gerçekleştirilmiştir. Receiver Operating Characteristics (ROC) eğrisi, eğri altında kalan alan olarak ifade edilen Area Under the Curve (AUC) değerleri, doğruluk, hassasiyet, duyarlılık, F1 puanı ve eğitim süreleri performans kriterleri olarak değerlendirilmiştir.

2. KAYNAK ARAŞTIRMASI

Sharif ve ark. (2021), tarafından yapılan çalışmada BRATS 2018 ve BRATS 2019 veri setleri kullanılarak çok sınıflı beyin tümörleri ön eğitilmiş DenseNet201 ağı ile sınıflandırılmıştır. Çalışmada, Entropy Kurtosis based High Feature Values (EKbHFV) Entropi Kurtosis Tabanlı Yüksek Özellik Değerleri isimli yeni bir özellik seçim yaklaşımı önerilmiştir. Bu yaklaşım ile yinleme sayısı dikkate alınarak özellik seçimi yapılmaktadır. Kullanılan diğer bir teknik ise Modified the Genetic Algorithm (MGA) Değiştirilmiş Genetik Algoritma'dır. Bu yöntemle en iyi özellik seçimi için genetik algoritma değiştirilmektedir. Evrişimli Sinir Ağları (ESA) ile önceden eğitilmiş DenseNet201 modelinde eğitim gerçekleştirilmiştir. Şekil 2.1'de önerilen metotlar ile çok modlu beyin tümörünün sınıflandırılmasına ait adımlar gösterilmiştir.



Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..1. Önerilen derin öğrenme tabanlı çok modlu beyin tümörü sınıflandırması (Sharif ve ark., 2021)

Yapılan çalışmada, önceden eğitilmiş derin öğrenme modelinin başka problemlerde yeniden kullanılmasını sağlayan Transfer Learning (TL) yöntemi ile modeller eğitilmiştir. Eğitim, seçilen özelliklere göre gerçekleşir. Bu çalışmada, Stokastik Gradyan Düşüşü (SGD) optimizasyon yöntemi, 0.0001 öğrenme oranı, 64 mini batch boyutu ve 100 epoch sayısı seçilerek eğitim yapılmıştır. Sınıflandırmada, genetik algoritma ve EKbHFV yöntemi ile seçilen özellikler doğruluk oranını arttırmaktadır. Seçilenler özellikler seri füzyon olarak ifade edilen bir yöntemle kaynaştırılarak fazlalık bilgiler çıkartılmaktadır. Bu işlemlerden sonra elde edilen öznitelikler ile Destek Vektör Makinesi (DVM) algoritması ile sınıflandırılır. BRATS 2018 ve BRATS 2019 veri

setlerinde HGG ve LGG olmak üzere iki sınıf ile FLAIR, T1CE, T1 ve T2 MR sekansları bulunmaktadır. Eğitimler MATLAB 2020a üzerinde 16GB Graphics Processing Unit (GPU) ve Core i7 işlemcili bir donanımla yapılmıştır. Her iki veri kümesi de %50 eğitim, %50 test ve 10 kat çapraz doğrulama verisi olarak ayrılmıştır. Çalışma sonucunda makine öğrenmesi ile derin öğrenme sınıflandırma algoritmalarına ait eğitim sonuçları elde edilmiştir. DVM sınıflandırma yöntemi makine öğrenimi sınıflandırma algoritmalarında en yüksek sonucu veren yöntemdir. Her iki veri setinde de DVM sınıflandırıcısı duyarlılık, kesinlik, F1 puanı ve doğruluk performans ölçütlerinde en yüksek değerlere sahiptir. Önerilen yöntemin doğruluk değeri VGGNet, AlexNet, ResNet10, InceptionV3 ağ modelleri kullanılarak karşılaştırılmıştır. BRATS 2018 veri setinde doğruluk değeri HGG derecesinde %99,7, LGG derecesinde %98,8 iken BRATS 2019 veri setinde doğruluk değeri HGG derecesinde %99,8, LGG derecesinde %99,3 ile en yüksek sonucu vermiştir. Önerilen yöntemde MGA ve Entropi-Kurtosis tabanlı teknikleri kullanarak en optimal özneliklerin seçilmesi hedeflenmiştir. Doğruluğun artırılması ve sınıflandırma süresinin azaltılması çalışmanın en önemli çıktılarından (Sharif ve ark., 2021).


Ranjbar ve ark. (2020), derin öğrenme tekniklerini kullanarak yaptıkları çalışmada T1 ağırlıklı, T1CE, T2 ağırlıklı ve FLAIR olmak üzere dört adet MR modalitesinde görüntü kullanmışlardır. 20 farklı kurumdan elde edilen tedavi öncesi ve sonrası MR görüntüleri, her bir sekansta 1000 benzersiz görüntü serisinin rastgele seçilmesiyle veri seti oluşturulmuştur. Toplamda 14400 iki boyutlu görüntü, rastgele dört eksenel dilimden seçilmiştir. Ön işleme adımında görüntü boyutu, 128x128 piksel olarak yeniden boyutlandırılmış ve dinamik yoğunluk 0-1 aralığında ölçeklendirilmiştir. 14400 adet görüntüden oluşan veri seti 9600 eğitim, 2400 doğrulama ve 2400 test olmak üzere 3 parçaya bölünmüştür. Her veri kümesinde 4 farklı sekansa ait eşit sayıda görüntü bulunmaktadır. Rastgele döndürme, genişlik ve yükseklik kayması, kesme, yakınlaştırma ve yatay çevirme gibi yöntemler kullanılarak veri çoğaltma işlemi yapılmıştır. Eğitim aşamasında, TensorFlow ve Keras kütüphaneleri kullanılmıştır. NVIDIA TITAN V GPU üzerinde eğitim işlemi gerçekleştirilmiştir. VGGNet ağ mimarisinin farklı bir varyasyonu kullanılmıştır. Ağda her 2 katman için 32, 64 ve 128 filtreli 6 evrişimsel katman, 3×3 çekirdek boyutları ve tüm bloklarda 1 adım içeren maksimum havuz katmanı bulunmaktadır. Tüm evrişimli katmanlara, Rectified Linear Unit (RELU) doğrultulmuş bir doğrusal birim aktivasyon işlevi ve toplu normalleştirme eşlik etmektedir. Ağ eğitiminde mini batch boyutu 32, Adam optimizasyon algoritması, başlangıçta $2e^{-4}$ öğrenme hızı seçilerek eğitime başlanmıştır. Öğrenme hızı, ağırlıkların güncellenmesinde

epoch sayısına bölünerek her epoch da azaltılmıştır. Hesaplamalar Scikit-learn ve Scipy paketleri kullanılarak yapılmıştır. Test setinin model performansı incelendiğinde T1 Gadolinyum (Gd) sekansının en düşük duyarlılık değerine, T2 ağırlıklı sekansın ise en yüksek duyarlılık, özgüllük ve doğruluk değerine sahip olduğu görülmüştür. Tüm sekanslarda, sistemin daha önce görmediği veriler kullanılarak yapılan denemelerde %99'un üzerinde doğruluk sağlanmıştır (Ranjbar ve ark., 2020).

Yang ve ark. (2018), GoogleNet ve AlexNet kullanılarak yaptıkları çalışmada, birden fazla kurumdan elde ettikleri MR görüntüleri ile veri seti oluşturmuştur. Çalışmada 51 LGG'li ve 61 HGG'li hastadan elde edilen sadece T1CE görüntüler kullanılmıştır. Görüntü ön işleme adımında, DICOM (Digital Imaging and Communications in Medicine) formatında olan görüntüler BMP (BitMaP) formatına dönüştürülmüştür. Daha sonrasında radyologlar tarafından tümör dokusu içeren veriler seçilerek elde edilen görüntüler %20 test verisi için ayrılarak 5 kat çapraz doğrulama uygulanmıştır. Eğitim verileri, MATLAB 2016a kullanılarak histogram eşitleme, yakınlaştırma, rastgele döndürme, gürültü ekleme ve çevirme yöntemleri ile 14 kez artırılmıştır.

Çalışmada eğitim aşamasında dört NVIDIA Tesla K80 kartıyla AlexNet ve GoogleNet ağırları üzerinde tüm denemeler yapılmıştır. Eğitim, doğrulama ve test veri setleri 5 kat çapraz doğrulama yapılarak performans değerlendirmesi gerçekleştirilmiştir. Sıfırdan eğitilen ESA'ların performans değerlendirilmesinde GoogleNet'in AlexNet'e göre daha iyi performans sergilediği görülmektedir. Önceden eğitim yapılan AlexNet ve GoogleNet verileri incelendiğinde her iki ağda iyileştirilmiş performans görülmektedir. Özellikle AlexNet için test doğruluğu ve AUC değeri, transfer öğrenimi ile Google Net'e yakın seviyelere ulaşmıştır. Bu çalışmada, ameliyat öncesi gliomu derecelendirmek için AlexNet ve GoogleNet üzerinde transfer öğrenimi değerlendirilmiştir. Transfer öğrenimi ile önceden eğitilmiş ağlarda performansın arttığı gözlemlenmiştir (Yang ve ark., 2018).

Şekil 2.2’de LGG ve HGG görüntülere ait farklı kesitlerin yanlış sınıflandırılma örneği verilmiştir. Şekil 2.2a’da HGG olan görüntü LGG olarak, Şekil 2.2b’de de LGG olan görüntü HGG olarak sınıflandırılmıştır.



Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..2. Yanlış sınıflandırma örneği (a) LGG olarak sınıflandırılan HGG (b) HGG olarak sınıflandırılan LGG (Yang ve ark., 2018)

Beyin tümörünün farklı modaliteler kullanılarak sınıflandırılması ile ilgili bir diğer çalışma, Hao ve ark. (2021) tarafından gerçekleştirilmiştir. Beyin tümörü tanılı 335 hastadan (259 HGG ve 76 LGG) oluşan, BRATS 2019 veri seti üzerinde uygulama yapılmıştır. Veriler T1 ağırlıklı, T1CE, T2 ağırlıklı ve FLAIR olmak üzere dört MR sekansından oluşmaktadır. Eğitim setinde 203, doğrulama setinde 66 ve test setinde 66 hastanın MR verisi bulunmaktadır. Görüntüler önceden eğitilmiş ESA’ya uygun olması için 240x240 pikselden 224x224 piksele yeniden boyutlandırılmıştır.

AlexNet’i sıfırdan eğitmek için büyük miktarda etiketli veri gerekmektedir. Transfer öğrenme tekniğini kullanmak, yeterli veri olmadığında modelin performansını iyileştirmektedir. Tüm eğitim veri setinde, önceden eğitilmiş AlexNet’in ince ayarı yapılarak AUC değeri hesaplanmıştır. Hiper parametre değerleri, maksimum epoch sayısı 30, öğrenme oranı 0.001, mini batch boyutu 16, SGD optimizasyon algoritmasının momentumu 0.8 ve L2 düzenleme değeri 0.0001 olarak ayarlanmıştır. Aynı hiper parametre ayarlarıyla AlexNet’in sıfırdan eğitilmesinde daha fazla yinelemeye ihtiyaç duyması nedeniyle epoch sayısı 80’e çıkarılmıştır. Sıfırdan ve önceden eğitilmiş AlexNet AUC sonuçlarında transfer öğrenme yöntemi kullanıldığında, doğrulama seti AUC değeri %1,51 oranında artarken test seti AUC değeri de %7,98 artmıştır. Çalışmada önerilen

yöntemin AUC değeri, test ve doğrulama veri setlerindeki AUC değerine oranla yüksek çıkmıştır. Önerilen yöntemin sağlamlığını doğrulamak amacıyla dengeli bir veri seti oluşturulmuştur. HGG hasta sayısının (259), LGG hasta sayısına (76) oranına göre, HGG ve LGG dilimlerinin sayısı aynı oranda değiştirilmiştir. Önerilen yöntemde, test veri setinden daha iyi bir sınıflandırma performansı elde edilmiştir. Bu çalışma sonucunda, transfer öğrenme tabanlı aktif öğrenme çerçevesi, beyin MRG'sinde tümör sınıflandırmasının yüksek doğruluğunu korurken, gerekli etiketlenmiş eğitim verilerinin boyutunu önemli ölçüde azaltabileceği görülmüştür (Hao ve ark., 2021).

Shahzadi ve ark. (2018), tarafından yapılan çalışmada BRATS 2015 veri seti kullanılarak, toplamda 60 vaka ile HGG-LGG sınıflandırılması yapılmıştır. Glioma özellik çıkarımı için önceden eğitilmiş VGG16, HGG-LGG sınıflandırması için Long Short Term Memory (LSTM) yöntemleri kullanılmıştır. AlexNet ve ResNet ağları ile VGG16'nın özellik çıkarma performansı karşılaştırılmıştır. Sınıflandırma için kullanılan LSTM üç kapılı Recurrent Neural Network (RNN)'nin genişletilmiş bir versiyonudur. Çalışmada kullanılan veri seti içerisinde sadece FLAIR sekansındaki görüntülere yer verilmiştir. Verilerin %80'i eğitim, %20'si ise test amacıyla kullanılmıştır. NVIDIA k4000 GPU ile MATLAB 2018b programında çalıştırılan eğitimler yaklaşık iki saat sürmüştür. Çalışma sonucunda AlexNet, ResNet ve VGG16 ağları karşılaştırılmış olup VGG16 %84 ile en yüksek doğruluk değerini vermiştir. Seçilen hiper parametrelerin değiştirilmesi ve veri miktarı artırma gibi yöntemlerle doğruluğun yüksekselebileceği öne sürülmüştür (Shahzadi ve ark., 2018).

Ge ve ark. (2018), yapmış olduğu çalışmada T1CE, T2 ve FLAIR sekanslarından elde edilen 2 boyutlu görüntü dilimleriyle beyin tümörü sınıflandırması gerçekleştirmiştir. Çalışmada BRATS 2017 veri seti ile HGG ve LGG sınıflandırması, ABD'de bir klinikten alınan başka bir veri seti ile 1p19q kodlaması olan ya da olmayan düşük dereceli gliom sınıflandırması gerçekleştirilmiştir. 128x128 boyutundaki FLAIR, T1CE ve T2 ağırlıklı görüntü dilimleri birleştirilerek giriş olarak verilmektedir. Kullanılan filtrelerin 3x3 boyutunda olması ağırlıklı derinliğini artırarak daha iyi öğrenmesine katkı sağlamıştır. Tüm denemeler, Intel-i7 3.40 GHz Central Processing Unit (CPU), 48 GB Random Access Memory (RAM) ve NVIDIA Titan Xp 12GB GPU donanımına sahip sistemde Keras kütüphanesi kullanılarak yapılmıştır. Adagrad optimizasyon algoritması, öğrenme oranı 0.0001, evrişimli katmanlar için 0.0001 L2 düzenleme değeri kullanılan hiper parametrelerdir. Veri setleri %60 eğitim, %20 doğrulama ve %20 test olmak üzere 3 gruba ayrılmıştır.

BRATS 2017 veri seti ile yapılan eğitimde test veri seti ortalama doğruluk oranı %90,87 bulunmuştur. Modalitelerin ayrı ayrı ve T1CE, T2, FLAIR füzyonu olarak sisteme verilmesi karşılaştırıldığında %91,27 HGG, %90,48 LGG ile en yüksek doğruluk değerleri füzyon yöntemiyle elde edilmiştir. 1p19q kodlaması olan/olmayan glioma sınıflandırmasında ise önerilen yöntemin %89,39 test doğruluğunu sağladığı görülmektedir. Çalışmada önerilen füzyon yöntemi ile performansın yaklaşık %7 oranında arttığı gözlemlenmiştir (Ge ve ark., 2018).

Abd El Kader ve ark. (2021), tarafından yapılan çalışmada diferansiyel bir ESA mimarisi ile beyin tümörleri sınıflandırılmıştır. Önerilen diferansiyel ESA modeli, beş evrişim katmanı ve bu katmanlar arasında bulunan beş ortalama havuzlama katmanından oluşmaktadır. Diferansiyel özellik haritaları, önceden tanımlanan hiper aktif değerler ve diferansiyel operatör uygulanarak elde edilmektedir. Diferansiyel özellik haritaları, evrişim katmanlarını artırmadan sayılarının artmasıyla görüntülerde daha fazla ayrıntının elde edilmesini sağlamaktadır. Tianjin Evrensel Tıbbi Görüntüleme ve Tanı Merkezi'nden elde edilen T1, T2 ve FLAIR sekanslarına ait 17.600 normal ve anormal beyin MR görüntüsü içeren bir veri seti kullanılmıştır. Veri seti içerisindeki görüntülerin birkaç farklı yöntem kullanılarak veri büyütme işlemi yapılması sonucunda, toplamda 25.000 görüntüden oluşan bir görüntü kümesi elde edilmiştir. 5 kat çapraz doğrulama ile eğitim gerçekleştirilmiştir. 5 evrişim katmanındaki özellik haritalarının sayısı 48, 20, 20, 8 ve 4'tür. İlk iki evrişim katmanının filtre boyutu 2x2, diğer katmanlarda ki filtre boyutu ise 3x3'tür. Eğitim Tensorflow, Keras ve Spyder 3.7 kullanılarak NVIDIA Quadro P2200 16 GB donanımla gerçekleşmiştir. AlexNet, GoogleNet, VGG16, BrainMRNet ve birkaç ESA modeli ile model performansı karşılaştırıldığında önerilen modelin, doğruluk değeri %99,25, duyarlılığı %95,89, özgüllüğü %93,75, kesinliği %97,22 ve F1 puanı %95,23 ile en iyi sonuçları elde ettiği izlenmiştir (Abd El Kader ve ark., 2021).

Mzoughi ve ark. (2020), yaptıkları çalışmada BRAST 2018 veri setini kullanarak 3 boyutlu HGG ve LGG MR görüntülerinin sınıflandırmasını gerçekleştirmiştir. Veri seti içerisinde, 209 HGG ve 75 LGG glioma tümörüne ait toplam 284 denekten elde edilen MR görüntüleri mevcuttur. T1Gd sekansına ait görüntülere, normalleştirme ve kontrast işlemleri uygulanarak eğitimlerde kullanılmıştır. Önerilen derin çok ölçekli 3 boyutlu mimaride, 8 evrişimli katman ve 3 tam bağlantılı katman bulunmaktadır. Havuzlama katmanlarında, tümör kenarlarının sınıflandırılması işleminde en uygun özellikleri çıkardığı için maksimum havuzlama yöntemi kullanılmıştır. Python 3.7 ortamında NVIDIA GPU Geforce GTX 1080 Ti 11Go RAM ile donatılmış iş istasyonunda, Keras

ve Tensorflow kütüphaneleri kullanılarak modeller geliştirilmiştir. Kullanılan hiper parametrelerin karşılaştırılmasında RELU, Scaled Exponential Linear Unit (SELU) ve tanh aktivasyon fonksiyonları arasında RELU'nun daha iyi performans sergilediği gözlemlenmiştir. Adam ve SGD optimizasyon algoritmalarında ise Adam'ın performansı daha yüksektir. Önerilen modelde kullanılan 3x3 çekirdek boyutunun, 5x5 ve 7x7 çekirdek boyutuna göre test ve doğrulama veri setinde daha yüksek doğruluk değeri elde edildiği görülmüştür. Önerilen yöntem, literatürde yapılan bazı çalışmalarla karşılaştırıldığında, %96,49 doğruluk değeri ile en yüksek performansı sağlamıştır (Mzoughi ve ark., 2020).

Chatterjee ve ark. (2021), BRATS 2019 veri setinde bulunan T1CE sekansındaki 332 vakaya ait MR görüntüleri ile tümör sınıflandırma çalışması yapmıştır. Patolojik olmayan görüntüler de IXI Dataset'ten elde edilmiştir. Çalışmada ResNet (2+1)D, ResNet Karışık Evrişim ve ResNet3D olarak adlandırılan ağ modelleri kullanılmıştır. ResNet (2+1)D modelinde, önce 2 boyutlu evrişim ve sonrasında 1 boyutlu evrişim kombinasyonu kullanılmaktadır. Bu yöntemde iki evrişim arasına RELU eklenmesi öğrenme işlevini artırmaktadır. ResNet Karışık Evrişim modeli ise 2 boyutlu ve 3 boyutlu evrişim kombinasyonunu içermektedir. ResNet3D modelinde ise tüm evrişim blokları 3 boyutludur. Ağ modelleri, Torchvision modelleri ile değiştirilerek PyTorch ortamında 8 GB belleğe sahip bir NVIDIA RTX 4000 GPU donanımı ile eğitilmiştir.

Model performans karşılaştırması için özgüllük, duyarlılık, kesinlik, F1 puanı ve test doğruluğu kullanılmıştır. Karmaşıklık matrisi kullanılarak sınıf bazında doğruluk değeri elde edilmiştir. Modellerin performansları ön eğitilmiş ve sıfırdan eğitilmiş olarak karşılaştırılmıştır. 3 kat çapraz doğrulama yapılmış ve değerlendirme kriteri olarak ortalama F1 puanı kullanılmıştır. LGG sınıfında, ön eğitilmiş ResNet Karışık Evrişim modeli 0,8949 ortalama F1 puanı, HGG sınıfında ise ResNet Karışık Evrişim modelinde 0,9123 ortalama F1 puanı elde edilmiştir. Sağlıklı beyin sınıfında ise önceden eğitilmiş ResNet3D modelinde, 0,9998 ortalama F1 puanı ile en yüksek sonuç alınmıştır. Bu sınıfın diğer modellerde de ortalama F1 puanları 0,9960'tan fazladır. Makro ve ağırlıklı F1 puanlarına bakıldığında ise ResNet Karışık Evrişim modeli en yüksek değerleri vermiştir. Çalışmada, modellerin önceden eğitilmesiyle ortalama F1 puanlarının arttığı gözlemlenmiştir (Chatterjee ve ark., 2021).


Zhuge ve ark. (2020), tarafından yapılan çalışmada, BRATS 2018 veri setinde yer alan 210 HGG'li ve 75 LGG'li hastaya ait T1, T2, T1CE ve FLAIR görüntüleri ile kamuya açık The Cancer Imaging Archive (TCIA) arşivinden alınan 30 hastaya ait LGG

görüntüleri kullanılmıştır. Çalışmada segmentasyon işlemi yapılarak, 2 boyutlu görüntülerde en geniş tümör alanına sahip dilimler, Mask R-CNN modeli ile sınıflandırılmıştır. Mask R-CNN modelinde özellik çıkarma görevini gerçekleştiren bileşene, omurga modülü adı verilmiştir. ResNet ve özellik piramit ağı kullanılarak özellik çıkarım işlemleri yapılmıştır. Diğer bir bileşen ise Region Proposal Networks (RPN) olarak ifade edilen, özellik haritalarını tarayan ve önerilen ilgili bölgede herhangi bir nesne içerip içermediğini tahmin eden bir sinir ağıdır. RPN tahminlerine göre, konum ve boyutlar seçilerek bir sonraki aşamaya geçilir. Region of Interest (ROI) sınıflandırıcısı, RPN tarafından önerilen bölgeleri girdi şeklinde alarak, sınıflandırma ve sınırlayıcı kutu işlemleri yapmaktadır. Yeni özellik haritaları ile ROI havuzu oluşturulmaktadır. 3 boyutlu tümör derecelendirmesi için 3DConvNet modeli kullanılmıştır. 3DCNN bileşeni ile sınırlayıcı bölge tanımlanarak softmax katmanında tek bir çıktıda görüntü sınıflandırılmıştır. Segmentasyon maskelerine gerek duyulmamıştır. Elde edilen toplam 210 HGG ve 105 LGG verisi, tüm modellerde üçte ikisi HGG, üçte biri LGG olmak üzere 5 kat çapraz doğrulama yapılarak %60 eğitim, %20 doğrulama ve %20 test olarak ayrılmıştır.

Tümör sınıflandırma performansı duyarlılık, özgüllük ve doğruluk kriterleri ile değerlendirilmiştir. Veri artırımı yapılmadan, 2 boyutlu Mask R-CNN metodu ile doğruluk değeri 0,89, duyarlılık 0,86 ve özgüllük 0,91 olarak elde edilmiştir. Veri artırımı yapıldığında ise 2 boyutlu Mask R-CNN metodu ile doğruluk değeri 0,96, duyarlılık değeri 0,93 ve özgüllük değeri 0,97 bulunmuştur. 3DConvNet yönteminde doğruluk değeri 0,97, duyarlılık değeri 0,94 ve özgüllük değeri 0,96 bulunmuştur. 2 boyutlu görüntülerde, 3DConvNet yöntemi kullanılırken veri artırımı yapıldığında daha yüksek sonuç elde edildiği görülmüştür. Önerilen metotlar, Ubuntu 18.4 Linux işletim sisteminde 64 GB belleğe sahip, 20 çekirdekli 2.20 GHZ Xeon CPU ve 2 adet 12 GB NVIDIA Titan Xp GPU donanımı ile gerçekleştirilmiştir. 2 boyutlu tümör sınıflandırmasında 60 bin iterasyon ile eğitim yaklaşık 4 saat sürerken, 3DConvNet metodu kullanıldığında 10 bin iterasyon ile yaklaşık 2 saat sürmüştür (Zhuge ve ark., 2020).

Amin ve ark. (2019), T1, T1CE, T2 ve FLAIR modalitelerine ait MR görüntülerinde füzyon işlemi kullanarak tümör tespiti ile ilgili çalışma yapmıştır. Çalışmanın ilk adımı, dört MR sekansının tek bir görüntüde birleştirilmesinden oluşmaktadır. Kısmi diferansiyel difüzyon filtresi ile gürültü giderme işlemi diğer bir adımdır. Üçüncü adımda segmentasyon için global eşikleme uygulanmış ve son olarak segmente edilmiş görüntüler ESA modeline verilmiştir. Önerilen metotta, tümör

bulunmayan ve tümör bulunan görüntüleri sınıflandırmak için konvolüsyon katmanı, batch normalizasyonu, RELU fonksiyonu, maksimum havuzlama katmanı, tam bağlantılı katman ve softmax katmanı kullanılmıştır. Dalgacık dönüşümü için Daubechies dalgacık dönüşümü çekirdeği işlevsel ve sayısal analize yardımcı olduğu için tercih edilmiştir. Dört MR dizisi dalgacık dönüşüm yöntemi ile tek bir görüntüde birleştirilerek, tüm sekanslardaki doku ve yapı bilgilerini içerdiği için ayrıntılı bir bilgi sağlamaktadır. Şekil 2.3'te görüldüğü üzere FLAIR ve T1 birleştirilerek F1, T1CE ve T2 birleştirilerek F2 elde edilmiş, F1 ve F2 birleşimiyle F3 elde edilmiştir. Global eşikleme yöntemi ile görüntüler bölümlere ayrılarak lezyon güçlendirmesi ve segmantasyon işlemi yapılmıştır.



Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..3. BRATS veri seti görüntü dizilerinin birleşimi (Amin ve ark., 2019)

Segmantasyondan elde edilen görüntüler, farklı parametrelerle önerilen ESA modeline verilmektedir. Hiper parametreler, maksimum epoch sayısı 40, doğrulama frekansı 30, öğrenme oranı 0,01 olarak ayarlanmıştır. Önerilen yöntemin BRATS 2012, BRATS 2013, BRATS 2015 ve BRATS 2018 veri setleri ile performans değerlendirilmesi yapılmıştır. Değerlendirme için veri setlerinde T1, T1CE, T2, FLAIR, (T1CE + T2) ve (FLAIR + T1) MR sekansları ile tüm görüntülerin birleştirildiği MR görüntüleri incelenmiştir. Füzyon MR sekansında doğruluk, duyarlılık ve özgüllük değerlerinin arttığı gözlemlenmiştir. BRATS 2013, BRATS 2015 ve BRATS 2018'de sırasıyla doğruluk değerleri 0,98, 0,96 ve 0,97, duyarlılık değerleri 0,99, 0,98 ve 0,99 iken, özgüllük değerleri 0,95, 0,92 ve 0,93 olarak bulunmuştur (Amin ve ark., 2019).

De Mello ve ark. (2021), ResNet 18 ağını kullanarak BRATS 2015 ve BRATS 2019 veri seti ile görüntü sınıflandırma çalışması yapmıştır. Bu çalışmada ESA mimarilerinden farklı olarak 3 kanallı girdi görüntüleri yerine, kullanıcı tarafından belirtilen kanal ve dilim sayısı parametreleri seçilmektedir. Farklı format ve boyuttaki MR hacimleriyle çalışılmasını sağlayan bir yöntem önerilmektedir. Veriler yüklenirken öncelikle merkezde bulunan 16 dilim ayıklanmakta, eğer dilim sayısı 16'dan az ise 16 derinlikli hacim oluşturulana kadar çoğaltma işlemi yapılmaktadır. Verilerin derinliklerinin her biri 200x200x16 piksel olacak şekilde yeniden boyutlandırılarak z eksen dönüşümleri ve parlaklık ayar işlemleri ile veri artırımı yapılmaktadır. Test işleminde elde edilen derinlikli görüntüler, her eğitimde rastgele farklı merkez dilimli alt gruplara ayrılmıştır. Sistemin çıkışı T1, T1CE, FLAIR, T2 ve diğer (önceki sınıflardan herhangi biri) olmak üzere 5 modaliteden oluşmaktadır. 1096 eğitim verisi ve 440 doğrulama verisinden oluşan BRATS 2015, 1340 eğitim verisi ve 500 doğrulama verisinden oluşan BRATS 2019 temel veri kümeleridir. Bir diğer veri kümesi ise The Cancer Genome Atlas Glioblastoma Multiforme (TCGA-GBM) adı verilen çeşitli kanser türlerini analiz etmek için belirli genomik nedenleri ve profilleri kataloglayan bir projeden elde edilmiştir. Bunun yanı sıra BRATS 2015, BRATS 2019 ve TCGA-GBM veri kümelerinden elde edilen veriler birleştirilerek 5 özel veri seti oluşturulmuştur.

Eğitimler sırasında mini batch boyutu 32, öğrenme oranı 0.01, epoch sayısı 300, SGD momentum değeri 0.9 olarak belirlenen hiper parametrelerdir. Eğitim sırasında girdi hacmi derinlik değeri (n) 4 olarak verildiğinde optimal sonuç alınmıştır. 4 sınıflı veri kümelerinde yapılan eğitimlerde, aynı türde test verilerinde BRATS4 %99,2, karışık verilerle test edildiğinde BRATS4 + TCGA4 %82,90 ve TCGA4 veri kümesinde %62,44 doğruluk değeri elde edilmiştir. TCGA4 ise aynı tür verilerde %92,99, karma verilerde %65,01 ve farklı tür verilerde %42,59 doğruluk göstermiştir. 5 sınıf veri seti TCGA5 ile yapılan eğitimlerde, aynı tür verilerde %94,66, karışık verilerde ise %52,68 doğruluk elde edildiği görülmüştür (De Mello ve ark., 2021).

Saba ve ark. (2020), tarafından yapılan çalışmanın içeriği, gerçek lezyon semptomlarının Grabcut yöntemi ile bölütlenmesi ve transfer öğrenme yöntemiyle VGG19 ağında eğitilerek sınıflandırılmasıdır. Önerilen metotla, öncelikle MR görüntülerinde bulunan glioma, segmentlere Grabcut yöntemi kullanılarak ayrılmaktadır. Bunun için RGB formatındaki görüntü tek bir kanala dönüştürülerek 0 -180 arasında eşik noktaları seçilmektedir. Benzer değerdeki pikseller belirli eşik seviyesinden gruplandırılarak tümör segmentli dilimler elde edilmektedir. Konvolüsyon, maksimum

havuzlama ve tam bağlantılı katmandan oluşan VGG19 modeli ile eğitimler gerçekleştirilir. Görüntülerin sınıflandırılmasında, Local Binary Pattern (LBP) doku bilgileri, Histograms of Oriented Gradients (HOG) algoritması öznitelikleri ve derin öğrenme ile elde edilen diğer öznitelik çıkarımları yapılmıştır. Elde edilen birden fazla özellik vektörü birleştirilmiştir. BRATS 2015, BRATS 2016 ve BRATS 2017 veri setleri eğitimlerde kullanılmıştır. Veri seti içerisinde HGG ve LGG görüntüler mevcuttur. Denemeler MATLAB 2018b ortamında Intel Core I7 3.4 GHz, RAM 16 GB, 64 bit işletim sistemi, x64 tabanlı işlemci ve NVIDIA GeForce GTX 1080 donanımı ile gerçekleştirilmiştir. LBP+HOG, derin özellikler ve füzyon (LBP + HOG + derin özellikler) özellikleri kullanılarak çoklu sınıflandırma ile her veri setinde eğitim yapılmıştır. Önerilen yöntem karar ağacı, lojistik regresyon, k-Nearest Neighbors (k-NN) ve DVM sınıflama yöntemleri ile karşılaştırılmıştır. Füzyon özellikler karşılaştırıldığında BRATS 2017 veri setinde en yüksek doğruluğa %99,25 ile lojistik regresyon yöntemi, BRATS 2015 ve BRATS 2016 veri setlerinde ise önerilen yöntem sırasıyla %91,30 ve %91,74 doğruluk değerlerine ulaşmıştır. Füzyon yönteminin aynı zamanda bütün sınıflandırma yöntemlerinde, diğer özelliklere göre daha yüksek performans sağladığı görülmüştür (Saba ve ark., 2020).


Anaraki ve ark. (2019), tarafından yapılan çalışmada ESA ve genetik algoritmaya dayalı bir yöntem ile farklı derecelerdeki gliomalar sınıflandırılmıştır. Veri setleri araştırma amacıyla çevrimiçi olarak erişilebilen dört veri tabanından elde edilmiştir. Çalışmada kullanılan veri seti, herhangi bir lezyon bulunmayan yaklaşık 600 MR görüntüsünden oluşan IXI, TCGA-GBM koleksiyonunda yer alan 299 LGG MR görüntüsü, 130 hastaya ait HGG ve LGG görüntülerinden oluşan REMBRANDT ve Tahran'da bir hastaneden alınan 60 hastaya ait MR görüntülerinden oluşmaktadır. Çalışmada normal beyin MR görüntüleri dışında, T1 aksiyal görüntüleri kullanılmıştır. Normal MR görüntülerinde, her hastaya ait aynı aralıklarla ortalama altı MR dilimi seçilmiş bu görüntüler sağlıklı ve tümörlü beyin görüntülerini ayırt etmek için kullanılmıştır. Verilere 10°, 20° ve 30° saat yönünde ve saat yönünün tersine döndürme, 15 piksel sağa ve sola çevirme, orijinal boyuta 0,75 oranında ölçeklendirme ve yansıtma gibi rastgele işlemler uygulanarak veri artırma yapılmıştır. Toplamda 8000 normal MR görüntüsü ile 8000 glioma MR görüntüsü eğitim ve test için ayarlanmıştır. Başlangıçta rastgele 50 parametrelili bir ağ oluşturularak %80 eğitim ve %20 doğrulama veri seti kullanılmıştır. Birden fazla ağ modelini ve sınıflandırıcıyı birleştirerek model ortalamasını alan torbalama adı verilen bir yöntem, genetik algoritma tarafından

geliştirilen en iyi model olarak belirlenmiştir. Önerilen yöntemde, normal ve üç tümör derecesine ait görüntülerden oluşan Vaka Çalışması 1'in ve glioma, meningioma ve hipofiz tümörlerinin sınıflandırıldığı Vaka Çalışması 2'nin karşılaştırılması yapılmıştır. Her iki çalışma grubunda da %94 üzerinde doğruluk sağlanmıştır. Vaka Çalışması 1'de normal MR görüntüleri %99,7, Vaka Çalışması 2'de ise hipofiz tümörü %97,4 ile en yüksek doğruluk değerlerine ulaşmıştır (Anaraki ve ark., 2019).

Rajasree ve ark. (2021), tarafından yapılan çalışmada T1, T1CE, FLAIR ve T2 modalitelerinde piksel özelliklerinin çıkarılmasını ve anlamsal bölütlenmesini geliştirmek amacıyla Multiscale Multimodal Convolutional Neural Network (MSMCNN) olarak ifade edilen, çok modlu çok ölçekli derin öğrenme modeli önerilmiştir. U-Net tabanlı evrişim ağları ile 2 boyutlu MR görüntülerinde, anlamsal bölütleme için tam otomatik beyin görüntü tanıma tekniği önerilmiştir. BRATS 2015 veri seti içerisindeki 54 LGG ve 220 HGG görüntülere 5 kat çapraz doğrulama uygulanmıştır. Denemelerde eğitim seti olarak 34 HGG ve 120 LGG, test veri seti olarak 20 HGG ve 70 LGG MR görüntüsü kullanılmıştır. LGG ve HGG tümör dereceli görüntülere MSMCNN-LTSM tabanlı anlamsal bölütleme için her 4 modalite girdi olarak verilmektedir. Her modalite 64x64, 128x128 ve 240x240 olmak üzere 3 farklı piksel ölçeğine bölünmüştür. 3 farklı yama LSTM ağı tarafından birleştirilerek sınıflandırma için eğitilir. Softmax katmanı ile çıktı elde edilir. Anlamsal bölütlemeye, her pikselin etiketlenmesi için yama sınıflandırılması yapılır. Önerilen yöntemde simetrik bir yapıya sahip U-Net mimarisinde, 64x64, 128x128 ve 240x240 gibi farklı giriş görüntü boyutlarında üç yollu akışlar tasarlanmıştır. Bu U-Net katmanında, daralma ve genişleme yolu, tüm girdi MR görüntülerini sınıflandırmak yerine, girdi MR görüntülerinde piksel bazında segmentasyon haritasını tahmin eder. MR görüntülerinde piksel sınıflarına bağlı olarak tümörün farklı kısımlarını tahmin etmek ve eş zamanlı özellik haritalarını genişleyen yola geçirmek için U-Net mimarisi kullanılır (Rajasree ve ark., 2021).

Khan ve ark. (2020b), tarafından yapılan çalışmada BRATS 2015, BRATS 2017 ve BRATS 2018 veri setleri kullanılarak multimodal beyin tümörü sınıflandırılmıştır. T1 ve T1CE sekanslarındaki sığ kontrastın giderilmesi için doğrusal kontrast geliştirme tekniği uygulanarak histogram eşitleme ve ayrık kosinüs dönüşümü uygulanmıştır. İki farklı ESA modelinde öznitelik çıkarımı için transfer öğrenme kullanılmıştır. ESA modellerinden elde edilen özniteliklere füzyon işlemi yapılarak daha fazla bilgi içeren öznitelik vektörü elde edilmesi amaçlanmıştır. Performansı arttırmak için Extreme Learning Machine (ELM) tekniği ile sınıflandırma yapılmıştır. Derin öğrenme özellikleri

VGG16 ve VGG19 modelleri ile elde edilmiştir. Şekil 2.4'te önerilen sistem tarafından tahmin edilen etiketli sonuçlar, yeşil kutucuk içinde kırmızı yazıyla verilmiştir. MATLAB 2019b üzerinde önerilen tekniğin deneyleri gerçekleştirilmiştir. ELM sınıflandırıcı ile önerilen özellik seçme yönteminin sonuçlarına bakıldığında BRATS 2015 doğruluğu %98,16, BRATS 2017 doğruluğu %97,26 ve BRATS 2018 doğruluğu ise %93,40 olarak elde edilmiştir (Khan ve ark., 2020b).



Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..4. Önerilen sistem tarafından oluşturulan etiketli sonuçlar (Khan ve ark., 2020b)

Sameer ve ark. (2020), tarafından yapılan çalışmada LGG ve HGG dereceli MR görüntüleri, segmentasyon yapılarak sınıflandırılmıştır. Görüntü kalitesinin artırılması için Uyarlanabilir Histogram Eşitleme yöntemi kullanılmıştır. U-Net'e dayalı tümör segmentasyonu yapılarak tümör bölgeleri ve sağlıklı dokular ayrılmıştır. Segmentasyon model çıktısı dört MR modalitesine uygulanarak 3 boyutlu ESA'ya dayalı bir tümör sınıflandırması yapılmıştır. Sınıflandırmada 5 kat ve 10 kat çapraz doğrulama yöntemi uygulanmıştır. Denemeler BRATS 2015 veri seti kullanılarak yapılmıştır. 5 kat çapraz doğrulama yapıldığında %96,35 doğruluk, %95,90 duyarlılık ve %98,14 özgüllük değerleri, 10 kat çapraz doğrulamada ise %98,54 doğruluk, %99,09 duyarlılık ve %96,29 özgüllük değerleri elde edilmiştir. 10 kat çapraz doğrulamada performans değerlerinin yükseldiği görülmektedir. Segmentasyon doğruluğu %99,77, duyarlılık %99,76 ve özgüllük %99,77 olarak elde edilmiştir (Sameer ve ark., 2020).

Banerjee ve ark. (2019), tarafından yapılan çalışmada BRATS 2017, TCGA-GBM ve TCGA LGG veri setleri kullanılarak tümör derecelerinin sınıflandırılması yapılmıştır. Transfer öğrenimi için VGGNet ve ResNet50 mimarileri kullanılmıştır. ESA modelleri Python programlama dilinde Keras ve TensorFlow kütüphaneleri kullanılarak geliştirilmiştir. Model doğrulaması için Leave One Patient Out (LOPO) olarak ifade edilen bir hastayı dışarda bırakma testi ve holdout testi kullanılmıştır. Çalışmanın ilk aşamasında, LGG ve HGG dereceli tümör sınıflandırılmasında, LOPO testinde VolumeNet modeli %97,19 ile en yüksek doğruluk değerini elde etmiştir. Holdout testinde de VolumeNet modeli %95 doğrulukla en yüksek sonucu vermiştir. Çalışmanın diğer aşamasında 1p19q kodlaması olan ya da olmayan LGG sınıflandırılmasında ise T1CE ve T2 MR sekansları ile gerçekleştirilen eğitimde VolumeNet modeli holdout testinde %97 doğruluk elde edilmiştir (Banerjee ve ark., 2019).

Khan ve ark. (2020a), tarafından yapılan çalışma tümör bulunan ve tümör bulmayan görüntülerin sınıflandırılmasına yöneliktir. 253 beyin MR görüntüsünden oluşan veri setine veri çoğaltma teknikleri uygulanmıştır. Veri seti eğitim, test ve doğrulama olarak üçe ayrılmıştır. MR görüntüleri görüntü işleme teknikleri ile koyu kenarlar kırılarak sadece beyin kısmı ile eğitilmiştir. Eğitimler Python dilinde Keras ve TensorFlow kütüphaneleri kullanılarak gerçekleştirilmiştir. Önerilen yöntemin performansı VGG16, ResNet50 ve InceptionV3 modelleri ile karşılaştırılmıştır. Önerilen model, eğitim verilerinde %96 doğruluk, doğrulama verilerinde ise %89 doğruluk değeri vermiştir. VGG16 modelinde eğitim verilerinde %90, doğrulama verilerinde ise %87 doğruluk elde edilmiştir. ResNet50 modeli eğitim verilerinde %92, doğrulama verilerinde %87 doğruluk değeri elde ederken, InceptionV3 modeli ise eğitim verilerinde %93, doğrulama verilerinde %83 doğruluk değeri sağlamıştır. Diğer performans kriterlerine bakıldığında ise önerilen model doğruluk, kesinlik, duyarlılık, F1 puanı ve ROC- AUC değeri 1 olarak bulunmuştur. Aynı zamanda önerilen ESA modeli ile eğitim süresi, diğer modellerden çok daha kısa bir sürede gerçekleşmiştir (Khan ve ark., 2020a).

3. MATERYAL VE YÖNTEM

3.1. Beyin Tümörleri

İnsan vücudundaki hücreler bir sistem içerisinde büyümekte, bölünmekte ve ölmektedir. Ancak bazen hücrelerin işleyişi aksayarak normalden farklı bir şekilde büyümeler ve çoğalmalar görülmektedir. Beyinde de meydana gelen bu anormal büyüyen ve çoğalan hücreler bir kitle oluşturmaktadır. Bu oluşan kitleye tümör denilmektedir. Beyin tümörü, birçok farklı isimlendirmelerle anılmaktadır. İyi huylu (benign) ya da kötü huylu (malign) tümör isimlendirmesi en yaygın kullanım şeklidir. İyi huylu tümörler yavaş büyür, nadiren diğer organlara yayılım gösterir ve cerrahi operasyonlar ile alınabilir. Kötü huylu tümörler ise hızlı bir şekilde büyümekte ve diğer organlara yayılım göstermektedir. Bu tümörler hücrenin tipine ve bulunduğu yere göre sağ kalım süresini etkilemektedir. Beyin ve omurilikte başlayan primer beyin tümörü, merkezi sinir sistemi tümörlerinin %85'ten fazlasını oluşturmaktadır. Sekonder (metastaz) beyin tümörü ise vücudun diğer bölgelerinde başlayarak beyne yayıldığı süreçte oluşan tümörlerdir. Beyne yayılan en yaygın kanserler meme, böbrek, akciğer, lösemi, lenfoma ve melanomdur (Anonim, 2021).

Beyin tümörü, hücresel özelliklere (hücre tipi, konumu, doku türü) göre sınıflandırılmaktadır. Dünya Sağlık Örgütü'nün (DSÖ) belirlemiş olduğu sınıflandırma ve evreleme sistemi günümüzde dünya çapında kullanılmaktadır. Buna göre teşhis edilen tümörlerin tedavi edilmesi ve tedavilerinin planlanması yapılmaktadır. Bu sisteme göre kötü huylu tümörler 4 evrede gruplandırılır. Evre I ve II LGG, Evre III ve IV HGG olarak ayrılmaktadır (Dandıl, 2015; Şimşek ve Dicle, 2017).

Beyin tümörlerinin oluş nedeni günümüzde tam olarak bilinmese de yoğun olarak X ışınına maruz kalınması, nadir de olsa genetik durumların, bazı nörolojik hastalıkların ve çevresel faktörlerin etkisiyle oluştuğu tahmin edilmektedir. Beyin tümörünün en sık rastlanılan belirtileri arasında sık baş ağrısı, bilinç bozukluğu, mide bulantısı, kusma, görme bozukluğu ve genel yorgunluk bulunmaktadır. Beyin tümörü tanısında, öncelikle fiziki ve nörolojik muayene yapılarak isteğe göre MR ya da beyin tomografisi yöntemleriyle hastalık tanısı konulmaktadır (Tanash, 2020). Tıbbi görüntüleme ve laboratuvar sonuçlarına göre hastanın tedavi süreci planlanmaktadır.

3.2. Manyetik Rezonans Görüntüleme

MRG, insan vücudundaki yumuşak dokunun net ve detaylı bir şekilde görüntülenmesini sağlayan medikal bir görüntüleme tekniğidir. MRG'nin temeli, Hidrojen (H) atomunun manyetik özelliğinin 1924 yılında keşfedilmesine dayanmaktadır (Yüksel, 2019). 1938 yılında yapılan çalışmada, manyetik alana maruz kalan atom parçalarının farklı frekanslarda radyo dalgaları yaydığını gösteren Rabi, 1944 yılında Nobel Fizik Ödülü'ne layık görülmüştür (Coşkun, 2019). Uzun yıllar süren çalışmalar sonucunda, MRG'nin insan vücuduna ilk kez uygulanması 1973 yılında Paul C. Lauterbur tarafından gerçekleştirilmiştir. Fourier Transform tekniğinin 1975 yılında geliştirilmesinin ardından, tüm vücut MR görüntüsü 1977'de Raymond Damadian tarafından elde edilmiştir (Oyar, 2008).

MR cihazı, manyetik alan oluşturmak için büyük mıknatıslardan, sinyalin 3 boyutta kodlanmasını sağlayan gradiyent sargılardan ve düzenli olarak RF dalgaları üreten RF sargılarından meydana gelmektedir (Dandıl, 2015). Manyetik alan birimi, Tesla (T) olarak ifade edilmektedir. Genellikle MR cihazlarında, manyetik alan kuvveti 1.5 T olan mıknatıslar kullanılmaktadır. Görüntü kalitesinin daha yüksek çözünürlüğe ulaşması için mıknatısların oluşturduğu manyetik alan 8T büyüklüğünde olabilmektedir (Coşkun, 2019).

İnsan vücudunun büyük bir kısmı su ve yağ moleküllerinden meydana gelmektedir. Su ve yağ moleküllerinde yüksek miktarda H atomu bulunmakta ve bu oran vücudun %63'üne denk gelmektedir. Cihazın içerisine düz bir şekilde uzanan kişilerin, hareket etmeden 3 boyutlu görüntülerinin elde edilmesi sağlanmaktadır. MR görüntüsü elde edilirken, hastanın vücuduna uygulanan RF atımları ile H atomlarının hareketlerinde oluşan farklılıklar, alıcı sargılar tarafından elektrik akımını meydana getirmektedir. Bilgisayar ortamında MR sinyalleri K-space adı verilen matrise yerleştirilerek, Fourier dönüşümü yapılmaktadır. Sinyallerin yoğunluğuna bağlı olarak, piksel değerinin parlaklığı belirlenmekte ve görüntü oluşturulmaktadır.


MRG yönteminde, dokuların daha detaylı incelenmesi için farklı sekanslar tasarlanmıştır. Görüntünün çözünürlüğü, kontrastı ve her dokudaki farklı proton sayısı görüntülerin oluşmasında önemli etkenlerdir. Bu etkenler RF darbelerine, gönderim aralıklarına ve sinyalin geri dönüş süresine göre değişmektedir. RF dalgasının atım süresine ve enerjinin gücüne bağlı olarak sapma açıları belirlenmektedir. Sapma açıları sekansların temelini oluşturmaktadır. Her bir sekans, görüntülerin analiz edilmesinde

farklı fayda sağlamaktadır. Hastaların durumuna göre sekanslar seçilerek analiz işlemleri gerçekleştirilmektedir (Öziç, 2013; Coşkun, 2019). MRG görüntüleri aksiyal, sagittal ve koronal olmak üzere üç farklı planda elde edilmektedir. MRG’de, Echo Time (TE) ve Repetition Time (TR) olarak ifade edilen iki zaman parametresi görüntü elde etmek için kullanılmaktadır. TE yankı zamanı, RF darbesinin gönderilmesi ile alınması arasında geçen süreyi ifade etmektedir. TR süresi, aynı kesite uygulanan RF darbelerinin tekrarlanma süresidir. Dokuların karakterize edilmesini sağlayan diğer parametreler ise T1 ve T2 dinlenme süreleridir. T1, protonların eski konumlarına dönmeleri için geçen süre, T2 ise defaze olma süresidir.

Radyasyon riski taşımaması, yumuşak dokularda göstermiş olduğu yüksek kontrastlı görüntüleme sağlaması ve hastayı hareket ettirmeden, tüm vücudunun farklı düzlemlerden görüntülenmesinin sağlanması MRG tanı yönteminin avantajlı yönleridir (Oyar, 2008).

3.2.1. T1 ağırlıklı modalite


T1 ağırlıklı görüntülerin oluşumunda, T1 dinlenme zamanı önemlidir. Bu sürede, dokularda oluşan farklılıkların ayırt edilmesi sağlanmaktadır. T1 ağırlıklı görüntüler, yağ ve su içeren dokuları birbirinden ayırmak için kullanılmaktadır. T1 ağırlıklı MRG taramalarında, anatomik özellikler ön plana çıkmaktadır. TR ve TE sürelerinin kısa olması sebebiyle, Beyin Omurilik Sıvısı (BOS) ve su dokuları karanlık, beynin Gri Madde (GM), Beyaz Madde (BM) ve yağ dokuları ise daha parlak görünmektedir (Tanash, 2020). Lezyonlar T1 ağırlıklı görüntülerde hipointenstir. Şekil 3.1’de BRATS 2019 veri setinden elde edilen T1 ağırlıklı görüntü örneği verilmiştir.



Şekil 3.1. T1 ağırlıklı beyin MR görüntüsü

3.2.2. T2 ağırlıklı modalite

MRG’de en çok kullanılan taramalardan biri de T2 ağırlıklı görüntülerdir. T1 ağırlıklı görüntülere benzer olarak su ve yağ dokularının ayrımı yapılabilmektedir. T1 ağırlıklı görüntülerin aksine TR ve TE süreleri uzun olduğu için yağ dokuları, BM ve GM koyu renkte, su dokuları ve BOS ise parlak görünmektedir. Ödem ve lezyonlar da T2 ağırlıklı görüntülerde parlak görüntülenmektedir. BRATS 2019 veri setinden elde edilen T2 ağırlıklı görüntü örneği Şekil 3.2’de gösterilmiştir.



Şekil 3.2. T2 ağırlıklı beyin MR görüntüsü


T1 ve T2 ağırlıklı görüntülerin, dokulardaki renk tonu farklılıkları Çizelge 3.1’de özetlenmiştir.

Çizelge 3.1. Dokulardaki sinyal yoğunlukları (Öğretmenoğlu Fıçııcı, 2016)

Doku	T1 Ağırlıklı Görüntü	T2 Ağırlıklı Görüntü
BOS	Siyah	Çok parlak
Gri Madde	Gri	Açık Gri
Beyaz Madde	Parlak	Gri
MS lezyonu (Multiple Sclerosis)	Gri	Parlak
Tümör	Koyu Gri	Parlak
Ölü Doku	Koyu Gri	Parlak
Beyin Zarı Tümörü	Gri	Gri
Ödem	Koyu Gri	Parlak
Apse	Koyu Gri	Parlak

3.2.3. T1CE modalitesi

T1CE olarak isimlendirilen modalitede, hastaya Gadolinyum (Gd) içeren ilaçlar verilmektedir. Bu yüzden bu modalite bazı kaynaklarda T1Gd olarak da isimlendirilmektedir. Gadolinyum, vücudun iç yapılarının daha net görüntülenmesini sağlayan kontrast bir maddedir. Kontrast madde birikimi kan damarlarının, lezyonların ve tümörün parlak görüntülenmesini sağlamaktadır. Şekil 3.3'te BRATS 2019 veri setinden elde edilen T1CE modalite örneği verilmiştir.




Şekil 3.3. T1CE modalitesi beyin MR görüntüsü

3.2.4. FLAIR modalitesi

FLAIR modalitesi, sıvılarda boşaltma tekniği ile lezyonların görüntülenmesinde kullanılmaktadır. Özellikle iskemi ve MS plakları gibi lezyonların tespitini kolaylaştırırken, kanama ve menenjit gibi lezyonlardan da önemli bilgiler elde edilmesini sağlamaktadır. FLAIR modalitesi T2 ağırlıklı görüntülere benzemekte fakat TR ve TE süreleri çok uzun olduğu için patolojilerin çoğunluğu parlak görünmektedir (Dandıl, 2015).


Şekil 3.4'te BRATS 2019 veri setinden elde edilen FLAIR modalite örneği gösterilmiştir.



Şekil 3.4. FLAIR modalitesi beyin MR görüntüsü

3.3. Veri Tabanı


Tez çalışmasında beyin MR görüntüleri, Medical Image Computing and Computer Assisted Interventions (MICCAI) topluluğunun sunduğu, BRATS 2019 veri setinden elde edilmiştir. Şekil 3.5'te BRATS 2019 ana sayfasının ekran görüntüsü verilmiştir (Anonim, 2020a).



Şekil 3.5. BRATS 2019 ana sayfası

BRATS 2019 veri seti içerisinde, 259 HGG, 76 LGG olmak üzere toplamda 335 beyin tümörü teşhisi konulmuş hastalara ait beyin MR görüntüleri bulunmaktadır. Görüntüler 240x240x155 boyutundadır. Veri kümesi içerisinde, HGG ve LGG klasörlerinde her hastaya ait T1, T1CE, T2 ve FLAIR modalitelerinde görüntüler ve ‘seg’ olarak isimlendirilen gold standardına ait görüntüler bulunmaktadır. Beyin MR görüntüleri The Neuroimaging Informatics Technology Initiative (Nifti) formatındadır. Nifti formatındaki görüntüler MRicro programı (Anonim, 2020b) aracılığıyla incelenmiştir. Çözünürlüğü düşük olan ya da beyin bölgesinin tam olmadığı MR görüntüleri, denemeler için oluşturulan veri kümesine dahil edilmemiştir.

Gold standartta, tümör bölgeleri 1 (aktif tümör bölgesi), 2 (ödem) ve 4 (nekrotik / ölü doku) olarak etiketlenmiştir. Seg dosyası içerisindeki maskeler incelenerek her bir Nifti formatındaki görüntülerde tümörün görüldüğü kesit aralıkları belirlenmiştir. Görüntüler üzerinde işlem yapabilmek için tüm Nifti formatındaki görüntüler Portable Network Graphic (PNG) formatına dönüştürülmüştür. Dönüştürülen her bir modaliteden 155 adet (kesit sayısı kadar) görüntü elde edilmiştir. Denemelerde kullanılan veri kümesi için tümör kesit alanları her modalitede aynı sayıda ve aynı kesite ait olacak şekilde ayarlanmıştır. Tümörün görülmediği kesitler ise normal MR görüntüleri olarak seçilmiştir. HGG, LGG ve normal sınıflarda yer alan, dört modalitede 1000’er görüntü, toplamda 12000 görüntü ile denemelerde kullanılan veri kümesi oluşturulmuştur. BRATS 2019 veri setinden elde edilen ve denemelerde kullanılan MR dilimleri EK-1’de HGG dereceli, EK-2’de LGG dereceli ve EK-3’te normal MR görüntüleri olarak verilmiştir (Menze ve ark., 2014; Bakas ve ark., 2017; Bakas ve ark., 2018). BRATS 2019 veri setinde FLAIR modalitesine ait Şekil 3.6a’da HGG, Şekil 3.6b’de LGG ve Şekil 3.6c’de normal MR görüntüleri verilmiştir.



Şekil 3.6. FLAIR modalitesine ait 3 görüntü (a) HGG (b) LGG (c) Normal

3.4. Derin Öğrenme

Derin öğrenme, temelinde yapay sinir ağları bulunan, büyük ve karmaşık veri kümelerinden anlamlı bilgiler çıkarılmasında kullanılan makine öğrenmesinin bir alt dalıdır. Son 20 yılda dijital platformların ortaya çıkması, çok fazla verinin elde edilmesini sağlamıştır (Ölmez, 2020). Biriken devasa boyuttaki verilerden anlamlı bilgiler çıkarmak için çok hızlı matematiksel işlemler yapan bir modele ihtiyaç duyulmuştur. Teknolojik gelişmelerle birlikte, özellikle GPU ve CPU donanım ünitelerinin kapasitesinin ve işlem gücünün artması derin öğrenmeye olan ilgiyi artırmıştır. 1998 yılında, LeCun ve arkadaşları tarafından el yazı karakterlerinin sınıflandırılması, ESA modelleri kullanılarak yapılan ilk çalışmadır (LeCun ve ark., 1998). Donanımsal eksikliklerden dolayı bu ağ modelleri, teknolojik gelişmelerin de katkısıyla 2000’li yıllarda popüler bir alan haline gelmiştir (İnik ve Ülker, 2017). Igor Aizenberg tarafından 2000 yılında yapılan çalışmada, ilk kez ‘Derin Öğrenme’ kavramı kullanılmıştır (Gültekin, 2020). 2006 yılında ise ilk kez, ağın eğitimi için denetimsiz öğrenme sağlayan derin öğrenme modeli ‘Derin İnanç Ağı’ ortaya atılmıştır (Gültekin, 2020; Msonda, 2020). Derin öğrenme modellerinin ortaya çıkması ve gerekli donanımsal ihtiyaçların karşılanması ile bu alan günümüzde oldukça popüler hale gelmiştir.


Derin öğrenme, denetimli ya da denetimsiz olarak ifade edilen algoritmalarıyla özellik çıkarma, dönüştürme, sınıflandırma ve desen analizi için çoklu doğrusal olmayan katmanlar ile öğrenme işleminin gerçekleştirildiği bir alandır. Çoklu katman yapısında, her katman bir önceki katman çıktısını girdi olarak kullanmaktadır (Deng ve Yu, 2014). Bilgisayarların öğrenmesi fikrinin temelinde, insan beyninin öğrenme yapısı baz alınmıştır. İlham alınan insan beyni, Yapay Sinir Ağı (YSA) olarak adlandırılan yazılımsal yapıya dönüştürülmüştür. Derin kavramı, üst üste yığılı birçok katmandan oluşmasını ifade etmektedir (Sertkaya, 2018).

Derin öğrenmenin amacı, eldeki verilere uygulanan algoritmalar sonucunda verilere ait tüm özniteliklere hızlı ve yüksek doğrulukla sahip olmaktır. Yapay sinir ağlarının geliştirilmiş bir versiyonu olduğu için bu kavram zaman zaman ‘yeni nesil sinir ağları’ olarak da adlandırılmaktadır (Sertkaya, 2018). Derin öğrenmenin sunduğu en büyük avantaj, seçilen derin öğrenme modellerine göre verilerden anlam çıkarabilmesidir. Diğer avantajı, verilerin artmasıyla bu verilerden gerekli özelliklerin en kısa sürede, doğru bir şekilde ve daha az uzmanla elde edilmesidir (Cantemir, 2019). Derin öğrenme algoritmaları, çok katmanlı yapıda karmaşık veri işlemlerinde gizli

katmanlar kullanmaktadır. Birçok farklı mimari, derin öğrenme için kullanılmaktadır. ESA, RNN, Boltzman makinesi, LSTM, derin inanç ağları, derin oto kodlayıcılar, dikkat ağı ve kohonen ağı derin öğrenme mimarilerden en bilinenleridir.

3.4.1. Yapay sinir ağları

YSA, insan beyninin yapısından esinlenilerek öğrenme, hatırlama, verilerden anlamlar çıkarma, elde edilen bilgiyle ilgili tahminlerde bulunabilme ve kendi kendine öğrenebilme işlevlerinin gerçekleştirilmesi amacıyla geliştirilen bilgisayar yazılımlarıdır (Öztürk ve Şahin, 2018). Farklı tanımlarla ifade edilen YSA, biyolojik sinir sisteminin bilgisayar ortamında modellenmesinin taklit edildiği yapıdır. İnsan sinir sisteminin uzun yıllar araştırılmasından sonra, nörofizyolog Warren McCulloch ve matematikçi Walter Pitts tarafından 1943 yılında ilk YSA modeli oluşturulmuştur (Yıldırım, 2020). Şekil 3.7’de görüldüğü üzere, biyolojik sinir sisteminin nöron yapısında dentrit, çekirdek, akson, sinaps ve miyelin tabaka bulunmaktadır. Dentritler, giriş sinyallerinin alınarak aksonlara iletiildiği yerdir. Aksonlar çıkış sinyalinin üretildiği, iletimin tek yönlü olduğu bölümdür. Aksonlarla dentritlerin bağlantısına sinaps denir. Miyelin tabaka yayılım hızına etki ederken, çekirdek ise periyodik olarak akson boyunca darbe üretimini sağlamaktadır (Kızrak, 2018).




Şekil 3.7. Biyolojik sinir sistemi genel görünüşü (Anonim, 2019)

Biyolojik sistemdeki bu işleyişin YSA modellerindeki terminoloji karşılığı Çizelge 3.2’de verilmiştir.

Çizelge 3.2. Biyolojik sinir sistemi ile YSA arasındaki terminoloji (Tosun, 2007)

Sinir Sistemi	Yapay Sinir Ağı
Nöron	İşlem Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Eleman Çıkışı
Sinaps	Ağırlıklar

Şekil 3.8’de örnek bir YSA matematiksel modeli verilmiştir. YSA modelleri girdi, toplama fonksiyonu, aktivasyon fonksiyonu, ağırlıklar ve çıktı olmak üzere temel beş unsurdan oluşmaktadır.



Şekil 3.8. YSA matematiksel modeli

Girdi: Dışarıdan nöronlara gelen değerlerdir; kısaca veri kümesi olarak adlandırılmaktadır.




Ağırlıklar: Her bir girdinin nörona olan etkisi olarak ifade edilmektedir. Girdiler ağırlıklarla çarpılarak toplama fonksiyonuna iletilmektedir.

Toplama fonksiyonu: Girdilerin ağırlıklarla çarpılması sonucunda, elde edilen tüm değerleri toplayarak net girdiyi hesaplamaktadır. En yaygın kullanılan toplama fonksiyonu ağırlık toplamadır. Denklem 3.1’de ağırlıklı toplama işlemine ait fonksiyon verilmiştir. Çarpım, minimum, maksimum, çoğunluk ve kümülatif toplam diğer toplama fonksiyonlarından bazılarıdır (Şengöz, 2017).

$$Net = \sum_{i=1}^N x_i * w_i \quad (3.1)$$

Aktivasyon fonksiyonu: Toplama fonksiyonundan elde edilen sonucun, seçilen aktivasyon fonksiyonuna göre çıktı değerinin üretildiği kısımdır. Yapay sinir ağlarının özelliklerinden biri olan doğrusal olmama, bu fonksiyonlar aracılığıyla oluşmaktadır. Aktivasyon fonksiyonlarında, türevi kolay hesaplanan fonksiyonların seçilmesi, hesaplama işleminin hızı açısından önemlidir. Çok katmanlı YSA modelinde sigmoid, tanh ve RELU yaygın olarak kullanılmaktadır. RELU fonksiyonu, doğrusal problemlerde toplamı sabit bir katsayı ile çarpmayı sağlamaktadır. Sigmoid fonksiyonu her bir girdi değeri için (0 1) arasında bir çıktı değeri üretmektedir. Hiperbolik tanjant fonksiyonunda ise her bir girdi için çıkış değeri (-1 1) arasında değişmektedir. Bu fonksiyonlara ait grafik ve denklemler Çizelge 3.3'te verilmiştir.


Çizelge 3.3. Örnek aktivasyon fonksiyonları (Çayıroğlu, 2015).

Relu Fonksiyonu		$F(Net) = A * NET$ (A sabit bir sayı)
Sigmoid Fonksiyonu		$F(Net) = \frac{1}{1 + e^{-Net}}$
Hiperbolik Tanjant Fonksiyonu		$F(Net) = \frac{e^{Net} + e^{-Net}}{e^{Net} - e^{-Net}}$

Çıktı: Seçilen aktivasyon fonksiyonu sonucunda elde edilen değerdir.

YSA modelinde giriş katmanı, gizli katman ve çıkış katmanı olmak üzere 3 katman bulunmaktadır. Giriş katmanı, girdileri gizli katmana aktarma işlemini, gizli katman gelen bilgileri işleyerek çıkış katmanına gönderme işlemini yapmaktadır. Gizli katman sayısı, ağ modellerine göre değişmektedir. Nöron sayısı giriş ve çıkış katmanlarından bağımsızdır. Çıkış katmanında ise gizli katmandan gelen bilgiler çıkış olarak gönderilmektedir. Modelde birden fazla girdi verisinin her biri, ağırlıklar ile çarpılarak toplama fonksiyonuna aktarılmaktadır. Elde edilen bilgi, aktivasyon fonksiyonu ile işlenerek çıkışa iletildiğinde sonuç nöronun değerini vermektedir (Yıldırım, 2020).

YSA, yapılarına göre sınıflandırıldığında, ileri beslemeli ve geri beslemeli ağlar olarak ayrılmaktadır. İleri beslemeli ağlarda çıkış değeri, giriş katmanından çıkış katmanına doğru ilerleyerek tek yönlü olarak hesaplanmaktadır. Girdiler öncelikle giriş katmanına, daha sonra ara katmanlara ve en son çıkış katmanına aktarılmaktadır. İleri beslemeli ağlarda doğrusal olmayan, durağan bir işlev gerçekleştirilmektedir. Geri beslemeli ağlarda ise en az bir hücre çıkışı, kendisine veya diğer hücrelere giriş olarak verilmektedir. Geri beslemeli bir ağda, elde edilen çıktı değeri ile sistemin çıktı değeri karşılaştırılarak oluşan hata oranlarına bakılmaktadır. Bulunan hatanın geriye doğru yayılması ile giriş katmanına kadar iletilmektedir. İleri beslemeli ağlarda olduğu gibi tek yönlü değil çift yönlü olarak girişler aktarılabilir. Geri beslemeli ağlarda ,dinamik bellek özelliği bulunduğu için tahmin modellerinde sıklıkla kullanılmaktadır (Ölmez, 2020). Geri beslemeli ağ modelinde, çıktı hesaplama ve hata yayılım yönü Şekil 3.9'da gösterilmektedir.



Şekil 3.9. Geri beslemeli YSA modeli

YSA'ların girdilere göre çıktı üretebilmesi için ağların öğrenmesi gerekir. Denetimli, denetimsiz ve pekiştirmeli öğrenme olmak üzere üç öğrenme metodu bulunmaktadır.

Denetimli Öğrenme: Ağa, dışarıdan müdahalede bulunulan bir öğrenme yöntemidir. Bu yöntemde ağa girdi ve çıktı verileri verilmektedir. Ağdaki veriler etiketlenerek hangi çıktının elde edileceği önceden bilinmekte ve hata durumunda algoritma düzeltilebilmektedir. Çıktı değerine ulaşana kadar ağırlıklar sürekli güncellenmektedir. Hata değeri istenilen noktaya gelinceye kadar, öğrenme devam etmektedir. Denetimli öğrenme regresyon ve sınıflandırma olarak ikiye ayrılarak, tahmin ve sınıflandırma ihtiyaçlarında kullanılmaktadır. Çok katmanlı algılayıcı ağlarda, denetimli öğrenme metodu ile öğrenim gerçekleşmektedir.

Denetimsiz Öğrenme: Ağa dışarıdan hiçbir müdahale olmadan, etiketli olmayan girdiler ağa verilmektedir. Elde edilecek çıktı değeri önceden bilinmemektedir. Bu öğrenme yöntemiyle, ağ eldeki verileri kullanarak nasıl bir çıktı vermesi gerektiğini modellemektedir. Bu yöntem, ağın kendi kendine öğrenmesini sağlamaktadır. Kümeleme ve bağlantı olarak adlandırılan iki türe ayrılmaktadır. Günümüzde birçok problemin çözümünde bu öğrenme metodu kullanılmaktadır.

Pekiştirmeli Öğrenme: Ağa sadece girdiler verilerek ağdan çıktı oluşturmaya beklenmektedir. Pekiştirmeli öğrenme yönteminde ödül ceza ilişkisi bulunmaktadır. Ajan olarak tabir edilen unsur, ağın giriş durumunu inceleyerek karar verme işlemini gerçekleştirecek eylemi belirlemektedir. Bu işlem, politika olarak adlandırılmaktadır. Ajan, çevreden gerçekleştirilen eylem sonrasında bir skaler ödül ya da takviye almaktadır. Ajanların en yüksek ödül miktarına ulaşması için hangi eylemleri yapacağına karar vermesiyle öğrenme gerçekleşmektedir.

YSA'nın sahip olduğu temel özellikler doğrusal olmama, öğrenebilme, genelleme, paralel olması, hata toleransı, genelleme, uyarlanabilirlik, donanım ve hızdır (Tosun, 2007). YSA'lar günümüzde uzay, bankacılık, sağlık, finans, robotik, otomotiv başta olmak üzere hemen her alanda sıkça kullanılmaktadır.


3.4.2. Evrişimli sinir ağları

Evrişimli veya konvolüsyonel sinir ağları, bilgisayarda görme, dil, ses ve görüntü işleme gibi alanlarda günümüzde sıklıkla kullanılan derin öğrenme mimarisidir. ESA mimarisi, konvolüsyon katmanı, havuzlama katmanı ve tam bağlantılı katman olmak

üzere üç temel katmandan oluşan çok katmanlı bir yapıdır. Kullanılan katmanların sayısına, derinliğine ve türüne bağlı olarak mimarilerde farklılıklar oluşmaktadır.

ESA mimarisi, özellikle özniteliklerin çıkarılmasında etkili olduğu için sınıflandırma problemlerinin hızlı bir şekilde çözülmesine katkı sağlamaktadır. Mimarinin genel çalışması, nöronların 3 boyutlu (derinlik, yükseklik ve genişlik) olarak düzenlenmesiyle YSA'dan ayrılmaktadır. Giriş katmanındaki nöronların tümü, gizli katmanda bulunan nöronlara bağlanır. Bu bağlama şekli, YSA'lardan farklı olarak tüm nöronlara değil sadece belli bir bölgesine bağlanmaktadır.

Şekil 3.10'da görüldüğü üzere örnek bir ESA mimarisinde katmanların sayısına bağlı olarak, temelde öznitelik çıkarma ve sınıflandırma işleminin yapılmasıyla çıktı elde edilmektedir.




Şekil 3.10. ESA mimarisi örneği (Tuncer, 2018)

Giriş katmanından gelen veriler, bağlı olduğu gizli katmandaki bölgede konvolüsyon işlemi uygulanarak diğer katmana girdi olarak aktarılmaktadır. Öznitelik çıkarma işlemi, konvolüsyon katmanı ve havuzlama katmanı sayısına göre ağırlıkların paylaşılmasıyla, sınıflandırma işlemi yapılan son katmana kadar devam etmektedir. Konvolüsyon ve havuzlama katmanları, diğer katmanlardan gelen verileri bir düzleme aktarmakta ve sonraki katmanlara vermektedir. Öznitelik haritalarının boyutunun artması, girdiden elde edilen öznitelik sayısının artması anlamına gelmektedir. Tüm öznitelikler çıkarıldıktan sonra, sınıflandırma katmanında son sinir ağının ağırlık matrisi boyutuna göre girdi olarak alınmaktadır. Bu işlem, öğrenme açısından maliyetli olduğu için ortalama havuzlama gibi yöntemler kullanılmaktadır. Sınıfın skoru bir softmax fonksiyonu ile hesaplanmakta ve sınıflar en yüksek skora göre çıktı vermektedir (Temür, 2021).

- Konvolüsyon Katmanı (Convolution Layer):

Konvolüsyon katmanı adından da anlaşılacağı üzere, ESA mimarisinin yapı taşıdır. Girdi olarak ağa verilen görüntüler piksel değerlerine göre matrise aktarılmaktadır. Konvolüsyon katmanında, konvolüsyon filtre boyutu, adım aralığı (stride) ve doldurma (padding) olmak üzere 3 hiper parametre bulunmaktadır. Matrise dönüştürülmüş girdi görüntüsü üzerinde, adım sayısına bağlı olarak seçilen filtre gezdirilmektedir. Her bir filtre bir nöronu, filtre içindeki değerler nörona ait ağırlıkları ifade etmektedir. Filtre boyutu değişken olmakla beraber 3x3 ve 5x5 yaygın olarak kullanılmaktadır (Temür, 2021). Konvolüsyon filtreleri, görüntü ile aynı derinliğe sahip olmalıdır. Filtre değeri görüntü üzerinde denk gelen değerler ile çarpılarak toplanmaktadır. Adım ve doldurma sayılarına göre, filtre görüntü piksellerinde gezdirilmekte ve yeni bir çıktı elde edilmektedir. Bu yeni çıktı, özellik veya aktivasyon haritaları olarak ifade edilmektedir. Öznitelik haritaları filtre boyutuna, adım ve doldurma sayılarına göre belirlenmektedir. Konvolüsyon katmanında elde edilen çıktı, diğer katmana girdi olarak verilmektedir. Doldurma sayısı, kenar değerlerine ne kadar sıfır atılacağını ifade etmektedir (Kutlu, 2020). Adım sayısı arttıkça elde edilen öznitelik haritası küçülmektedir. Şekil 3.11’de kırmızı, yeşil ve mavi renk kanallarında konvolüsyon filtresinin uygulanma adımları verilmiştir.



Şekil 3.11. Konvolüsyon filtresinin uygulanması


- Aktivasyon Katmanı:

Aktivasyon fonksiyonlarının uygulandığı katmandır. Yaygın olarak kullanılan aktivasyon fonksiyonları RELU, sigmoid, tanh ve softmax'tir. Aktivasyon fonksiyonları, genel olarak konvolüsyon katmanından sonra kullanılmaktadır. Konvolüsyon katmanından elde edilen çıktılar, seçilen aktivasyon fonksiyonuyla belli bir değer aralığına dönüştürülmektedir. Matrislerde oluşan büyük rakamları küçülterek işlem kolaylığı sağlamaktadır. RELU uygulamasının basit olması ve eğitimi hızlandırmasından dolayı ESA'da en çok kullanılan aktivasyon fonksiyonudur. RELU fonksiyonunda, girişteki her bir nörona $f(x) = \max(0, x)$ şeklinde bir fonksiyon uygulamaktadır. Giriş değeri negatif bir değer veya 0 olduğunda çıkış olarak 0 değerini üretmektedir. Giriş değeri pozitif değer olduğunda ise değişkene bağlı olarak doğrusal bir çıktı elde edilmesini sağlamaktadır (Ölmez, 2020). Denklem 3.2'de RELU fonksiyonu çıkış değerleri denklemi verilmiştir.

$$RELU(x) = \max(x, 0) = \begin{cases} x, & \text{if } x \geq 0 \\ 0, & \text{if } x \leq 0 \end{cases} \quad (3.2)$$

- Havuzlama Katmanı:


Ortaklama katmanı olarak da tabir edilen bu katmanda amaç, konvolüsyon katmanında oluşan öznitelik haritalarının boyutunu azaltmaktır. Maksimum ve ortalama havuzlama katmanı en çok kullanılan yöntemdir. İmge üzerine yerleştirilen filtre içerisindeki en büyük değer alındığında maksimum havuzlama, filtre içerisindeki değerlerin ortalaması alındığında ise ortalama havuzlama yöntemi kullanılmaktadır. Şekil 3.12'de maksimum ve ortaklama havuzlama yöntemlerine ait örnek verilmiştir. Havuzlama katmanı, ağıdaki parametrelerin sayısının azalmasına ve işlem maliyetinin düşürülmesine katkıda bulunmaktadır (Msonda, 2020).



Şekil 3.12. Maksimum ve ortalama havuzlama işlemi

- Seyreltme (Dropout) Katmanı:


Genellikle seyreltme ya da eksiltme olarak ifade edilen, ağda aşırı öğrenmeyi engellemek için belirtilen sayıda bağlantının kaldırıldığı katmandır. Şekil 3.13a'da görüldüğü üzere, standart ESA ağına seyreltme işlemi uygulandıktan sonra, Şekil 3.13b'de bağlantı sayıları azalmıştır. Ağırlıkların bağlantılar aracılığıyla birbirine benzemeleri engellenmektedir.



Şekil 3.13. Dropout örnek görseli (a) Standart ESA yapısı, (b) Dropout uygulandıktan sonra ESA yapısı

- Tam Bağlantılı (Fully Connected / Flatten Layer) Katman:


Tam bağlantılı katman, ESA mimarisinde ağın sonunda bulunan, öznitelik haritalarını tek boyutlu vektöre dönüştürerek yapay sinir ağlarına ileten katmandır. YSA'larda olduğu gibi kendinden önceki katmanın tüm alanlarına tamamen bağlıdır. Giriş bir önceki katman tarafından belirlenirken, çıkış veri setindeki sınıf sayısı kadar olmaktadır. Tek boyutlu vektör, sınıflandırıcıya girdi olarak verilmekte ve sınıflandırma olasılıklarının elde edilmesini sağlamaktadır (Ölmez, 2020). Şekil 3.14'te öznitelik haritasına tam bağlantılı katman uygulanmasına ait örnek görsel verilmiştir.



Şekil 3.14. Öznitelik haritasına tam bağlantılı katman uygulanması

3.4.3. AlexNet

AlexNet ağı, 2012 yılında Alex Krizhevsky ve arkadaşları tarafından geliştirilen, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC-2012) başarı sağlayan bir ESA mimarisidir. Derin öğrenme, AlexNet ağı ile tekrar popüler hale gelmiştir. 1 milyondan fazla görüntü ve 1000 farklı sınıf bulunan ImageNet veri tabanı ile yapılan eğitimde, nesnelerin sınıflandırılmasında hata oranı %15,4'tür (İnik ve Ülker, 2017). Genetik algoritma ile yapılan sınıflandırmadaki doğruluk oranını %74,3'ten %83,6'ya yükselterek önemli bir başarı sağlamıştır (Kutlu, 2020). Şekil 3.15'te verilen AlexNet ağ modeli 5 konvolüsyon katmanı, havuzlama katmanı ve 3 tam bağlantılı katmandan oluşmaktadır.



Şekil 3.15. AlexNet ağ modeli (Raghav, 2018)


AlexNet modelinde, girdi verilerinin boyutu $227 \times 227 \times 3$ olmalıdır. İlk konvolüsyon katmanı 11×11 boyutunda 96 filtreden oluşmaktadır. Bir sonraki konvolüsyon katmanı filtre boyutu 5×5 , sonraki konvolüsyon katmanların filtre boyutu 3×3 olmaktadır. AlexNet modelinde aktivasyon fonksiyonu olarak RELU, havuzlama katmanlarında ise maksimum havuzlama yöntemi kullanılmaktadır. Evrişim ve havuzlama katmanlarının birbiri ardına gelmesiyle AlexNet, LeNet modeline oldukça benzemektedir.

3.4.4. GoogleNet

GoogleNet ağ modeli, Google ekibinden Christian Szegedy ve arkadaşları tarafından geliştirilmiştir. ImageNet veri kümesiyle eğitilerek ILSVRC-2014 yarışmasında %5,7 hata oranı ile yarışmanın kazananı olmuştur (İnik ve Ülker, 2017).

GoogleNet ağ modeli Inception V1 olarak da bilinmektedir (Msonda, 2020). Toplamda 22 katmandan oluştuğu için AlexNet'e göre çok daha derin bir mimariye sahiptir. Giriş görüntü boyutu $224 \times 224 \times 3$ olarak verilmekte ve RELU aktivasyon fonksiyonu kullanılmaktadır.


Hesaplama gücünün artırılması için Şekil 3.16'da gösterilen başlangıç modülünün (inception module) son konsepti kullanılmıştır. İlk ve son başlangıç konsepti arasında 1×1 konvolüsyon katmanı eklenmesi fark oluşturmuştur. Ardışık mimari yerine paralel olarak birbirine bağlanan konvolüsyon ve havuzlama katmanından oluşmaktadır. Paralel mimari yapısı, modelin performansının artmasını sağlayarak hesaplama maliyetlerini düşürmektedir.



Şekil 3.16. GoogleNet başlangıç modülü

GoogleNet mimarisi, Şekil 3.17'de görüldüğü üzere çıkış bölümünden önce tam bağlantılı katman kullanmamaktadır. Başlangıç modüllerindeki iki dallanma sınıflandırmada yardımcı olan çıkışlardır (Can, 2019). Başlangıç modülleri, veri miktarını ve katman sayısını artırarak performansı yükseltmektedir.


GoogleNet mimarisi, Şekil 3.17’de gösterilmiştir.



Şekil 3.17. GoogleNet mimarisi

3.4.5. ShuffleNet

ShuffleNet mimarisi, minimal mimarilerin performans gereksinimlerine uygun olarak, özellik kanallarında bilgi akışına yardımcı olmak amacıyla, yeni bir kanal karıştırma işlemi gerçekleştirilerek oluşturulmuştur. Hesaplama maliyetinin azaltılmasına ve daha geniş özellik harita kanalları ile daha fazla bilginin kodlanmasına katkı sağlamaktadır. Noktasal grup evrişimi (Gconv) ve kanal karıştırma işlevine sahip olan ShuffleNet birimi, 1×1 evrişimlerin hesaplama karmaşıklığını azaltmak için geliştirilmiştir (Rezaee ve ark., 2021). ShuffleNet mimarisi, ImageNet veri tabanı ile sınıflandırılması ve MS COCO ile nesne tespiti değerlendirmeleri sonucunda diğer ağlara göre daha yüksek bir performans göstermiştir. MobileNet ağının ImageNet veri tabanı kullanılarak yapılan sınıflandırma karşılaştırılmasında, ShuffleNet mimarisine göre %7,8 daha düşük bir performans elde edilmiştir (Zhang ve ark., 2018). Şekil 3.18a’da aynı sayıda grupta evrişim katmanı, Şekil 3.18b’de farklı grup evrişimlerinin çaprazlanması ve Şekil 3.18c’de kanal karıştırma işlemine ait görsel verilmiştir.




Şekil 3.18. Grup evrişimi ile kanal karıştırma (a) Aynı sayıda grupta iki yığın evrişim katmanı (b) Gconv1 ve Gconv2 grup evrişiminin farklı yığınlarla çapraz bağlanması (c) b uygulamasına benzer kanal karıştırma

3.4.6. SqueezeNet

2016 yılında Iandola ve arkadaşları tarafından tanıtılan, SqueezeNet modelinde Şekil 3.19’da gösterildiği gibi konvolüsyon katmanı, sekiz ateşleme modülü ve son konvolüsyon katmanı olmak üzere 10 adet katman bulunmaktadır (Diker, 2020).

seti üzerinde işlem yapılacağı zaman kullanılmak üzere diğer ağa aktarılmasıdır. Transfer öğrenme kavramı, derin öğrenmenin dezavantajlarını avantaja çevirmektedir. Büyük verilerle işlem yapılan ağlarda, yüksek kapasiteli donanım ihtiyacı maliyeti artırmakta ve hızı düşürmektedir. Yeterli büyüklükte veri olmadığı durumlarda kullanılması da transfer öğrenmenin diğer avantajıdır. Transfer öğrenmenin model doğruluğunu artırdığı, daha az veri ile kısa zamanda yüksek doğruluk sağladığı kanıtlanmıştır (Ghosh, 2020).

Transfer öğrenme, önceden eğitilmiş ESA mimarisinin katmanlarının yeni ağa transfer edilerek eğitilmesi işlemidir. Transfer öğrenmede genellikle, yaklaşık 15 milyon görüntü ve 1000 farklı kategori bulunan ImageNet veri seti ile eğitimler yapılmaktadır. ImageNet veri kümesi, belli aralıklarla güncellenmesi ve kolay erişilebilir olması sebebi ile tercih edilmektedir. Transfer öğrenme yapılırken, katmanların yeni ağ modeline aktarılmasında ‘fine - tuning’ olarak ifade edilen ince ayarlamaların yapılması gerekmektedir. Genelde ilk katmanlar sabit olurken son katmanlar ise yeni modelde eğitim için ayrılmaktadır (Gültekin, 2020). Şekil 3.21’de transfer öğrenmede kullanılan genel model gösterilmiştir.



Şekil 3.21. Transfer öğrenme modeli

Transfer öğrenmede neyin aktarılması gerektiği, ne zaman aktarılacağı ve nasıl aktarılacağı ile ilgili 3 temel konu bulunmaktadır. Hedef ve kaynak görevleri, verilerin özelliğine göre 3 sınıfta gruplandırılır. Bunlar:

- Tümevarımsal Transfer Öğrenme: Görevlerdeki verinin etiketli olup olmama durumuna göre iki farklı yaklaşım bulunur. İlk durumda, hedef

görevde az da olsa etiketli veri varken, kaynak görevde etiketli verinin olup olmaması önemli değildir. Kendi kendine öğrenme mantığı ile çalışmaktadır. Kaynakta çok fazla etiketli verinin bulunması durumunda, çok yönlü öğrenme ile çalışması diğer bir yaklaşımdır. Etiketli veri kullanımı, sadece kaynak için değil hedef görevdeki verilerin de yüksek performans sağlaması amacıyla kullanılmaktadır (Yiğit ve Yeğin, 2020).

- Dönüştürücü Transfer Öğrenme: Kaynak görevde çok miktarda etiketli veri bulunurken, hedef görevde etiketli veri bulunmamaktadır. Hedef görevde etiketsiz verinin, etiketli veri yardımıyla kullanılabilir bilgiye dönüşmesi sağlanmaktadır (Koçer, 2012).
- Denetimsiz Transfer Öğrenme: Kaynak ve hedef görevde etiketli verinin olmadığı durumdur. Kaynak ve hedef veri kümelerinin benzer, görevlerinin farklı olduğu bu transfer öğrenme planlaması, boyut küçültme ve kümeleme gibi yöntemlerde kullanılmaktadır.

Transfer öğrenmenin temel konularından biri de neyin transfer edileceği ile ilgili yaklaşımlardır.

- Örnek Transferi: Kaynak verisindeki bazı örneklerin ağırlık değerlerinin hedef veride kullanılmasıdır. Kaynak verisi, hedef verisi ile ortak özelliklere sahip olduğu zaman geçerli olmaktadır.
- Parametre Transferi: Benzer kaynak ve hedef görevlerinde birbirine yakın parametrelerin kullanılması durumudur. Parametreler ile bilgi transferinin kaynaktan hedef göreve aktarılmasıdır.
- Özellik Temsil Transferi: Hedef ve kaynak görevde kullanılacak verilerin, ortak özellik temsillerine sahip olması durumunda, bilgi transferinin gerçekleştirilmesidir (Yiğit ve Yeğin, 2020).
- İlişkisel Bilgi Transferi: Kaynak ve hedef veri arasında ilişkisel bilgi eşleştirilmesinin yapıldığı durumdur.

3.5.1. Transfer öğrenmede kullanılan hiper parametreler

Derin öğrenme mimarisinde, ihtiyaca göre ayarlanması gereken bazı parametreler bulunmaktadır. Bu parametreler eğitilecek veri türüne, miktarına ve eğitimin yapılacağı mimariye göre değişiklik göstermektedir. Kullanılan bu parametreler, üst değişken seçimi

anlamına gelen hiper parametreler olarak da adlandırılmaktadır. Derin öğrenme mimarilerinde, hiper parametreler her probleme göre değişiklik göstermektedir. Hiper parametre seçimi, tüm sonuçları etkileyebilecek bir öneme sahiptir. Günümüzde kullanılan hiper parametreler, gelişim aşamasında olduğu için gelecekte daha popüler bir alan olması mümkündür (Çarkacı, 2018). Eğitim aşamasında sık kullanılan hiper parametreler ise şu şekildedir:

Optimizasyon Algoritması: Optimizasyon, sistemin en düşük hata oranı vermesi için kullanılması gereken ağırlık değeridir (Can, 2019). Derin öğrenme mimarilerinde, optimizasyon problemi öğrenmenin temelini oluşturmaktadır. Momentumlu Rastgele Eğim Düşümü olarak ifade edilen Stochastic Gradient Descent with Momentum (SGDM), Root Mean Squared Propagation (RMSProp) ve Adam en sık kullanılan optimizasyon algoritmalarıdır. SGD'de ağırlıklar, rastgele eğimlerle güncellenmektedir. SGD optimizasyon algoritmasında oluşan salınımları azaltmak için momentumlu eğimler kullanılarak SGDM algoritması oluşturulmuştur. Momentumlu eğimler hedefe gitme hızını artırmaktadır.

Öğrenme Katsayısı: Eğim düşümü algoritmalarında, performansı belirleyen hiper parametredir. Ağdaki parametrenin güncellenme hızını belirlemektedir.

Momentum Katsayısı: Maliyet fonksiyonunun küçültülmesinde, rastgele eğim düşümünün minimal değere ulaşmasını kolaylaştırmak amacıyla kullanılmaktadır. Salınının azalmasıyla minimal değere ulaşım hızlanmaktadır. Varsayılan momentum katsayısı, 0.9 olarak belirlenmiştir.

Mini Batch (Mini Paket) Boyutu: İleri ve geri yayılımda, ağı kullanacağı veri miktarıdır. Mini batch boyutu, ikinin katları şeklinde artmakta ve arttıkça hafıza ihtiyacı oluşmaktadır.

Epoch Sayısı: Eğitim sırasında, veri setinin bir ileri bir geri yönde ağa verilmesidir. Veriler, ağa parça parça verilerek model başarımı test edilmekte ve ağırlık güncellemesi yapılmaktadır (Kurt, 2018).

İterasyon: Mini batch boyutu kadar verinin, ileri ve geri yönde ağdan geçirilmesidir.

Düzenleştirme (Regularization): Ağ eğitiminde aşırı öğrenmenin engellenmesi için oluşturulan parametredir. L1 ve L2 düzenleştirme yöntemleri sıkça kullanılmaktadır. L1 yönteminde parametrelerin mutlak değerlerinin toplamını azaltmak için L2 yönteminde ise karelerinin toplamını azaltmak için fonksiyona ekleme yapılmaktadır.

Tez çalışmasında, eğitimin gerçekleştirildiği derin öğrenme ağ modellerinde SGDM optimizasyon algoritması kullanılmıştır. Bu optimizasyon algoritmasında kullanılan diğer özellikler Çizelge 3.4’te gösterilmiştir. Aynı eğitim parametreleri ağ performansını değerlendirmek için tercih edilmiştir.

Çizelge Hata! Belgede belirtilen stilde metne rastlanmadı..4. Tüm denemelerde seçilen eğitim parametreleri

Parametre Adı	Değer
Momentum	0.9
InitialLearnRate	1.0000e-04
L2Regularization	1.0000e-04
MaxEpochs	15
MiniBatchSize	32
VerboseFrequency	true
ValidationFrequency	50
Shuffle	every-epoch
ExecutionEnvironment	gpu
BatchNormalizationStatistic	population

- Ayrıntılı Frekans (Verbose Frequency): Varsayılan olarak 50 değerini alan, komut ekranına yazdırma sıklığını ifade eden parametredir. Verbose değeri ‘true’ olarak seçildiğinde etkili olmaktadır.
- Doğrulama Frekansı (Validation Frequency): Ağın doğruluğunu, yineleme sıklığını ifade eder.
- Shuffle: Seçilen değer ile her eğitimden önce verilerin karıştırılmasını belirlemektedir.
- Çalıştırma Ortamı (Execution Environment): Eğitimin hangi donanım ünitesinde gerçekleşeceğini belirlediği parametredir. Denemelerde GPU seçilmiştir.
- Toplu Normalleştirme İstatistiği (Batch Normalization Statistic): Eğitim parametresi olarak ‘population’ seçildiğinde, eğitim verileri ile eğitimden elde edilen ortalama ve varyans değerlerini gözden geçirerek sonlandırmaktadır.

3.6. Performans Değerlendirme Ölçütleri

Tez çalışmasında, BRATS 2019 veri setindeki görüntüler PNG formatına dönüştürülmüştür. Çalışmanın daha kapsamlı olması için 3 farklı sınıf çıkışlı

sınıflandırma yapılmıştır. 3 sınıf çıkışlı sınıflandırmada, tüm modaliteler HGG, LGG ve normal olarak sınıflandırılmıştır. 4 sınıf çıkışlı sınıflandırmada HGG, LGG ve normal görüntüler kendi içerisinde FLAIR, T1, T1CE ve T2 modalitelerine göre sınıflandırılmıştır. 12 sınıf çıkışlı sınıflandırmada ise HGG, LGG ve normal MR görüntüleri FLAIR, T1, T1CE ve T2 modaliteleri ile aynı anda sisteme verilmiştir. 3, 4 ve 12 sınıf çıkışlı denemeler AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve InceptionV3 ağ modelleriyle gerçekleştirilmiştir. Literatür detaylı incelenerek, performans kriterleri ile gerçekleştirilen 40 farklı denemenin değerlendirmesi yapılmıştır. Görüntü sayısı yeterli olduğu için çalışmalarda herhangi bir veri çoğaltma işlemi yapılmamıştır.

Tüm eğitimler Intel Core i7-10750H, GPU 2.6 GHZ, 16 GB RAM, NVIDIA GeForce RTX 3060 6GB GDDR6 özelliklerine sahip donanımla MATLAB R2021a programı aracılığıyla gerçekleştirilmiştir. Eğitim sırasında, ağ modellerinin tümünde aynı parametreler kullanılarak ağ performanslarının karşılaştırılması yapılmıştır.

- K – Katlamalı Çapraz Doğrulama

K–katlamalı çapraz doğrulama yönteminde, veri kümesinin eğitim ve test seti olarak ayrılması eğitimin performansını etkilemektedir. Eğitimlerde öncelikle bir k değeri seçilmesi gerekmektedir. Veri seti, seçilen k değeri kadar parçalara bölünmekte ve k değeri kadar döngü işlemi yapılmaktadır. Her döngüde oluşturulan parçaların biri test verisi olarak ayrılırken, diğerleri eğitim verisi olarak belirlenmektedir. Tez çalışmasında, k değeri 5 olarak belirlenmiş ve veri setindeki görüntüler %80 eğitim, %20 test verisi olarak ayrılmıştır. Çizelge 3.5’te, 5 kat çapraz doğrulamada kullanılan veri kümesi dağılımı verilmiştir. Eğitimler sonucunda elde edilen performans değerlerinin ortalaması alınmıştır.

Çizelge Hata! Belgede belirtilen stilde metne rastlanmadı..5. 5 kat çapraz doğrulama tablosu

	Eğitim Verisi				Test Verisi
	1. Veri Kümesi	2. Veri Kümesi	3. Veri Kümesi	4. Veri Kümesi	5. Veri Kümesi
1. Döngü	Test	Eğitim	Eğitim	Eğitim	Eğitim
2. Döngü	Eğitim	Test	Eğitim	Eğitim	Eğitim
3. Döngü	Eğitim	Eğitim	Test	Eğitim	Eğitim
4. Döngü	Eğitim	Eğitim	Eğitim	Test	Eğitim
5. Döngü	Eğitim	Eğitim	Eğitim	Eğitim	Test

Çapraz doğrulama yöntemiyle eğitim ve test verilerinin performans sonuçları, karmaşıklık matrisi (confusion matrix) olarak ifade edilen matrise aktarılmaktadır. Bu matris, sınıflandırma problemlerinde performans ölçümü sağlamaktadır. Gerçek ve tahmin edilen değerlerle ilgili kombinasyonlar içermektedir. 2 sınıflı bir eğitim modelinin karmaşıklık matrisi örneği Çizelge 3.6’da verilmiştir.

Çizelge Hata! Belgede belirtilen stilde metne rastlanmadı..6. 2 sınıflı karmaşıklık matrisi

		TAHMİN		TOPLAM
		P ⁺	P ⁻	
GERÇEK	P ⁺	TP True Positive	FN False Negative	N ⁺ Gerçek Pozitif
	P ⁻	FP False Positive	TN True Negative	N ⁻ Gerçek Pozitif
TOPLAM		N ⁺ Tahmin Pozitif	N ⁻ Gerçek Pozitif	N Toplam Sınıf

Modelin performansını değerlendirmek için karmaşıklık matrisinde TP, FP, FN ve TN olarak ifade edilen değerler elde edilmelidir.

- True Positive (TP) – Doğru Pozitif (DP): Gerçek sınıfı pozitif olan verilerin, modelde tahmin ettiği sınıfın da pozitif olmasıdır. TP değerleri, doğru olarak sınıflandırılmış verileri gösterir.
- False Positive (FP) – Yanlış Pozitif (YP): Gerçekte negatif olan verilerin, modelde pozitif olarak tahmin edilen değeridir.
- False Negative (FN) – Yanlış Negatif (YN): Gerçekte pozitif olan verilerin, negatif olarak sınıflandırılmasıdır.
- True Negative (TN) – Doğru Negatif (DN): Gerçekte negatif olan verilerin, negatif olarak sınıflandırılma sayısıdır.

Karmaşıklık matrisinde elde edilen TP, FP, FN ve TN değerleri, performans değerlendirme kriteri olarak ifade edilen doğruluk (accuracy), duyarlılık (sensitivity), kesinlik (precision), özgüllük (specificity) ve F1 puanı (score) değerlerinin hesaplanmasını sağlamaktadır.

Doğruluk (Accuracy): Modelin başarısını gösteren bu değer, doğru olarak sınıflandırılan veri sayısının toplam veri sayısına bölünmesidir. Kısacası doğru olarak sınıflandırılan verilerin yüzdesini vermektedir. Model değerlendirme kriterlerinde en çok kullanılan yöntemdir. Denklem 3.3'te toplam görüntü sayısı denklemi, Denklem 3.4'te ise doğruluk değeri hesaplama denklemi verilmiştir.

$$\text{Toplam Görüntü Sayısı} = TP + FP + TN + FN \quad (3.3)$$

$$\text{Doğruluk} = \frac{TP + TN}{\text{Toplam Görüntü Sayısı}} \quad (3.4)$$

Duyarlılık (Sensitivity) : Gerçekte pozitif olan ve sınıflandırıcı tarafından pozitif sınıflandırılan verilerin, gerçekte pozitif olan tüm verilere oranıdır. Gerçek Pozitif Oran, True Positive Rate (TPR) ya da Geri Çağırma (Recall) olarak da ifade edilmektedir. Denklem 3.5'te duyarlılık değeri hesaplama denklemi verilmiştir.

$$\text{Duyarlılık (Recall / TPR)} = \frac{TP}{TP + FN} \quad (3.5)$$

Kesinlik (Presicion): Gerçekte pozitif olup pozitif olarak sınıflandırılan verilerin, pozitif olarak sınıflandırılan tüm verilere oranıdır. Denklem 3.6'da kesinlik denklemi verilmiştir.

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

Özgüllük (Specificity): Gerçekte negatif olup negatif olarak sınıflandırılan verilerin, gerçekte negatif olan toplam veri sayısına oranıdır. Denklem 3.7'de özgüllük değeri hesaplaması verilmiştir.

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (3.7)$$

F1 Score (Skoru / Puanı): Kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Model değerlendirilmesinde iki ölçüt kullanılması yerine bir ölçüt

üzerinden değerlendirme yapılmasını sağlamaktadır. Denklem 3.8’de F1 puanı denklemi verilmiştir.

$$F1\text{puanı} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.8)$$

2 sınıf çıkışlı sınıflandırmada, karmaşıklık matrisinin performans kriterlerinin denklemleri yukarıda verilmiştir. Tez çalışmasında çok sınıflı çıkışlar ile denemeler yapılmaktadır. Bu sebeple karmaşıklık matrisi Çizelge 3.7’de gösterildiği şekilde düzenlenerek performans değerlendirme kriterleri hesaplanmıştır.

Çizelge Hata! Belgede belirtilen stilde metne rastlanmadı..7. Çok sınıflı karmaşıklık matrisi

		TAHMİN					TOPLAM
		P ₁	P ₂	P ₃	...	P _n	
GERÇEK	P ₁	T ₁	F ₁₂	F ₁₃	...	F _{1n}	N ₁
	P ₂	F ₂₁	T ₂	F ₂₃	...	F _{2n}	N ₂
	P ₃	F ₃₁	F ₃₂	T ₃	...	F _{3n}	N ₃
	...	...	...	...	...	...	...
	P _n	F _{n1}	F _{n2}	F _{n3}	...	T _n	N _n
TOPLAM		N ₁	N ₂	N ₃	...	N _n	N Toplam Veri

Tez çalışmasında, sınıflandırma problemlerinde önemli diğer performans ölçütleri olan ROC eğrisi ve AUC değeri de kullanılmıştır. ROC eğrisi, olasılıkları ifade eden bir eğridir. Eğrinin X ekseninde, Yanlış Pozitif Oran olarak adlandırılan False Positive Rate (FPR), Y ekseninde ise daha önce bahsedilen TPR yani duyarlılık değeri bulunmaktadır. Eğri altındaki alanın artması, sınıflandırmada performans artışı anlamına gelmektedir.

Denklem 3.9’da FPR değerin bulunması için gerekli denklem verilmiştir.

$$FPR = 1 - \text{Özgüllük} = \frac{FP}{FP + TN} \quad (3.9)$$

AUC değeri, modelin sınıfları ayırt etmesinin bir ölçüsüdür. Bu değer 0 ile 1 arasında değişmektedir. AUC değerinin 1 olması modelin sınıfları %100 doğrulukla sınıflandırdığını göstermektedir. Tez çalışmasında, çok sınıflı sınıflandırma modellerinde elde edilen ROC grafiği araştırma sonuçları başlığı altında verilmiştir.

3.6.1. 3 sınıf çıkışlı performans kriterleri

T1, T1CE, T2 ve FLAIR modalitelerinin her biri içerisinde bulunan HGG, LGG ve normal veriler sınıflandırılmıştır. Bütün modalitelere, ayrı ayrı 3 sınıf çıkışlı sınıflandırma yapılmıştır. HGG, LGG ve normal olarak ayrılan verilerin hepsinde, aynı modaliteye ait aynı kesitlerin olduğu 1000 adet görüntü mevcuttur. Her modalitenin HGG, LGG ve normal görüntülerinin sınıflandırılma performansları, derin öğrenme modelleriyle test edilmiştir.

Çizelge Hata! Belgede belirtilen stilde metne rastlanmadı..8. 3 sınıf çıkışlı karmaşıklık matrisi

		TAHMİN		
		HGG	LGG	NORMAL
GERÇEK	HGG	T _{HH}	F _{HL}	F _{HN}
	LGG	F _{LH}	T _{LL}	F _{LN}
	NORMAL	F _{NH}	F _{NL}	T _{NN}

Çizelge 3.8’de verilen 3 sınıf çıkışlı sınıflandırma karmaşıklık matrisi elemanlarının anlamları:

T_{HH}: Doğru sınıflandırılan HGG görüntü sayısı

T_{LL}: Doğru sınıflandırılan LGG görüntü sayısı

T_{NN}: Doğru sınıflandırılan normal beyin görüntü sayısı

F_{HL} : HGG görüntüsü iken, LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{HN} : HGG görüntüsü iken, normal olarak yanlış sınıflandırılan görüntü sayısı

F_{LH} : LGG görüntüsü iken, HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{LN} : LGG görüntüsü iken, normal olarak yanlış sınıflandırılan görüntü sayısı

F_{NH} : Normal beyin görüntüsü iken, HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{NL} : Normal beyin görüntüsü iken, LGG olarak yanlış sınıflandırılan görüntü sayısı

Karmaşıklık matrisinde anlatılan performans ölçütleri, her bir sınıf için elde edilmiştir. Performans ölçütlerinin tüm döngüler sonrası ortalamaları alınmıştır.

Denklem 3.10 – 3.12 sırasıyla HGG, LGG ve normal görüntü sınıfının gerçek pozitif değerleridir.

3 sınıfa ait TP değerleri:

$$TP_{HGG} = T_{HH} \quad (3.10)$$

$$TP_{LGG} = T_{LL} \quad (3.11)$$

$$TP_{NORMAL} = T_{NN} \quad (3.12)$$

Denklem 3.11 – 3.15 sırasıyla HGG, LGG ve normal görüntü sınıfının yanlış pozitif değerleridir.

3 sınıfa ait FP değerleri:

$$FP_{HGG} = F_{LH} + F_{NH} \quad (3.13)$$

$$FP_{LGG} = F_{HL} + F_{NL} \quad (3.14)$$

$$FP_{NORMAL} = F_{HN} + F_{LN} \quad (3.15)$$

Denklem 3.16 – 3.18 sırasıyla HGG, LGG ve normal görüntü sınıfının yanlış negatif değerleridir.

3 sınıfa ait FN değerleri:

$$FN_{HGG} = F_{HL} + F_{HN} \quad (3.16)$$

$$FN_{LGG} = F_{LH} + F_{LN} \quad (3.17)$$

$$FN_{NORMAL} = F_{NH} + F_{NL} \quad (3.18)$$

Denklem 3.19 – 3.21 sırasıyla HGG, LGG ve normal görüntü sınıfının doğru negatif değerleridir.

3 sınıfa ait TN değerleri:

$$TN_{HGG} = T_{LL} + F_{LN} + F_{NL} + T_{NN} \quad (3.19)$$

$$TN_{LGG} = T_{HH} + F_{HN} + F_{NH} + T_{NN} \quad (3.20)$$

$$TN_{NORMAL} = T_{HH} + F_{HL} + F_{LH} + T_{LL} \quad (3.21)$$

Karmaşıklık matrisinde değerlerin elde edilmesiyle, 3 sınıf çıkışlı performans değerlendirme kriterlerinin hesaplanma formülleri verilmiştir. Doğruluk değeri, her sınıfa ait TP değerlerinin, tüm görüntü sayısına bölümüyle elde edilir. Denklem 3.22 – 3.24 doğruluk değerinin elde edilme adımlarını vermektedir.

$$TP = T_{HH} + T_{LL} + T_{NN} \quad (3.22)$$

$$\text{Toplam Görüntü Sayısı} = T_{HH} + F_{HL} + F_{HN} + F_{LH} + T_{LL} + F_{LN} + F_{NH} + F_{NL} + T_{NN} \quad (3.23)$$

$$\text{Doğruluk} = \frac{TP}{\text{Toplam Görüntü Sayısı}} \quad (3.24)$$

Kesinlik değerinin hesaplanması HGG, LGG ve normal sınıflarda TP değerlerinin TP ve FP değerlerinin toplamına bölünmesiyle elde edilir (Denklem 3.25 – 3.27).

$$Kesinlik_{HGG} = \frac{TP_{HGG}}{TP_{HGG} + FP_{HGG}} \quad (3.25)$$

$$Kesinlik_{LGG} = \frac{TP_{LGG}}{TP_{LGG} + FP_{LGG}} \quad (3.26)$$

$$Kesinlik_{NORMAL} = \frac{TP_{NORMAL}}{TP_{NORMAL} + FP_{NORMAL}} \quad (3.27)$$

Ortalama kesinlik denklemi, her sınıfa ait kesinlik değerleri toplamının sınıf sayısına bölünmesi ile elde edilmiş ve Denklem 3.28’de gösterilmiştir.

$$\text{Ortalama Kesinlik} = \frac{Kesinlik_{HGG} + Kesinlik_{LGG} + Kesinlik_{NORMAL}}{3} \quad (3.28)$$

Duyarlılık değerin hesaplanması HGG, LGG ve normal sınıflarda TP değerlerinin TP ve FN değerlerinin toplamına bölünmesiyle elde edilir (Denklem 3.29 – 3.31).

$$Duyarlılık_{HGG} = \frac{TP_{HGG}}{TP_{HGG} + FN_{HGG}} \quad (3.29)$$

$$Duyarlılık_{LGG} = \frac{TP_{LGG}}{TP_{LGG} + FN_{LGG}} \quad (3.30)$$

$$Duyarlılık_{NORMAL} = \frac{TP_{NORMAL}}{TP_{NORMAL} + FN_{NORMAL}} \quad (3.31)$$

3 sınıfa ait ortalama duyarlılık denklemi, her sınıfa ait duyarlılık değerleri toplamının sınıf sayısına bölünmesi ile elde edilmektedir (Denklem 3.32)

$$Ortalama Duyarlılık = \frac{Duyarlılık_{HGG} + Duyarlılık_{LGG} + Duyarlılık_{NORMAL}}{3} \quad (3.32)$$

ROC eğrisinin elde edilmesi için gerekli olan FPR değerlerinin bulunmasında HGG, LGG ve normal sınıflara ait Denklem (3.33 – 3.35)'te verilmiştir.

$$FPR_{HGG} = \frac{FP_{HGG}}{FP_{HGG} + TN_{HGG}} \quad (3.33)$$

$$FPR_{LGG} = \frac{FP_{LGG}}{FP_{LGG} + TN_{LGG}} \quad (3.34)$$

$$FPR_{NORMAL} = \frac{FP_{NORMAL}}{FP_{NORMAL} + TN_{NORMAL}} \quad (3.35)$$

Özgüllük değeri, HGG, LGG ve normal sınıflarda TN değerlerinin, TN ve FP değerlerinin toplamına bölünmesiyle elde edilir (Denklem 3.36 – 3.38).

$$Özgüllük_{HGG} = \frac{TN_{HGG}}{TN_{HGG} + FP_{HGG}} \quad (3.36)$$

$$Özgüllük_{LGG} = \frac{TN_{LGG}}{TN_{LGG} + FP_{LGG}} \quad (3.37)$$

$$\text{Özgüllük}_{NORMAL} = \frac{TN_{NORMAL}}{TN_{NORMAL} + FP_{NORMAL}} \quad (3.38)$$

3 sınıfa ait ortalama özgüllük denklemi, her sınıfa ait özgüllük değerleri toplamının sınıf sayısına bölünmesi sonucu elde edilmiş ve Denklem 3.39’da verilmiştir.

$$\text{Ortalama Özgüllük} = \frac{\text{Özgüllük}_{HGG} + \text{Özgüllük}_{LGG} + \text{Özgüllük}_{NORMAL}}{3} \quad (3.39)$$

Sınıflandırma problemlerinde, performans ölçüt kriterlerinden biri de F1 puanıdır. Denklem 3.40’ta örnek olarak HGG sınıfı F1 puanı hesaplama denklemi verilmiştir. LGG ve normal sınıfların F1 puanı hesaplaması da bu denkleme kesinlik ve duyarlılık değerlerinin yerleştirilmesiyle bulunmaktadır.

$$F1\text{puanı}_{HGG} = 2 * \frac{\text{Kesinlik}_{HGG} * \text{Duyarlılık}_{HGG}}{\text{Kesinlik}_{HGG} + \text{Duyarlılık}_{HGG}} \quad (3.40)$$

3 sınıfa ait ortalama F1 puanı, Denklem 3.41’de ortalama kesinlik ve duyarlılık değerleri yerleştirildiğinde elde edilmektedir. 3, 4 ve 12 sınıf çıkışlı sınıflandırmada ortalama F1 puanı aynı formül ile bulunmaktadır.

$$\text{Ortalama F1puanı} = 2 * \frac{\text{Ortalama Kesinlik} * \text{Ortalama Duyarlılık}}{\text{Ortalama Kesinlik} + \text{Ortalama Duyarlılık}} \quad (3.41)$$

3.6.2. 4 sınıf çıkışlı performans kriterleri

HGG, LGG ve normal görüntüler, modalitelerine göre FLAIR, T1, T1CE ve T2 olarak sınıflandırılmıştır. Çizelge 3.9’da 4 sınıf çıkışlı sınıflandırmaya ait karmaşıklık matrisi verilmiştir.

Çizelge Hata! Belgede belirtilen stilde metne rastlanmadı..9. 4 sınıf çıkışlı karmaşıklık matrisi

		TAHMİN			
		FLAIR	T1	T1CE	T2
GERÇEK	FLAIR	T_{FF}	F_{FT1}	F_{FC}	F_{FT2}
	T1	F_{T1F}	T_{T1T1}	F_{T1C}	F_{T1T2}
	T1CE	F_{CF}	F_{CT1}	T_{CC}	F_{CT2}
	T2	F_{T2F}	F_{T2T1}	F_{T2C}	T_{T2T2}

Çizelge 3.9’da verilen, 4 sınıf çıkışlı sınıflandırma karmaşıklık matrisi elemanlarının anlamları:

T_{FF} : Doğru sınıflandırılan FLAIR görüntü sayısı

T_{T1T1} : Doğru sınıflandırılan T1 görüntü sayısı

T_{CC} : Doğru sınıflandırılan T1CE görüntü sayısı

T_{T2T2} : Doğru sınıflandırılan T2 görüntü sayısı

F_{FT1} : FLAIR görüntüsü iken, T1 olarak yanlış sınıflandırılan görüntü sayısı

F_{FC} : FLAIR görüntüsü iken, T1CE olarak yanlış sınıflandırılan görüntü sayısı

F_{FT2} : FLAIR görüntüsü iken, T2 olarak yanlış sınıflandırılan görüntü sayısı

F_{T1F} : T1 görüntüsü iken, FLAIR olarak yanlış sınıflandırılan görüntü sayısı

F_{T1C} : T1 görüntüsü iken, T1CE olarak yanlış sınıflandırılan görüntü sayısı

F_{T1T2} : T1 görüntüsü iken, T2 olarak yanlış sınıflandırılan görüntü sayısı

F_{CF} : T1CE görüntüsü iken, FLAIR olarak yanlış sınıflandırılan görüntü sayısı

F_{CT1} : T1CE görüntüsü iken, T1 olarak yanlış sınıflandırılan görüntü sayısı

F_{CT2} : T1CE görüntüsü iken, T2 olarak yanlış sınıflandırılan görüntü sayısı

F_{T2F} : T2 görüntüsü iken, FLAIR olarak yanlış sınıflandırılan görüntü sayısı

F_{T2C} : T2 görüntüsü iken, T1CE olarak yanlış sınıflandırılan görüntü sayısı

F_{T2T1} : T2 görüntüsü iken, T1 olarak yanlış sınıflandırılan görüntü sayısı

Karmaşıklık matrisinde gerekli olan TP, FN, FP ve TN değer hesaplamaları yapılmıştır. HGG, LGG ve normal sınıfta, modalite değerleri ayrı ayrı hesaplanmıştır. 4 sınıf çıkışlı sınıflandırmada, doğru pozitif değerleri Denklem (3.42 – 3.45), yanlış pozitif değerleri Denklem (3.46 – 3.49)’da gösterilmiştir. Yanlış negatif değerleri Denklem (3.50 – 3.53), doğru negatif değerleri Denklem (3.54 – 3.57)’de verilmiştir.

4 sınıfa ait TP değerleri:

$$TP_{FLAIR} = T_{FF} \quad (3.42)$$

$$TP_{T1} = T_{T1T1} \quad (3.43)$$

$$TP_{T1CE} = T_{CC} \quad (3.44)$$

$$TP_{T2} = T_{T2T2} \quad (3.45)$$

4 sınıfa ait FP değerleri:

$$FP_{FLAIR} = F_{T1F} + F_{CF} + F_{T2F} \quad (3.46)$$

$$FP_{T1} = F_{FT1} + F_{CT1} + F_{T2T1} \quad (3.47)$$

$$FP_{T1CE} = F_{FC} + F_{T1C} + F_{T2C} \quad (3.48)$$

$$FP_{T2} = F_{FT2} + F_{CT2} + F_{T1T2} \quad (3.49)$$

4 sınıfa ait FN değerleri:

$$FN_{FLAIR} = F_{FT1} + F_{FC} + F_{FT2} \quad (3.50)$$

$$FN_{T1} = F_{T1F} + F_{T1C} + F_{T1T2} \quad (3.51)$$

$$FN_{T1CE} = F_{CF} + F_{CT1} + F_{CT2} \quad (3.52)$$

$$FN_{T2} = F_{T2F} + F_{T2T1} + F_{T2C} \quad (3.53)$$

4 sınıfa ait TN değerleri:

$$TN_{FLAIR} = T_{T1T1} + F_{T1C} + F_{T1T2} + F_{CT1} + T_{CC} + F_{CT2} + F_{T2T1} + F_{T2C} + T_{T2T2} \quad (3.54)$$

$$TN_{T1} = T_{FF} + F_{FC} + F_{FT2} + F_{CF} + T_{CC} + F_{CT2} + F_{T2F} + F_{T2C} + T_{T2T2} \quad (3.55)$$

$$TN_{T1CE} = T_{FF} + F_{FT1} + F_{FT2} + F_{T1F} + T_{T1T1} + F_{T1T2} + F_{T2F} + F_{T2T1} + T_{T2T2} \quad (3.56)$$

$$TN_{T2} = T_{FF} + F_{FT1} + F_{FC} + F_{T1F} + T_{T1T1} + F_{T1C} + F_{CF} + F_{CT1} + T_{CC} \quad (3.57)$$

Karmaşıklık matrisinde değerlerin elde edilmesiyle, 4 sınıf çıkışlı performans değerlendirme kriterlerinin hesaplama formülleri verilmiştir. Tüm doğru pozitif toplamaları Denklem 3.58’de, matristeki tüm eleman sayısı Denklem 3.59’da verilmiştir. 4 sınıf çıkışlı sınıflandırma doğruluğu ise Denklem 3.60’da elde edilmiştir.

$$TP = T_{FF} + T_{TIT1} + T_{CC} + T_{T2T2} \quad (3.58)$$

$$\text{Toplam Görüntü Sayısı: } T_{FF} + F_{FT1} + F_{FC} + F_{FT2} + F_{TIF} + T_{TIT1} + F_{TIC} + F_{TIT2} + F_{CF} + F_{CT1} + T_{CC} + F_{CT2} + F_{T2F} + F_{T2T1} + F_{T2C} + T_{T2T2} \quad (3.59)$$

$$\text{Doğruluk} = \frac{TP}{\text{Toplam Görüntü Sayısı}} \quad (3.60)$$

Kesinlik değeri, her çıkışın kendi TP değerinin, TP ve FP değerlerinin toplamına bölünmesiyle bulunmaktadır (Denklem 3.61 – 3.64).

$$\text{Kesinlik}_{FLAIR} = \frac{TP_{FLAIR}}{TP_{FLAIR} + FP_{FLAIR}} \quad (3.61)$$

$$\text{Kesinlik}_{T1} = \frac{TP_{T1}}{TP_{T1} + FP_{T1}} \quad (3.62)$$

$$\text{Kesinlik}_{T1CE} = \frac{TP_{T1CE}}{TP_{T1CE} + FP_{T1CE}} \quad (3.63)$$

$$\text{Kesinlik}_{T2} = \frac{TP_{T2}}{TP_{T2} + FP_{T2}} \quad (3.64)$$

4 sınıfa ait ortalama kesinlik değeri, her sınıfa ait kesinlik değerlerinin toplamının sınıf sayısına bölünmesi ile elde edilmiştir (Denklem 3.65).

$$\text{Ortalama Kesinlik} = \frac{\text{Kesinlik}_{FLAIR} + \text{Kesinlik}_{T1} + \text{Kesinlik}_{T1CE} + \text{Kesinlik}_{T2}}{4} \quad (3.65)$$

Duyarlılık değeri, her çıkışın kendi TP değerinin TP ve FN değerlerinin toplamına bölünmesiyle bulunmaktadır (Denklem 3.66 – 3.69).

$$\text{Duyarlılık}_{FLAIR} = \frac{TP_{FLAIR}}{TP_{FLAIR} + FN_{FLAIR}} \quad (3.66)$$

$$Duyarlilik_{T_1} = \frac{TP_{T_1}}{TP_{T_1} + FN_{T_1}} \quad (3.67)$$

$$Duyarlilik_{T_{1CE}} = \frac{TP_{T_{1CE}}}{TP_{T_{1CE}} + FN_{T_{1CE}}} \quad (3.68)$$

$$Duyarlilik_{T_2} = \frac{TP_{T_2}}{TP_{T_2} + FN_{T_2}} \quad (3.69)$$

4 sınıfa ait ortalama duyarlılık değeri, her sınıfa ait duyarlılık değerlerinin toplamının sınıf sayısına bölünmesi ile elde edilmektedir (Denklem 3.70).

$$Ortalama\ Duyarlilik = \frac{Duyarlilik_{FLAIR} + Duyarlilik_{T_1} + Duyarlilik_{T_{1CE}} + Kesinlik_{T_2}}{4} \quad (3.70)$$

Özgüllük denklemi, TN değerlerinin TN ve FP değerlerinin toplamına bölünmesi ile elde edilmektedir (Denklem 3.71 – 3.74).

$$Özgüllük_{FLAIR} = \frac{TN_{FLAIR}}{TN_{FLAIR} + FP_{FLAIR}} \quad (3.71)$$

$$Özgüllük_{T_1} = \frac{TN_{T_1}}{TN_{T_1} + FP_{T_1}} \quad (3.72)$$

$$Özgüllük_{T_{1CE}} = \frac{TN_{T_{1CE}}}{TN_{T_{1CE}} + FP_{T_{1CE}}} \quad (3.73)$$

$$Özgüllük_{T_2} = \frac{TN_{T_2}}{TN_{T_2} + FP_{T_2}} \quad (3.74)$$

4 sınıfa ait ortalama özgüllük değeri, her sınıfa ait özgüllük değerlerinin toplamının sınıf sayısına bölünmesi ile elde edilmiştir (Denklem 3.75).

$$Ortalama\ Özgüllük = \frac{Özgüllük_{FLAIR} + Özgüllük_{T_1} + Özgüllük_{T_{1CE}} + Özgüllük_{T_2}}{4} \quad (3.75)$$

Sınıflandırma problemlerinde, performans değerlendirme kriterlerinden F1 puanı (Denklem 3.76 – 3.79), her sınıfta ait kesinlik ve duyarlılık değerleri denkleme

yerleştirildiğinde elde edilmektedir. Ortalama F1 puanı ise her sınıfa ait F1 puanları toplamının sınıf sayısına bölünmesiyle elde edilir.

$$F1puanı_{FLAIR} = 2 * \frac{Kesinlik_{FLAIR} * Duyarlılık_{FLAIR}}{Kesinlik_{FLAIR} + Duyarlılık_{FLAIR}} \quad (3.76)$$

$$F1puanı_{T1} = 2 * \frac{Kesinlik_{T1} * Duyarlılık_{T1}}{Kesinlik_{T1} + Duyarlılık_{T1}} \quad (3.77)$$

$$F1puanı_{T1CE} = 2 * \frac{Kesinlik_{T1CE} * Duyarlılık_{T1CE}}{Kesinlik_{T1CE} + Duyarlılık_{T1CE}} \quad (3.78)$$

$$F1puanı_{T2} = 2 * \frac{Kesinlik_{T2} * Duyarlılık_{T2}}{Kesinlik_{T2} + Duyarlılık_{T2}} \quad (3.79)$$

3.6.3. 12 sınıf çıkışlı performans kriterleri

Dört modalite ve üç tümör dereceli görüntüler, aynı anda sisteme verilerek 12 sınıf çıkışlı sınıflandırma yapılmıştır. FLAIR, T1, T1CE, T2, modalitelerin her birinde HGG, LGG ve normal şeklinde üç sınıf bulunmaktadır. Bu sınıflandırma ile aynı anda modalitelere ve MR görüntü derecelerine göre tümör sınıflandırması yapılmıştır.

Çizelge 3.10'da 12 sınıf çıkışlı karmaşıklık matrisi gösterilmiştir. Karmaşıklık matrisinde, eleman isimlendirmesi satır ve sütun (satır, sütun) numaralarına göre yapılmıştır.

Çizelge Hata! Belgede belirtilen stilde metne rastlanmadı..10. 12 sınıf çıkışlı karmaşıklık matrisi

		TAHMİN											
		Flair _{HGG}	Flair _{LGG}	Flair _{NORMAL}	T1 _{HGG}	T1 _{LGG}	T1 _{NORMAL}	T1CE _{HGG}	T1CE _{LGG}	T1CE _{NORMAL}	T2 _{HGG}	T2 _{LGG}	T2 _{NORMAL}
GERÇEK	Flair _{HGG}	T _{1,1}	F _{1,2}	F _{1,3}	F _{1,4}	F _{1,5}	F _{1,6}	F _{1,7}	F _{1,8}	F _{1,9}	F _{1,10}	F _{1,11}	F _{1,12}
	Flair _{LGG}	F _{2,1}	T _{2,2}	F _{2,3}	F _{2,4}	F _{2,5}	F _{2,6}	F _{2,7}	F _{2,8}	F _{2,9}	F _{2,10}	F _{2,11}	F _{2,12}
	Flair _{NORMAL}	F _{3,1}	F _{3,2}	T _{3,3}	F _{3,4}	F _{3,5}	F _{3,6}	F _{3,7}	F _{3,8}	F _{3,9}	F _{3,10}	F _{3,11}	F _{3,12}
	T1 _{HGG}	F _{4,1}	F _{4,2}	F _{4,3}	T _{4,4}	F _{4,5}	F _{4,6}	F _{4,7}	F _{4,8}	F _{4,9}	F _{4,10}	F _{4,11}	F _{4,12}
	T1 _{LGG}	F _{5,1}	F _{5,2}	F _{5,3}	F _{5,4}	T _{5,5}	F _{5,6}	F _{5,7}	F _{5,8}	F _{5,9}	F _{5,10}	F _{5,11}	F _{5,12}
	T1 _{NORMAL}	F _{6,1}	F _{6,2}	F _{6,3}	F _{6,4}	F _{6,5}	T _{6,6}	F _{6,7}	F _{6,8}	F _{6,9}	F _{6,10}	F _{6,11}	F _{6,12}
	T1CE _{HGG}	F _{7,1}	F _{7,2}	F _{7,3}	F _{7,4}	F _{7,5}	F _{7,6}	T _{7,7}	F _{7,8}	F _{7,9}	F _{7,10}	F _{7,11}	F _{7,12}
	T1CE _{LGG}	F _{8,1}	F _{8,2}	F _{8,3}	F _{8,4}	F _{8,5}	F _{8,6}	F _{8,7}	T _{8,8}	F _{8,9}	F _{8,10}	F _{8,11}	F _{8,12}
	T1CE _{NORMAL}	F _{9,1}	F _{9,2}	F _{9,3}	F _{9,4}	F _{9,5}	F _{9,6}	F _{9,7}	F _{9,8}	T _{9,9}	F _{9,10}	F _{9,11}	F _{9,12}
	T2 _{HGG}	F _{10,1}	F _{10,2}	F _{10,3}	F _{10,4}	F _{10,5}	F _{10,6}	F _{10,7}	F _{10,8}	F _{10,9}	T _{10,10}	F _{10,11}	F _{10,12}
	T2 _{LGG}	F _{11,1}	F _{11,2}	F _{11,3}	F _{11,4}	F _{11,5}	F _{11,6}	F _{11,7}	F _{11,8}	F _{11,9}	F _{11,10}	T _{11,11}	F _{11,12}
	T2 _{NORMAL}	F _{12,1}	F _{12,2}	F _{12,3}	F _{12,4}	F _{12,5}	F _{12,6}	F _{12,7}	F _{12,8}	F _{12,9}	F _{12,10}	F _{12,11}	T _{12,12}

Çizelge 3.10'da verilen 12 sınıf çıkışlı sınıflandırma karmaşıklık matrisi elemanlarının anlamları

T_{1,1}: Doğru sınıflandırılan FLAIR modalitesi, HGG görüntü sayısı

T_{2,2}: Doğru sınıflandırılan FLAIR modalitesi, LGG görüntü sayısı

T_{3,3}: Doğru sınıflandırılan FLAIR modalitesi, normal beyin görüntü sayısı

T_{4,4}: Doğru sınıflandırılan T1 modalitesi, HGG görüntü sayısı

T_{5,5}: Doğru sınıflandırılan T1 modalitesi, LGG görüntü sayısı

T_{6,6}: Doğru sınıflandırılan T1 modalitesi, normal beyin görüntü sayısı

T_{7,7}: Doğru sınıflandırılan T1CE modalitesi, HGG görüntü sayısı

T_{8,8}: Doğru sınıflandırılan T1CE modalitesi, LGG görüntü sayısı

T_{9,9}: Doğru sınıflandırılan T1CE modalitesi, normal beyin görüntü sayısı

T_{10,10}: Doğru sınıflandırılan T2 modalitesi, HGG görüntü sayısı

T_{11,11}: Doğru sınıflandırılan T2 modalitesi, LGG görüntü sayısı

T_{12,12}: Doğru sınıflandırılan T2 modalitesi, normal beyin görüntü sayısı

F_{1,2}: FLAIR modalitesinde HGG görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{1,3}: FLAIR modalitesinde HGG görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{1,4}: FLAIR modalitesinde HGG görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{1,5}: FLAIR modalitesinde HGG görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{1,6}: FLAIR modalitesinde HGG görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{1,7}: FLAIR modalitesinde HGG görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{1,8}: FLAIR modalitesinde HGG görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{1,9}: FLAIR modalitesinde HGG görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{1,10}: FLAIR modalitesinde HGG görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{1,11}: FLAIR modalitesinde HGG görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{1,12}: FLAIR modalitesinde HGG görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{2,1}: FLAIR modalitesinde LGG görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{2,3}: FLAIR modalitesinde LGG görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{2,4}: FLAIR modalitesinde LGG görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{2,5}: FLAIR modalitesinde LGG görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{2,6}: FLAIR modalitesinde LGG görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{2,7}: FLAIR modalitesinde LGG görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{2,8}: FLAIR modalitesinde LGG görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{2,9}: FLAIR modalitesinde LGG görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{2,10}: FLAIR modalitesinde LGG görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{2,11}: FLAIR modalitesinde LGG görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{2,12}: FLAIR modalitesinde LGG görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{3,1}: FLAIR modalitesinde normal beyin görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{3,2}: FLAIR modalitesinde normal beyin görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{3,4}: FLAIR modalitesinde normal beyin görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{3,5}: FLAIR modalitesinde normal beyin görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{3,6}: FLAIR modalitesinde normal beyin görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{3,7}: FLAIR modalitesinde normal beyin görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{3,8}: FLAIR modalitesinde normal beyin görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{3,9}: FLAIR modalitesinde normal beyin görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{3,10}: FLAIR modalitesinde normal beyin görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{3,11}: FLAIR modalitesinde normal beyin görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{3,12}: FLAIR modalitesinde normal beyin görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{4,1}: T1 modalitesinde HGG görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{4,2}: T1 modalitesinde HGG görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{4,3}: T1 modalitesinde HGG görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{4,5}: T1 modalitesinde HGG görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{4,6}: T1 modalitesinde HGG görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{4,7}: T1 modalitesinde HGG görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{4,8}: T1 modalitesinde HGG görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{4,9}: T1 modalitesinde HGG görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{4,10}: T1 modalitesinde HGG görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{4,11}: T1 modalitesinde HGG görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{4,12}: T1 modalitesinde HGG görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{5,1}: T1 modalitesinde LGG görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{5,2}: T1 modalitesinde LGG görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{5,3}: T1 modalitesinde LGG görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{5,4}: T1 modalitesinde LGG görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{5,6}: T1 modalitesinde LGG görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{5,7}: T1 modalitesinde LGG görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{5,8}: T1 modalitesinde LGG görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{5,9}: T1 modalitesinde LGG görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{5,10}: T1 modalitesinde LGG görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{5,11}: T1 modalitesinde LGG görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{5,12}: T1 modalitesinde LGG görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{6,1}: T1 modalitesinde normal görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{6,2}: T1 modalitesinde normal görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{6,3}: T1 modalitesinde normal görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{6,4}: T1 modalitesinde normal görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{6,5}: T1 modalitesinde normal görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{6,7}: T1 modalitesinde normal görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{6,8}: T1 modalitesinde normal görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{6,9}: T1 modalitesinde normal görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{6,10}: T1 modalitesinde normal görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{6,11}: T1 modalitesinde normal görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{6,12}: T1 modalitesinde normal görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{7,1}: T1CE modalitesinde HGG görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{7,2}: T1CE modalitesinde HGG görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{7,3}: T1CE modalitesinde HGG görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{7,4}: T1CE modalitesinde HGG görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{7,5}: T1CE modalitesinde HGG görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{7,6}: T1CE modalitesinde HGG görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{7,8}: T1CE modalitesinde HGG görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{7,9}: T1CE modalitesinde HGG görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{7,10}: T1CE modalitesinde HGG görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{7,11}: T1CE modalitesinde HGG görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{7,12}: T1CE modalitesinde HGG görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{8,1}: T1CE modalitesinde LGG görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{8,2}: T1CE modalitesinde LGG görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{8,3}: T1CE modalitesinde LGG görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{8,4}: T1CE modalitesinde LGG görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{8,5}: T1CE modalitesinde LGG görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{8,6}: T1CE modalitesinde LGG görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{8,7}: T1CE modalitesinde LGG görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{8,9}: T1CE modalitesinde LGG görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{8,10}: T1CE modalitesinde LGG görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{8,11}: T1CE modalitesinde LGG görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{8,12}: T1CE modalitesinde LGG görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{9,1}: T1CE modalitesinde normal görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{9,2}: T1CE modalitesinde normal görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{9,3}: T1CE modalitesinde normal görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{9,4}: T1CE modalitesinde normal görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{9,5}: T1CE modalitesinde normal görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{9,6}: T1CE modalitesinde normal görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{9,7}: T1CE modalitesinde normal görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{9,8}: T1CE modalitesinde normal görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{9,10}: T1CE modalitesinde normal görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{9,11}: T1CE modalitesinde normal görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{9,12}: T1CE modalitesinde normal görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{10,1}: T2 modalitesinde HGG görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{10,2}: T2 modalitesinde HGG görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{10,3}: T2 modalitesinde HGG görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{10,4}: T2 modalitesinde HGG görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{10,5}: T2 modalitesinde HGG görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{10,6}: T2 modalitesinde HGG görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{10,7}: T2 modalitesinde HGG görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{10,8}: T2 modalitesinde HGG görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{10,9}: T2 modalitesinde HGG görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{10,11}: T2 modalitesinde HGG görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{10,12}: T2 modalitesinde HGG görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{11,1}: T2 modalitesinde LGG görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{11,2}: T2 modalitesinde LGG görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{11,3}: T2 modalitesinde LGG görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{11,4}: T2 modalitesinde LGG görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{11,5}: T2 modalitesinde LGG görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{11,6}: T2 modalitesinde LGG görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

F_{11,7}: T2 modalitesinde LGG görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

F_{11,8}: T2 modalitesinde LGG görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

F_{11,9}: T2 modalitesinde LGG görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

$F_{11,10}$: T2 modalitesinde LGG görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

$F_{11,12}$: T2 modalitesinde LGG görüntüsü iken, T2 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,1}$: T2 modalitesinde normal görüntüsü iken, FLAIR modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,2}$: T2 modalitesinde normal görüntüsü iken, FLAIR modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,3}$: T2 modalitesinde normal görüntüsü iken, FLAIR modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,4}$: T2 modalitesinde normal görüntüsü iken, T1 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,5}$: T2 modalitesinde normal görüntüsü iken, T1 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,6}$: T2 modalitesinde normal görüntüsü iken, T1 modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,7}$: T2 modalitesinde normal görüntüsü iken, T1CE modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,8}$: T2 modalitesinde normal görüntüsü iken, T1CE modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,9}$: T2 modalitesinde normal görüntüsü iken, T1CE modalitesinde normal olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,10}$: T2 modalitesinde normal görüntüsü iken, T2 modalitesinde HGG olarak yanlış sınıflandırılan görüntü sayısı

$F_{12,11}$: T2 modalitesinde normal görüntüsü iken, T2 modalitesinde LGG olarak yanlış sınıflandırılan görüntü sayısı

Karmaşıklık matrisinde gerekli olan TP, FN, FP ve TN değerleri hesaplamaları yapılmıştır. HGG, LGG ve normal sınıfta, bu değerler ayrı ayrı hesaplanmıştır. 12 sınıf çıkışlı sınıflandırmada, doğru pozitif değerleri Denklem (3.80 – 3.91)'de ve yanlış pozitif değerleri Denklem (3.92 – 3.103)'te verilmiştir. Yanlış negatif değerleri Denklem (3.104 – 3.115), doğru negatif değerleri Denklem (3.116 – 3.127)'de gösterilmiştir.

12 sınıfa ait TP değerleri:

$$TP_{FLAIRHGG} = T_{1,1} \quad (3.80)$$

$$TP_{FLAIRLGG} = T_{2,2} \quad (3.81)$$

$$TP_{FLAIRNORMAL} = T_{3,3} \quad (3.82)$$

$$TP_{TIHGG} = T_{4,4} \quad (3.83)$$

$$TP_{TILGG} = T_{5,5} \quad (3.84)$$

$$TP_{TINORMAL} = T_{6,6} \quad (3.85)$$

$$TP_{TICEHGG} = T_{7,7} \quad (3.86)$$

$$TP_{TICELGG} = T_{8,8} \quad (3.87)$$

$$TP_{TICENORMAL} = T_{9,9} \quad (3.88)$$

$$TP_{T2HGG} = T_{10,10} \quad (3.89)$$

$$TP_{T2LGG} = T_{11,11} \quad (3.90)$$

$$TP_{T2NORMAL} = T_{12,12} \quad (3.91)$$

12 sınıfa ait FP değerleri:

$$FP_{FLAIRHGG} = F_{2,1} + F_{3,1} + F_{4,1} + F_{5,1} + F_{6,1} + F_{7,1} + F_{8,1} + F_{9,1} + F_{10,1} + F_{11,1} + F_{12,1} \quad (3.92)$$

$$FP_{FLAIRLGG} = F_{1,2} + F_{3,2} + F_{4,2} + F_{5,2} + F_{6,2} + F_{7,2} + F_{8,2} + F_{9,2} + F_{10,2} + F_{11,2} + F_{12,2} \quad (3.93)$$

$$FP_{FLAIRNORMAL} = F_{1,3} + F_{2,3} + F_{4,3} + F_{5,3} + F_{6,3} + F_{7,3} + F_{8,3} + F_{9,3} + F_{10,3} + F_{11,3} + F_{12,3} \quad (3.94)$$

$$FP_{TIHGG} = F_{1,4} + F_{2,4} + F_{3,4} + F_{5,4} + F_{6,4} + F_{7,4} + F_{8,4} + F_{9,4} + F_{10,4} + F_{11,4} + F_{12,4} \quad (3.95)$$

$$FP_{TILGG} = F_{1,5} + F_{2,5} + F_{3,5} + F_{4,5} + F_{6,5} + F_{7,5} + F_{8,5} + F_{9,5} + F_{10,5} + F_{11,5} + F_{12,5} \quad (3.96)$$

$$FP_{TINORMAL} = F_{1,6} + F_{2,6} + F_{3,6} + F_{4,6} + F_{5,6} + F_{7,6} + F_{8,6} + F_{9,6} + F_{10,6} + F_{11,6} + F_{12,6} \quad (3.97)$$

$$FP_{TICEHGG} = F_{1,7} + F_{2,7} + F_{3,7} + F_{4,7} + F_{5,7} + F_{6,7} + F_{8,7} + F_{9,7} + F_{10,7} + F_{11,7} + F_{12,7} \quad (3.98)$$

$$FP_{TICELGG} = F_{1,8} + F_{2,8} + F_{3,8} + F_{4,8} + F_{5,8} + F_{6,8} + F_{7,8} + F_{9,8} + F_{10,8} + F_{11,8} + F_{12,8} \quad (3.99)$$

$$FP_{TICENORMAL} = F_{1,9} + F_{2,9} + F_{3,9} + F_{4,9} + F_{5,9} + F_{6,9} + F_{7,9} + F_{8,9} + F_{10,9} + F_{11,9} + F_{12,9} \quad (3.100)$$

$$FP_{T2HGG} = F_{1,10} + F_{2,10} + F_{3,10} + F_{4,10} + F_{5,10} + F_{6,10} + F_{7,10} + F_{8,10} + F_{9,10} + F_{11,10} + F_{12,10} \quad (3.101)$$

$$FP_{T2LGG} = F_{1,11} + F_{2,11} + F_{3,11} + F_{4,11} + F_{5,11} + F_{6,11} + F_{7,11} + F_{8,11} + F_{9,11} + F_{10,11} + F_{12,11} \quad (3.102)$$

$$FP_{T2NORMAL} = F_{1,12} + F_{2,12} + F_{3,12} + F_{4,12} + F_{5,12} + F_{6,12} + F_{7,12} + F_{8,12} + F_{9,12} + F_{10,12} + F_{11,12} \quad (3.103)$$

12 sınıfa ait FN değerleri:

$$FN_{FLAIRHGG} = F_{1,2} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,11} + F_{1,12} \quad (3.104)$$

$$FN_{FLAIRLGG} = F_{2,1} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,11} + F_{2,12} \quad (3.105)$$

$$FN_{FLAIRNORMAL} = F_{3,1} + F_{3,2} + F_{3,4} + F_{3,5} + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,11} + F_{3,12} \quad (3.106)$$

$$FN_{TIHGG} = F_{4,1} + F_{4,2} + F_{4,3} + F_{4,5} + F_{4,6} + F_{4,7} + F_{4,8} + F_{4,9} + F_{4,10} + F_{4,11} + F_{4,12} \quad (3.107)$$

$$FN_{TILGG} = F_{5,1} + F_{5,2} + F_{5,3} + F_{5,4} + F_{5,6} + F_{5,7} + F_{5,8} + F_{5,9} + F_{5,10} + F_{5,11} + F_{5,12} \quad (3.108)$$

$$FN_{TINORMAL} = F_{6,1} + F_{6,2} + F_{6,3} + F_{6,4} + F_{6,5} + F_{6,7} + F_{6,8} + F_{6,9} + F_{6,10} + F_{6,11} + F_{6,12} \quad (3.109)$$

$$FN_{TICEHGG} = F_{7,1} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,5} + F_{7,6} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,11} + F_{7,12} \quad (3.110)$$

$$FN_{TICELGG} = F_{8,1} + F_{8,2} + F_{8,3} + F_{8,4} + F_{8,5} + F_{8,6} + F_{8,7} + F_{8,9} + F_{8,10} + F_{8,11} + F_{8,12} \quad (3.111)$$

$$FN_{T1CENORMAL} = F_{9,1} + F_{9,2} + F_{9,3} + F_{9,4} + F_{9,5} + F_{9,6} + F_{9,7} + F_{9,8} + F_{9,10} + F_{9,11} + F_{9,12} \quad (3.112)$$

$$FN_{T2HGG} = F_{10,1} + F_{10,2} + F_{10,3} + F_{10,4} + F_{10,5} + F_{10,6} + F_{10,7} + F_{10,8} + F_{10,9} + F_{10,11} + F_{10,12} \quad (3.113)$$

$$FN_{T2LGG} = F_{11,1} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,5} + F_{11,6} + F_{11,7} + F_{11,8} + F_{11,9} + F_{11,10} + F_{11,12} \quad (3.114)$$

$$FN_{T2NORMAL} = F_{12,1} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,6} + F_{12,7} + F_{12,8} + F_{12,9} + F_{12,10} + F_{12,11} \quad (3.115)$$

12 sınıfa ait TN değerleri

$$\begin{aligned} TN_{FLAIRHGG} = & T_{2,2} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,11} + F_{2,12} + F_{3,2} \\ & + T_{3,3} + F_{3,4} + F_{3,5} + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,11} + F_{3,12} + F_{4,2} + F_{4,3} + T_{4,4} + \\ & F_{4,5} + F_{4,6} + F_{4,7} + F_{4,8} + F_{4,9} + F_{4,10} + F_{4,11} + F_{4,12} + F_{5,2} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,6} + F_{5,7} \\ & + F_{5,8} + F_{5,9} + F_{5,10} + F_{5,11} + F_{5,12} + F_{6,2} + F_{6,3} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,9} + \\ & F_{6,10} + F_{6,11} + F_{6,12} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,11} + \\ & F_{7,12} + F_{8,2} + F_{8,3} + F_{8,4} + F_{8,5} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,11} + F_{8,12} + F_{9,2} + F_{9,3} \\ & + F_{9,4} + F_{9,5} + F_{9,6} + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,11} + F_{9,12} + F_{10,2} + F_{10,3} + F_{10,4} + F_{10,5} \\ & + F_{10,6} + F_{10,7} + F_{10,8} + F_{10,9} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,5} + F_{11,6} \\ & + F_{11,7} + F_{11,8} + F_{11,9} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,6} + F_{12,7} \\ & + F_{12,8} + F_{12,9} + F_{12,10} + F_{12,11} + T_{12,12} \end{aligned} \quad (3.116)$$

$$\begin{aligned} TN_{FLAIRLGG} = & T_{1,1} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,11} + F_{1,12} + F_{3,1} \\ & + T_{3,3} + F_{3,4} + F_{3,5} + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,11} + F_{3,12} + F_{4,1} + F_{4,3} + T_{4,4} + \\ & F_{4,5} + F_{4,6} + F_{4,7} + F_{4,8} + F_{4,9} + F_{4,10} + F_{4,11} + F_{4,12} + F_{5,1} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,6} + F_{5,7} \\ & + F_{5,8} + F_{5,9} + F_{5,10} + F_{5,11} + F_{5,12} + F_{6,1} + F_{6,3} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,9} + \\ & F_{6,10} + F_{6,11} + F_{6,12} + F_{7,1} + F_{7,3} + F_{7,4} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,11} + \\ & F_{7,12} + F_{8,1} + F_{8,3} + F_{8,4} + F_{8,5} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,11} + F_{8,12} + F_{9,1} + F_{9,3} \\ & + F_{9,4} + F_{9,5} + F_{9,6} + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,11} + F_{9,12} + F_{10,1} + F_{10,3} + F_{10,4} + F_{10,5} \\ & + F_{10,6} + F_{10,7} + F_{10,8} + F_{10,9} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,1} + F_{11,3} + F_{11,4} + F_{11,5} + F_{11,6} \\ & + F_{11,7} + F_{11,8} + F_{11,9} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,6} + F_{12,7} \\ & + F_{12,8} + F_{12,9} + F_{12,10} + F_{12,11} + T_{12,12} \end{aligned} \quad (3.117)$$

$$\begin{aligned} TN_{FLAIRNORMAL} = & T_{1,1} + F_{1,2} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,11} + F_{1,12} + \\ & F_{2,1} + T_{2,2} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,11} + F_{2,12} + F_{4,1} + F_{4,2} + T_{4,4} \\ & + F_{4,5} + F_{4,6} + F_{4,7} + F_{4,8} + F_{4,9} + F_{4,10} + F_{4,11} + F_{4,12} + F_{5,1} + F_{5,2} + F_{5,4} + T_{5,5} + F_{5,6} + \\ & F_{5,7} + F_{5,8} + F_{5,9} + F_{5,10} + F_{5,11} + F_{5,12} + F_{6,1} + F_{6,2} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,9} \\ & + F_{6,10} + F_{6,11} + F_{6,12} + F_{7,1} + F_{7,2} + F_{7,4} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,11} + \\ & F_{7,12} + F_{8,1} + F_{8,2} + F_{8,4} + F_{8,5} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,11} + F_{8,12} + F_{9,1} + F_{9,2} \end{aligned}$$

$$\begin{aligned}
& + F_{9,4} + F_{9,5} + F_{9,6} + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,11} + F_{9,12} + F_{10,1} + F_{10,2} + F_{10,4} + F_{10,5} \\
& + F_{10,6} + F_{10,7} + F_{10,8} + F_{10,9} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,1} + F_{11,2} + F_{11,4} + F_{11,5} + F_{11,6} \\
& + F_{11,7} + F_{11,8} + F_{11,9} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,2} + F_{12,4} + F_{12,5} + F_{12,6} + F_{12,7} \\
& + F_{12,8} + F_{12,9} + F_{12,10} + F_{12,11} + T_{12,12}
\end{aligned} \tag{3.118}$$

$$\begin{aligned}
TN_{TIHGG} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,11} + F_{1,12} + F_{2,1} + \\
& T_{2,2} + F_{2,3} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,11} + F_{2,12} + F_{3,1} + F_{3,2} + T_{3,3} + F_{3,5} \\
& + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,11} + F_{3,12} + F_{5,1} + F_{5,2} + F_{5,3} + T_{5,5} + F_{5,6} + F_{5,7} + \\
& F_{5,8} + F_{5,9} + F_{5,10} + F_{5,11} + F_{5,12} + F_{6,1} + F_{6,2} + F_{6,3} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,9} + F_{6,10} \\
& + F_{6,11} + F_{6,12} + F_{7,1} + F_{7,2} + F_{7,3} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,11} + F_{7,12} + \\
& F_{8,1} + F_{8,2} + F_{8,3} + F_{8,5} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,11} + F_{8,12} + F_{9,1} + F_{9,2} + F_{9,3} \\
& + F_{9,5} + F_{9,6} + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,11} + F_{9,12} + F_{10,1} + F_{10,2} + F_{10,3} + F_{10,5} + F_{10,6} \\
& + F_{10,7} + F_{10,8} + F_{10,9} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,1} + F_{11,2} + F_{11,3} + F_{11,5} + F_{11,6} + F_{11,7} \\
& + F_{11,8} + F_{11,9} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,2} + F_{12,3} + F_{12,5} + F_{12,6} + F_{12,7} + F_{12,8} \\
& + F_{12,9} + F_{12,10} + F_{12,11} + T_{12,12}
\end{aligned} \tag{3.119}$$

$$\begin{aligned}
TN_{TILGG} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,4} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,11} + F_{1,12} + F_{2,1} + \\
& T_{2,2} + F_{2,3} + F_{2,4} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,11} + F_{2,12} + F_{3,1} + F_{3,2} + T_{3,3} + F_{3,4} \\
& + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,11} + F_{3,12} + F_{4,1} + F_{4,2} + F_{4,3} + T_{4,4} + F_{4,6} + F_{4,7} + \\
& F_{4,8} + F_{4,9} + F_{4,10} + F_{4,11} + F_{4,12} + F_{6,1} + F_{6,2} + F_{6,3} + F_{6,4} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,9} + F_{6,10} \\
& + F_{6,11} + F_{6,12} + F_{7,1} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,11} + F_{7,12} + \\
& F_{8,1} + F_{8,2} + F_{8,3} + F_{8,4} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,11} + F_{8,12} + F_{9,1} + F_{9,2} + F_{9,3} \\
& + F_{9,4} + F_{9,6} + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,11} + F_{9,12} + F_{10,1} + F_{10,2} + F_{10,3} + F_{10,4} + F_{10,6} \\
& + F_{10,7} + F_{10,8} + F_{10,9} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,1} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,6} + F_{11,7} \\
& + F_{11,8} + F_{11,9} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,6} + F_{12,7} + F_{12,8} \\
& + F_{12,9} + F_{12,10} + F_{12,11} + T_{12,12}
\end{aligned} \tag{3.120}$$

$$\begin{aligned}
TN_{TINORMAL} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,11} + F_{1,12} + F_{2,1} \\
& + T_{2,2} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,11} + F_{2,12} + F_{3,1} + F_{3,2} + T_{3,3} + \\
& F_{3,4} + F_{3,5} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,11} + F_{3,12} + F_{4,1} + F_{4,2} + F_{4,3} + T_{4,4} + F_{4,5} + F_{4,7} \\
& + F_{4,8} + F_{4,9} + F_{4,10} + F_{4,11} + F_{4,12} + F_{5,1} + F_{5,2} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,7} + F_{5,8} + F_{5,9} + \\
& F_{5,10} + F_{5,11} + F_{5,12} + F_{7,1} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,5} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,11} + \\
& F_{7,12} + F_{8,1} + F_{8,2} + F_{8,3} + F_{8,4} + F_{8,5} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,11} + F_{8,12} + F_{9,1} + F_{9,2}
\end{aligned}$$

$$\begin{aligned}
& + F_{9,3} + F_{9,4} + F_{9,5} + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,11} + F_{9,12} + F_{10,1} + F_{10,2} + F_{10,3} + F_{10,4} \\
& + F_{10,5} + F_{10,7} + F_{10,8} + F_{10,9} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,1} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,5} \\
& + F_{11,7} + F_{11,8} + F_{11,9} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,7} \\
& + F_{12,8} + F_{12,9} + F_{12,10} + F_{12,11} + T_{12,12}
\end{aligned} \tag{3.121}$$

$$\begin{aligned}
TN_{TICEHGG} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,11} + F_{1,12} + F_{2,1} \\
& + T_{2,2} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,11} + F_{2,12} + F_{3,1} + F_{3,2} + T_{3,3} + \\
& F_{3,4} + F_{3,5} + F_{3,6} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,11} + F_{3,12} + F_{4,1} + F_{4,2} + F_{4,3} + T_{4,4} + F_{4,5} + F_{4,6} \\
& + F_{4,8} + F_{4,9} + F_{4,10} + F_{4,11} + F_{4,12} + F_{5,1} + F_{5,2} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,6} + F_{5,8} + F_{5,9} + \\
& F_{5,10} + F_{5,11} + F_{5,12} + F_{6,1} + F_{6,2} + F_{6,3} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,8} + F_{6,9} + F_{6,10} + F_{6,11} + \\
& F_{6,12} + F_{8,1} + F_{8,2} + F_{8,3} + F_{8,4} + F_{8,5} + F_{8,6} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,11} + F_{8,12} + F_{9,1} + F_{9,2} \\
& + F_{9,3} + F_{9,4} + F_{9,5} + F_{9,6} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,11} + F_{9,12} + F_{10,1} + F_{10,2} + F_{10,3} + F_{10,4} \\
& + F_{10,5} + F_{10,6} + F_{10,8} + F_{10,9} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,1} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,5} \\
& + F_{11,6} + F_{11,8} + F_{11,9} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,6} \\
& + F_{12,8} + F_{12,9} + F_{12,10} + F_{12,11} + T_{12,12}
\end{aligned} \tag{3.122}$$

$$\begin{aligned}
TN_{TICELGG} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,9} + F_{1,10} + F_{1,11} + F_{1,12} + F_{2,1} \\
& + T_{2,2} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,9} + F_{2,10} + F_{2,11} + F_{2,12} + F_{3,1} + F_{3,2} + T_{3,3} + \\
& F_{3,4} + F_{3,5} + F_{3,6} + F_{3,7} + F_{3,9} + F_{3,10} + F_{3,11} + F_{3,12} + F_{4,1} + F_{4,2} + F_{4,3} + T_{4,4} + F_{4,5} + F_{4,6} \\
& + F_{4,7} + F_{4,9} + F_{4,10} + F_{4,11} + F_{4,12} + F_{5,1} + F_{5,2} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,6} + F_{5,7} + F_{5,9} + \\
& F_{5,10} + F_{5,11} + F_{5,12} + F_{6,1} + F_{6,2} + F_{6,3} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,9} + F_{6,10} + F_{6,11} + \\
& F_{6,12} + F_{7,1} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,9} + F_{7,10} + F_{7,11} + F_{7,12} + F_{9,1} + F_{9,2} \\
& + F_{9,3} + F_{9,4} + F_{9,5} + F_{9,6} + F_{9,7} + T_{9,9} + F_{9,10} + F_{9,11} + F_{9,12} + F_{10,1} + F_{10,2} + F_{10,3} + F_{10,4} \\
& + F_{10,5} + F_{10,6} + F_{10,7} + F_{10,9} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,1} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,5} \\
& + F_{11,6} + F_{11,7} + F_{11,9} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,6} \\
& + F_{12,7} + F_{12,9} + F_{12,10} + F_{12,11} + T_{12,12}
\end{aligned} \tag{3.123}$$

$$\begin{aligned}
TN_{TICENORMAL} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,10} + F_{1,11} + F_{1,12} + \\
& F_{2,1} + T_{2,2} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,10} + F_{2,11} + F_{2,12} + F_{3,1} + F_{3,2} + T_{3,3} \\
& + F_{3,4} + F_{3,5} + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,10} + F_{3,11} + F_{3,12} + F_{4,1} + F_{4,2} + F_{4,3} + T_{4,4} + F_{4,5} + \\
& F_{4,6} + F_{4,7} + F_{4,8} + F_{4,10} + F_{4,11} + F_{4,12} + F_{5,1} + F_{5,2} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,6} + F_{5,7} + F_{5,8} \\
& + F_{5,10} + F_{5,11} + F_{5,12} + F_{6,1} + F_{6,2} + F_{6,3} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,10} + F_{6,11} + \\
& F_{6,12} + F_{7,1} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,10} + F_{7,11} + F_{7,12} + F_{8,1} + F_{8,2} \\
& + F_{8,3} + F_{8,4} + F_{8,5} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,10} + F_{8,11} + F_{8,12} + F_{10,1} + F_{10,2} + F_{10,3} + F_{10,4}
\end{aligned}$$

$$\begin{aligned}
& + F_{10,5} + F_{10,6} + F_{10,7} + F_{10,8} + T_{10,10} + F_{10,11} + F_{10,12} + F_{11,1} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,5} \\
& + F_{11,6} + F_{11,7} + F_{11,8} + F_{11,10} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,6} \\
& + F_{12,7} + F_{12,8} + F_{12,10} + F_{12,11} + T_{12,12}
\end{aligned} \tag{3.124}$$

$$\begin{aligned}
TN_{T2HGG} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,11} + F_{1,12} + F_{2,1} + \\
& T_{2,2} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,11} + F_{2,12} + F_{3,1} + F_{3,2} + T_{3,3} + F_{3,4} \\
& + F_{3,5} + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,11} + F_{3,12} + F_{4,1} + F_{4,2} + F_{4,3} + T_{4,4} + F_{4,5} + F_{4,6} + F_{4,7} \\
& + F_{4,8} + F_{4,9} + F_{4,11} + F_{4,12} + F_{5,1} + F_{5,2} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,6} + F_{5,7} + F_{5,8} + F_{5,9} + \\
& F_{5,11} + F_{5,12} + F_{6,1} + F_{6,2} + F_{6,3} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,9} + F_{6,11} + F_{6,12} + \\
& F_{7,1} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,11} + F_{7,12} + F_{8,1} + F_{8,2} + F_{8,3} + \\
& F_{8,4} + F_{8,5} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,11} + F_{8,12} + F_{9,1} + F_{9,2} + F_{9,3} + F_{9,4} + F_{9,5} + F_{9,6} \\
& + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,11} + F_{9,12} + F_{11,1} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,5} + F_{11,6} + F_{11,7} + F_{11,8} \\
& + F_{11,9} + T_{11,11} + F_{11,12} + F_{12,1} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,6} + F_{12,7} + F_{12,8} + F_{12,9} + \\
& F_{12,11} + T_{12,12}
\end{aligned} \tag{3.125}$$

$$\begin{aligned}
TN_{T2LGG} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,12} + F_{2,1} + \\
& T_{2,2} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,12} + F_{3,1} + F_{3,2} + T_{3,3} + F_{3,4} \\
& + F_{3,5} + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,12} + F_{4,1} + F_{4,2} + F_{4,3} + T_{4,4} + F_{4,5} + F_{4,6} + F_{4,7} \\
& + F_{4,8} + F_{4,9} + F_{4,10} + F_{4,12} + F_{5,1} + F_{5,2} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,6} + F_{5,7} + F_{5,8} + F_{5,9} + \\
& F_{5,10} + F_{5,12} + F_{6,1} + F_{6,2} + F_{6,3} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,9} + F_{6,10} + F_{6,12} + \\
& F_{7,1} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,12} + F_{8,1} + F_{8,2} + F_{8,3} + \\
& F_{8,4} + F_{8,5} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,12} + F_{9,1} + F_{9,2} + F_{9,3} + F_{9,4} + F_{9,5} + F_{9,6} \\
& + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,12} + F_{10,1} + F_{10,2} + F_{10,3} + F_{10,4} + F_{10,5} + F_{10,6} + F_{10,7} + \\
& F_{10,8} + F_{10,9} + T_{10,10} + F_{10,12} + F_{12,1} + F_{12,2} + F_{12,3} + F_{12,4} + F_{12,5} + F_{12,6} + F_{12,7} + F_{12,8} + \\
& F_{12,9} + F_{12,10} + T_{12,12}
\end{aligned} \tag{3.126}$$

$$\begin{aligned}
TN_{T2NORMAL} = & T_{1,1} + F_{1,2} + F_{1,3} + F_{1,4} + F_{1,5} + F_{1,6} + F_{1,7} + F_{1,8} + F_{1,9} + F_{1,10} + F_{1,11} + F_{2,1} \\
& + T_{2,2} + F_{2,3} + F_{2,4} + F_{2,5} + F_{2,6} + F_{2,7} + F_{2,8} + F_{2,9} + F_{2,10} + F_{2,11} + F_{3,1} + F_{3,2} + T_{3,3} + F_{3,4} \\
& + F_{3,5} + F_{3,6} + F_{3,7} + F_{3,8} + F_{3,9} + F_{3,10} + F_{3,11} + F_{4,1} + F_{4,2} + F_{4,3} + T_{4,4} + F_{4,5} + F_{4,6} + F_{4,7} \\
& + F_{4,8} + F_{4,9} + F_{4,10} + F_{4,11} + F_{5,1} + F_{5,2} + F_{5,3} + F_{5,4} + T_{5,5} + F_{5,6} + F_{5,7} + F_{5,8} + F_{5,9} + \\
& F_{5,10} + F_{5,11} + F_{6,1} + F_{6,2} + F_{6,3} + F_{6,4} + F_{6,5} + T_{6,6} + F_{6,7} + F_{6,8} + F_{6,9} + F_{6,10} + F_{6,11} + \\
& F_{7,1} + F_{7,2} + F_{7,3} + F_{7,4} + F_{7,5} + F_{7,6} + T_{7,7} + F_{7,8} + F_{7,9} + F_{7,10} + F_{7,11} + F_{8,1} + F_{8,2} + F_{8,3} + \\
& F_{8,4} + F_{8,5} + F_{8,6} + F_{8,7} + T_{8,8} + F_{8,9} + F_{8,10} + F_{8,11} + F_{9,1} + F_{9,2} + F_{9,3} + F_{9,4} + F_{9,5} + F_{9,6} \\
& + F_{9,7} + F_{9,8} + T_{9,9} + F_{9,10} + F_{9,11} + F_{10,1} + F_{10,2} + F_{10,3} + F_{10,4} + F_{10,5} + F_{10,6} + F_{10,7} +
\end{aligned}$$

$$F_{10,8} + F_{10,9} + T_{10,10} + F_{10,11} + F_{11,1} + F_{11,2} + F_{11,3} + F_{11,4} + F_{11,5} + F_{11,6} + F_{11,7} + F_{11,8} + F_{11,9} + F_{11,10} + T_{11,11} \quad (3.127)$$

12 sınıf çıkışlı sınıflandırmada doğruluk değeri, tüm TP değerlerinin (Denklem 3.128) toplam görüntü sayısına (Denklem 3.129) bölünmesi sonucu elde edilir (Denklem 3.130).

$$TP = T_{1,1} + T_{2,2} + T_{3,3} + T_{4,4} + T_{5,5} + T_{6,6} + T_{7,7} + T_{8,8} + T_{9,9} + T_{10,10} + T_{11,11} + T_{12,12} \quad (3.128)$$

$$\text{Toplam Görüntü Sayısı} = \text{Karmaşıklık matrisindeki tüm eleman sayısı} \quad (3.129)$$

$$\text{Doğruluk} = \frac{TP}{\text{Toplam Görüntü Sayısı}} \quad (3.130)$$

Kesinlik değeri, sınıflara ait TP değerlerinin TP değeri ve FP değerinin toplamına bölünmesiyle elde edilir. Denklem 3.131’de FLAIR HGG sınıfına ait kesinlik değeri hesaplama örneği verilmiştir. Diğer tüm sınıflarda, aynı denkleme uygun değerlerin yazılmasıyla kesinlik değeri elde edilir. Ortalama kesinlik değeri, bütün sınıfların kesinlik değerleri toplamının sınıf sayısı olan 12’ye bölünmesi ile elde edilir.

$$\text{Kesinlik}_{FLAIRHGG} = \frac{TP_{FLAIRHGG}}{TP_{FLAIRHGG} + FP_{FLAIRHGG}} \quad (3.131)$$

Duyarlılık değerinin hesaplanması, sınıflara ait TP değerlerinin TP değeri ve FN değerinin toplamına bölünmesiyle elde edilir. Denklem 3.132’de, FLAIR HGG sınıfına ait duyarlılık değeri hesaplama örneği verilmiştir. Diğer tüm sınıflarda aynı denkleme uygun değerlerin yazılmasıyla duyarlılık değeri elde edilir. Ortalama duyarlılık değeri, tüm sınıfların duyarlılık değerlerinin toplamının sınıf sayısı olan 12’ye bölünmesi ile elde edilir.

$$\text{Duyarlılık}_{FLAIRHGG} = \frac{TP_{FLAIRHGG}}{TP_{FLAIRHGG} + FN_{FLAIRHGG}} \quad (3.132)$$

Özgüllük değeri ise gerçek negatiflerin yanlış pozitif toplamına bölünmesi ile elde edilir (Denklem 3.133). 12 sınıfa ait ortalama özgüllük değeri, her sınıfa ait özgüllük değerleri toplamının sınıf sayısına bölünmesi ile bulunmaktadır.

$$\text{Özgüllük}_{FLAIRHGG} = \frac{TN_{FLAIRHGG}}{TN_{FLAIRHGG} + FP_{FLAIRHGG}} \quad (3.133)$$

Sınıflandırma problemlerinde performans ölçütü olan bir diğer kriter F1 puanı hesaplaması Denklem 3.134'te verilmiştir. Her sınıfta ait kesinlik ve duyarlılık değerleri denkleme yazıldığında sınıfların F1 puanı bulunur.

$$F1\text{puanı}_{FLAIRHGG} = 2 * \frac{Kesinlik_{FLAIRHGG} * Duyarlilik_{FLAIRHGG}}{Kesinlik_{FLAIRHGG} + Duyarlilik_{FLAIRHGG}} \quad (3.134)$$

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Tez çalışmasında, modeller veri kümesi 5 kat çapraz doğrulama yapılarak eğitilmiştir. Her bir döngüde performans değerlendirme kriteri olan duyarlılık, hassasiyet, kesinlik, özgüllük, F1 puanı ve doğruluk değerleri hesaplanmıştır. Elde edilen değerlerin ortalamaları ve standart sapmaları bulunmuştur.

4.1. 3 Sınıf Çıkışlı Sınıflandırma Sonuçları


4.1.1. AlexNet

3 sınıf çıkışlı sınıflandırmada, AlexNet ağ modeli performansı sonucunda FLAIR, T1, T1CE ve T2 modalitelerine ait kesinlik, duyarlılık, özgüllük doğruluk ve F1 puanı ve her döngüye ait eğitim süreleri Çizelge 4.1’de gösterilmiştir. 3 sınıf çıkışlı AlexNet ağ modelinde, tüm değerlerin %99’un üzerinde olduğu görülmektedir. Ağ modelinin yüksek performansı, optimum hiper parametrenin belirlenmesi ile sağlanmıştır. Modalitelerin eğitim süresinin ortalaması ~ 2 dakika (dk) 45 saniye (sn)’dir.

Çizelge 4.1. 3 sınıf çıkışlı AlexNet modelinde beş döngünün performans değerleri ve ortalamaları


Modalite	Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
FLAIR	1.Döngü	0,9966	0,9966	0,9983	0,9966	0,9966	00:02:44
	2.Döngü	0,9983	0,9983	0,9991	0,9983	0,9983	00:02:43
	3.Döngü	0,9965	0,9969	0,9983	0,9966	0,9967	00:02:42
	4.Döngü	0,9968	0,9965	0,9982	0,9966	0,9967	00:02:43
	5.Döngü	1	1	1	1	1	00:02:52
	Ortalama	0,9976±(0,0014)	0,9977±(0,0014)	0,9988±(0,0007)	0,9976±(0,0014)	0,9976±(0,0014)	00:02:45
T1	1.Döngü	0,9949	0,9949	0,9974	0,995	0,9949	00:02:46
	2.Döngü	0,9788	0,9784	0,9891	0,9783	0,9786	00:02:41
	3.Döngü	0,9937	0,9927	0,9965	0,9933	0,9932	00:02:43
	4.Döngü	0,9967	0,9966	0,9983	0,9966	0,9967	00:02:42
	5.Döngü	0,9948	0,9951	0,9975	0,995	0,9949	00:02:48
	Ortalama	0,9918±(0,0073)	0,9915±(0,0074)	0,9958±(0,0037)	0,9916±(0,0075)	0,9917±(0,0073)	00:02:44
T1CE	1.Döngü	0,995	0,9948	0,9975	0,995	0,9949	00:02:45
	2.Döngü	0,9885	0,9885	0,9941	0,9883	0,9885	00:02:45
	3.Döngü	0,9946	0,9949	0,9976	0,995	0,9948	00:02:45
	4.Döngü	0,9983	0,9984	0,9992	0,9983	0,9983	00:02:45
	5.Döngü	0,9877	0,9889	0,9944	0,9883	0,9883	00:02:45
	Ortalama	0,9928±(0,0045)	0,9930±(0,0042)	0,9965±(0,0021)	0,9930±(0,0044)	0,9929±(0,0044)	00:02:45
T2	1.Döngü	0,995	0,9948	0,9975	0,995	0,9949	00:02:44
	2.Döngü	0,9885	0,9885	0,9941	0,9883	0,9885	00:02:47
	3.Döngü	0,9946	0,9949	0,9976	0,995	0,9948	00:02:44
	4.Döngü	0,9983	0,9984	0,9992	0,9983	0,9983	00:02:49
	5.Döngü	0,9877	0,9889	0,9944	0,9883	0,9883	00:02:47
	Ortalama	0,9969±(0,0007)	0,9970±(0,0007)	0,9985±(0,0003)	0,9970±(0,0007)	0,9969±(0,0007)	00:02:46

AlexNet ağında FLAIR modalite doğruluk grafiği Şekil 4.1’de verilmiştir. Grafikte her 45 iterasyon sonunda elde edilen doğruluk oranları gösterilmiştir. Döngülerin doğruluk oranları birbirine çok yakın olduğu için 406. iterasyondan sonra ağ kararlı bir duruma geçmiştir.




Şekil 4.1. AlexNet ağı FLAIR modalitesine ait beş döngünün doğruluk grafiği

AlexNet ağı FLAIR modalitesine ait kayıp oranı grafiğinde (Şekil 4.2) model tahminlerindeki hata oranı gösterilmektedir.




Şekil 4.2. AlexNet ağı FLAIR modalitesine ait beş döngünün kayıp oranı grafiği

Şekil 4.3a’da verilen 5. döngüye ait karmaşıklık matrisinde, FLAIR modalitesine ait HGG, LGG ve normal sınıfların hatasız bir şekilde tahmin edildiği görülmektedir. Tüm sınıflandırmaların doğru olması sonucunda Şekil 4.3b’de verilen ROC-AUC değerleri de 1 olarak elde edilmiştir.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..3. AlexNet ağı (a) FLAIR modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

T1 modalitesine ait görüntülerin, AlexNet ağına eğitilmesi sonucunda elde edilen doğruluk grafiği Şekil 4.4’te verilmiştir. Doğruluk grafiğinde, 541. iterasyondan sonra ağıdaki beş döngünün doğruluk oranlarının %100’e yaklaştığı görülmektedir.




Şekil 4.4. AlexNet ağı T1 modalitesine ait beş döngünün doğruluk grafiği

541.iterasyondan sonra kayıp oranının 0'a yaklaştığı Şekil 4.5'teki grafikte gösterilmiştir.




Şekil 4.5. AlexNet ağı T1 modalitesine ait beş döngünün kayıp oranı grafiği

AlexNet ağı T1 modalitesi 5. döngüye ait karmaşıklık matrisinde (Şekil 4.6a), 2 adet LGG görüntüsü normal, 1 adet normal görüntüsü ise LGG olarak tahmin edildiği görülmüştür. Yüksek performans sonucu çizilen ROC grafiğinde (Şekil 4.6b), AUC değerleri 1 bulunmuştur.




Şekil 4.6. AlexNet ağı (a) T1 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

T1CE modalitesinde, 5. döngünün diğer döngülerden farklı bir salınımda olduğu Şekil 4.7.'de verilen doğruluk oranı grafiğinde görülmektedir.




Şekil 4.7. AlexNet ağı T1CE modalitesine ait beş döngünün doğruluk grafiği

Şekil 4.8'de verilen kayıp oranı grafiğinde 3,5 olan en yüksek değer 2. döngüye aittir.




Şekil 4.8. AlexNet ağı T1CE modalitesine ait beş döngünün kayıp oranı grafiği

T1CE modalitesi 5. döngü karmaşıklık matrisinde (Şekil 4.9a), 3 HGG ve 4 LGG görüntüsü normal görüntü olarak sınıflandırılmıştır. ROC grafiğinde (Şekil 4.9b), AUC değeri modalitelerin hepsinde 1 olarak bulunmuştur.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..9. AlexNet ağı (a) T1CE modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

T2 modalitesine ait doğruluk grafiğinde (Şekil 4.10), 271. iterasyon itibariyle yüksek doğruluk oranları elde edilmiştir.




Şekil 4.10. AlexNet ağı T2 modalitesine ait beş döngünün doğruluk grafiği

Kayıp oranı grafiğinde (Şekil 4.11), 46. iterasyon ile birlikte hata oranı 0,5'in altına düşmüştür.



Şekil 4.11. AlexNet ağı T2 modalitesine ait beş döngünün kayıp oranı grafiği

Şekil 4.12a'da verilen T2 modalitesine ait 5. döngü karmaşıklık matrisinde, LGG sınıfına ait görüntülerden 2 tanesi normal olarak tahmin edilmiştir. ROC grafiğinde, Şekil 4.12b'de gösterildiği üzere tüm sınıflarda AUC değeri 1 elde edilmiştir.



Şekil 4.12. AlexNet ağı (a) T2 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği


4.1.2. GoogleNet

GoogleNet, 3 sınıf çıkışlı sınıflandırmanın beş döngüye ait performans değerleri, ortalamaları ve eğitim süreleri Çizelge 4.2’de verilmiştir. Performans değerleri incelendiğinde FLAIR modalitesinin, %99,16 doğruluk ortalamasıyla en yüksek sonuca ulaştığı görülmektedir. Modaliteler arasında en düşük doğruluk ortalaması, %96,13 ile T1CE modalitesine aittir. Döngülerin ortalama eğitim süresi yaklaşık 6 dk ’dır.

Çizelge 4.2. 3 sınıf çıkışlı GoogleNet modelinde beş döngünün performans değerleri ve ortalamaları


Modalite	Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
FLAIR	1.Döngü	0,9950	0,9952	0,9975	0,9950	0,9951	00:05:50
	2.Döngü	0,9917	0,9916	0,9958	0,9917	0,9916	00:05:52
	3.Döngü	0,9804	0,9830	0,9914	0,9817	0,9817	00:05:54
	4.Döngü	1	1	1	1	1	00:05:59
	5.Döngü	0,9900	0,9901	0,9950	0,9900	0,9900	00:05:58
	Ortalama	0,9914±(0,0072)	0,9919±(0,0062)	0,9959±(0,0031)	0,9916±(0,0067)	0,9916±(0,0067)	00:05:55
T1	1.Döngü	0,9871	0,9867	0,9933	0,9867	0,9869	00:05:46
	2.Döngü	0,9852	0,9850	0,9925	0,9850	0,9851	00:05:49
	3.Döngü	0,9813	0,9823	0,9909	0,9817	0,9818	00:05:52
	4.Döngü	0,9750	0,9749	0,9875	0,9750	0,9749	00:05:58
	5.Döngü	0,9769	0,9764	0,9884	0,9767	0,9766	00:06:02
	Ortalama	0,9810±(0,0051)	0,9810±(0,0051)	0,9905±(0,0025)	0,9810±(0,0050)	0,9810±(0,0051)	00:05:53
T1CE	1.Döngü	0,9586	0,9555	0,9781	0,9567	0,9570	00:05:46
	2.Döngü	0,9537	0,9536	0,9766	0,9533	0,9536	00:05:54
	3.Döngü	0,9606	0,9613	0,9810	0,9617	0,9610	00:05:56
	4.Döngü	0,9632	0,9618	0,9808	0,9617	0,9625	00:05:56
	5.Döngü	0,9725	0,9740	0,9871	0,9733	0,9733	00:06:01
	Ortalama	0,9617±(0,0069)	0,9612±(0,0080)	0,9807±(0,0039)	0,9613±(0,0075)	0,9614±(0,0074)	00:05:55
T2	1.Döngü	0,9851	0,9847	0,9925	0,9850	0,9849	00:05:50
	2.Döngü	0,9818	0,9818	0,9908	0,9817	0,9818	00:05:53
	3.Döngü	0,9951	0,9952	0,9975	0,9950	0,9951	00:05:53
	4.Döngü	0,9855	0,9848	0,9924	0,9850	0,9851	00:05:54
	5.Döngü	0,9913	0,9918	0,9959	0,9917	0,9915	00:06:05
	Ortalama	0,9877±(0,0053)	0,9876±(0,0055)	0,9938±(0,0027)	0,9876±(0,0054)	0,9876±(0,0054)	00:05:55

FLAIR modalitesine ait doğruluk grafiğinde (Şekil 4.13), 3. ve 4. döngünün daha fazla salınım ile eğitimi sonlandırdığı görülmektedir.




Şekil 4.13. GoogleNet ağı FLAIR modalitesi beş döngüye ait doğruluk grafiği

Şekil 4.14'te verilen kayıp oranı grafiğine göre, 2. döngü yaklaşık 4,5 değeri ile en yüksek kayıp oranına sahiptir.




Şekil 4.14. GoogleNet ağı FLAIR modalitesi beş döngüye ait kayıp oranı grafiği

FLAIR modalitesi 5. döngüye ait karmaşıklık matrisinde (Şekil 4.15a), 6 görüntü yanlış tahmin edilmiştir. ROC grafiğinde ise (Şekil 4.15b), HGG sınıfının AUC değeri diğer sınıflardan düşük bulunmuştur.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..15. GoogleNet ağı FLAIR modalitesi 5. döngü karmaşıklık matrisi ve ROC grafiği

T1 modalitesi doğruluk grafiğinde (Şekil 4.16), 5 döngünün düşük doğruluk oranıyla eğitime başladığı ve uzun sürede kararlılığa ulaştığı görülmektedir.




Şekil 4.16. GoogleNet ağı T1 modalitesi beş döngüye ait doğruluk grafiği

Şekil 4.17’de T1 modalitesine ait kayıp oran grafiğinde, 451. iterasyon sonrasında döngülerin 0,5 değeri altında olduğu gözlemlenmiştir.




Şekil 4.17. GoogleNet ağı T1 modalitesi beş döngüye ait kayıp oranı grafiği

T1 modalitesi 5. döngü karmaşıklık matrisi (Şekil 4.18a) ve ROC grafiğinde (Şekil 4.18b) LGG ve normal sınıf tahminlerinin, HGG görüntülere göre daha düşük doğruluk değerine sahip olduğu görülmektedir.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..18. GoogleNet ağı (a) T1 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.19’da T1CE modalitesi doğruluk grafiğinde, ağı 811. iterasyon sonrasında kararlı hale gelmiştir.




Şekil 4.19. GoogleNet ağı T1CE modalitesine ait beş döngünün doğruluk grafiği

Şekil 4.20’de verilen kayıp oranı grafiğinde ise ilk 2 döngünün kayıp oranının, diğer döngülere göre daha yüksek olduğu görülmüştür.




Şekil 4.20. GoogleNet ağı T1CE modalitesine ait beş döngünün kayıp oranı grafiği

T1CE modalitesine ait karmaşıklık matrisi (Şekil 4.21a) ve ROC grafiği (Şekil 4.21b) verilmiştir. Karmaşıklık matrisinde, 4 HGG ve 8 LGG görüntüsü, normal sınıfa ait olarak tahmin edilmiştir. 1 LGG ve 3 normal görüntü ise HGG olarak tahmin edilmiştir.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..21. GoogleNet ağı (a) T1CE modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.22’de verilen T2 modalitesi doğruluk grafiğinde, ağın öğrenme oranının 721. iterasyonda yüksek doğruluk seviyesine ulaştığı görülmektedir.




Şekil 4.22. GoogleNet ağı T2 modalitesine ait beş döngünün doğruluk grafiği

Şekil 4.23’de kayıp grafiğinde ise 2. döngünün en yüksek kayıp oranına sahip olduğu görülmektedir.



Şekil 4.23. GoogleNet ağı T2 modalitesine ait beş döngünün kayıp oranı grafiği

T2 modalitesi karmaşıklık matrisi (Şekil 4.24a) ve ROC grafiği (Şekil 4.24b) gösterilmektedir. 2 HGG ve 2 LGG görüntüsü normal sınıf, 1 normal sınıf ise LGG olarak tahmin edilmiştir.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..24. GoogleNet ağı (a) T2 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

4.1.3. ShuffleNet

ShuffleNet modeli, 3 sınıf çıkışlı sınıflandırma performans değerleri Çizelge 4.3'te verilmiştir. FLAIR ve T2 modalitelerinde kesinlik, duyarlılık, özgüllük, doğruluk ve F1 puanı değerleri %99'un üzerinde bir performans sağlamıştır. T1CE modalitesi performans ortalamaları, %97 değerinde olup diğer modalitelere göre düşük bulunmuştur. Döngülerin eğitim süresi 12-13 dk arasındadır.


Çizelge 4.3. 3 sınıf çıkışlı ShuffleNet modelinde beş döngünün performans değerleri ve ortalamaları

Modalite	Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
FLAIR	1.Döngü	0,9919	0,9914	0,9958	0,9917	0,9917	00:13:10
	2.Döngü	0,9916	0,9917	0,9959	0,9917	0,9917	00:13:29
	3.Döngü	0,9968	0,9966	0,9983	0,9967	0,9967	00:13:34
	4.Döngü	0,9950	0,9948	0,9975	0,9950	0,9949	00:13:39
	5.Döngü	0,9932	0,9936	0,9967	0,9933	0,9934	00:13:46
	Ortalama	0,9937±(0,0021)	0,9936±(0,0021)	0,9968±(0,0010)	0,9936±(0,0021)	0,9936±(0,0021)	00:13:32
T1	1.Döngü	0,9802	0,9799	0,9900	0,9800	0,9800	00:12:58
	2.Döngü	0,9670	0,9668	0,9833	0,9667	0,9669	00:13:22
	3.Döngü	0,9907	0,9902	0,9948	0,9900	0,9904	00:13:28
	4.Döngü	0,9883	0,9884	0,9942	0,9883	0,9884	00:13:35
	5.Döngü	0,9952	0,9947	0,9975	0,9950	0,9949	00:13:45
	Ortalama	0,9842±(0,0110)	0,9839±(0,0110)	0,9919±(0,0055)	0,9840±(0,0110)	0,9841±(0,0110)	00:13:26
T1CE	1.Döngü	0,9715	0,9711	0,9859	0,9717	0,9713	00:12:57
	2.Döngü	0,9674	0,9667	0,9833	0,9667	0,9670	00:13:25
	3.Döngü	0,9696	0,9682	0,9839	0,9683	0,9689	00:13:28
	4.Döngü	0,9732	0,9738	0,9867	0,9733	0,9735	00:13:40
	5.Döngü	0,9774	0,9782	0,9894	0,9783	0,9778	00:13:40
	Ortalama	0,9718±(0,0038)	0,9716±(0,0045)	0,9858±(0,0024)	0,9716±(0,0045)	0,9717±(0,0041)	00:13:26
T2	1.Döngü	0,9916	0,9914	0,9959	0,9917	0,9915	00:12:55
	2.Döngü	0,9836	0,9831	0,9916	0,9833	0,9834	00:13:24
	3.Döngü	0,9922	0,9916	0,9957	0,9917	0,9919	00:13:28
	4.Döngü	0,9965	0,9968	0,9984	0,9967	0,9967	00:13:37
	5.Döngü	0,9911	0,9916	0,9960	0,9917	0,9914	00:13:46
	Ortalama	0,9910±(0,0046)	0,9909±(0,0049)	0,9955±(0,0024)	0,9919±(0,0048)	0,9909±(0,0047)	00:13:26




Şekil 4.25. ShuffleNet ağı FLAIR modalitesine ait beş döngünün doğruluk grafiği

FLAIR modalitesine ait doğruluk grafiği Şekil 4.25’de, kayıp grafiği ise Şekil 4.26’da verilmiştir. Doğruluk grafiğinde 2. ve 5. döngüde, diğer döngülere göre farklı salınımlar olduğu görülmektedir. Kayıp oranı grafiğinde, sadece 4. döngünün kayıp oranı 2’nin üzerindedir.




Şekil 4.26. ShuffleNet ağı FLAIR modalitesine ait beş döngünün kayıp oranı grafiği

Şekil 4.27a’da FLAIR modalitesi 5. döngüye ait karmaşıklık matrisi ve Şekil 4.27b’de ROC grafiği verilmiştir. Modelde 4 hatalı tahmin yapılmış ve tüm sınıfların AUC değerinin 1 olduğu ROC grafiğinde gösterilmiştir.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..27. ShuffleNet ağı (a) FLAIR modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

T1 modalitesine ait doğruluk grafiğinde (Şekil 4.28), ağın kısa sürede yüksek performansa ulaştığı görülmektedir.




Şekil 4.28. ShuffleNet ağı T1 modalitesine ait beş döngünün doğruluk grafiği

Kayıp oran grafiğinde (Şekil 4.29), 181. iterasyon sonrasında kayıp oranı 0,5 değerinin altındadır.




Şekil 4.29. ShuffleNet ağı T1 modalitesine ait beş döngünün kayıp oranı grafiği

T1 modalitesi karmaşıklık matrisinde (Şekil 4.30a), 2 normal görüntü HGG, 1 HGG görüntü ise LGG olarak tahmin edilmiştir. ROC grafiğinde (Şekil 4.30b), AUC değerlerinin tüm sınıflarda 1 değerinde olduğu görülmektedir.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..30. ShuffleNet ağı (a) T1 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği




Şekil 4.31. ShuffleNet ağı T1CE modalitesine ait beş döngünün doğruluk grafiği

T1CE modalitesi doğruluk grafiğinde (Şekil 4.31), ağ kısa sürede %90 üstü doğruluk değerine ulaşmıştır. Şekil 4.32’de verilen kayıp grafiğinde, en yüksek kayıp oranının 2,4 olduğu ve ağın 226. iterasyon sonrası 0 değerine yaklaştığı görülmektedir.




Şekil 4.32. ShuffleNet ağı T1CE modalitesine ait beş döngünün kayıp oranı grafiği

T1CE modalitesi karmaşıklık matrisinde (Şekil 4.33a), 5 HGG ve 4 LGG görüntü normal tahmin edilmiştir. 3 normal görüntü HGG, 1 normal görüntü ise LGG bulunmuştur. ROC grafiğinde (Şekil 4.33b), HGG ve LGG sınıfının 0,999, normal sınıfın ise 0,998 AUC değerine sahip olduğu görülmektedir.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..33. ShuffleNet ağı (a) T1CE modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.34’de gösterilen T2 modalitesi doğruluk grafiğinde, ağın 226. iterasyondan sonra döngülerde %90 doğruluk değerine ulaştığı görülmektedir.




Şekil 4.34. ShuffleNet ağı T2 modalitesine ait beş döngünün doğruluk grafiği

Şekil 4.35'te verilen kayıp oranı grafiğinde ise 46. iterasyondan sonra 0.5 kayıp oranına düştüğü görülmektedir.



Şekil 4.35. ShuffleNet ağı T2 modalitesine ait beş döngünün kayıp oranı grafiği

Şekil 4.36a'da karmaşıklık matrisinde 3 HGG ve 1 LGG görüntüsü normal sınıfa, 1 normal sınıf görüntüsü ise HGG sınıfına ait olarak tahmin edilmiştir. ROC grafiğinde (Şekil 4.36b), tüm sınıfların AUC değeri 1 olarak bulunmuştur.



(a)

(b)


Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..36. ShuffleNet ağı (a) T2 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

4.1.4. SqueezeNet

Tez çalışması için yapılan denemelerin tümünde, en kısa süreye sahip olan SqueezeNet modeline ait, 3 sınıf çıkışlı sınıflandırmanın performans değerleri Çizelge 4.4'te verilmiştir. Performans kriterleri incelendiğinde, FLAIR modalitesinin tüm performans değerlerinin %99,45 üzerinde olduğu görülmektedir. T2 modalitesi doğruluk değeri %98,50, T1 modalitesi %97,23 ve T1CE modalitesi doğruluk değeri ise %95,10 bulunmuştur.


Çizelge 4.4. 3 sınıf çıkışlı SqueezeNet modelinde beş döngünün performans değerleri ve ortalamaları

Modalite	Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
FLAIR	1.Döngü	0,9932	0,9933	0,9967	0,9933	0,9933	00:02:26
	2.Döngü	0,9983	0,9983	0,9992	0,9983	0,9983	00:02:24
	3.Döngü	0,9969	0,9962	0,9983	0,9967	0,9965	00:02:25
	4.Döngü	0,9932	0,9934	0,9967	0,9933	0,9933	00:02:23
	5.Döngü	0,9915	0,9921	0,9959	0,9917	0,9918	00:02:23
	Ortalama	0,9946±(0,0028)	0,9946±(0,0025)	0,9973±(0,0013)	0,9946±(0,0027)	0,9946±(0,0026)	00:02:24
T1	1.Döngü	0,9561	0,9549	0,9775	0,9550	0,9555	00:02:23
	2.Döngü	0,9670	0,9668	0,9833	0,9667	0,9669	00:02:20
	3.Döngü	0,9820	0,9817	0,9907	0,9817	0,9819	00:02:21
	4.Döngü	0,9817	0,9815	0,9908	0,9817	0,9816	00:02:21
	5.Döngü	0,9764	0,9760	0,9884	0,9767	0,9762	00:02:28
	Ortalama	0,9726±(0,0110)	0,9721±(0,0114)	0,9861±(0,0056)	0,9723±(0,0114)	0,9724±(0,0112)	00:02:23
T1CE	1.Döngü	0,9582	0,9585	0,9793	0,9583	0,9584	00:02:23
	2.Döngü	0,9543	0,9530	0,9766	0,9533	0,9536	00:02:21
	3.Döngü	0,9418	0,9437	0,9710	0,9417	0,9427	00:02:21
	4.Döngü	0,9435	0,9423	0,9702	0,9400	0,9429	00:02:23
	5.Döngü	0,9607	0,9619	0,9812	0,9617	0,9613	00:02:28
	Ortalama	0,9516±(0,0085)	0,9518±(0,0087)	0,9756±(0,0048)	0,9510±(0,0097)	0,9517±(0,0086)	00:02:23
T2	1.Döngü	0,9951	0,9949	0,9975	0,9950	0,9950	00:02:23
	2.Döngü	0,9801	0,9801	0,9900	0,9800	0,9801	00:02:20
	3.Döngü	0,9769	0,9775	0,9883	0,9767	0,9772	00:02:21
	4.Döngü	0,9800	0,9801	0,9900	0,9800	0,9800	00:02:21
	5.Döngü	0,9930	0,9933	0,9967	0,9933	0,9932	00:02:24
	Ortalama	0,9850±(0,0083)	0,9851±(0,0082)	0,9925±(0,0042)	0,9850±(0,0084)	0,9851±(0,0083)	00:02:22




Şekil 4.37. SqueezeNet ağı FLAIR modalitesine ait beş döngünün doğruluk grafiği

FLAIR modalitesi doğruluk grafiğinde (Şekil 4.37), her döngünün doğruluk oranı birbirine yakındır. Şekil 4.38’de verilen kayıp oranı grafiğinde, döngülerin kayıp oranı 181. iterasyon sonrasında 0,5 altına düşmüştür.




Şekil 4.38. SqueezeNet ağı FLAIR modalitesine ait beş döngünün kayıp oranı grafiği

FLAIR modalitesi 5. döngü karmaşıklık matrisinde (Şekil 4.39a), 1 HGG görüntüsü LGG ve 1 HGG görüntüsü normal olarak tahmin edilmiştir. 2 LGG görüntüsünün HGG ve 1 LGG görüntüsünün normal sınıfına ait olduğu görülmüştür. ROC grafiğinde (Şekil 4.39b), sınıfların tümü için AUC değeri 1 bulunmuştur.




Şekil Hata! Belgede belirtilen stilde metne rastlanmadı..39. SqueezeNet ağı (a) FLAIR modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

T1 modalitesine ait Şekil 4.40'da verilen doğruluk grafiğinde, 586. iterasyon sonrası ağı kararlı hale geldiği görülmektedir.




Şekil 4.40. SqueezeNet ağı T1 modalitesine ait beş döngünün doğruluk grafiği

Şekil 4.41’de verilen kayıp oranı grafiğinde, eğitim başlangıcında 4. döngüde oran 5’in üzerindeyken 46. iterasyon sonrasında 1’in altına indiği görülmektedir.




Şekil 4.41. SqueezeNet ağı T1 modalitesine ait beş döngünün kayıp oranı grafiği

Şekil 4.42a’da verilen karmaşıklık matrisinde, 2 HGG görüntüsü LGG ve normal olarak, 3 LGG görüntüsü ise normal sınıfa ait olarak tahmin edilmiştir. 5 normal görüntü HGG olarak, 2 normal görüntü ise LGG olarak sınıflandırılmıştır. ROC grafiğinde (Şekil 4.42b), sırasıyla HGG, LGG ve normal sınıf AUC değerleri, 0,999, 0,998, 0,998 olarak bulunmuştur.




Şekil 4.42. SqueezeNet ağı (a) T1 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği




Şekil 4.43. SqueezeNet ağı T1CE modalitesi beş döngüye ait doğruluk grafiği

T1CE modalitesi doğruluk oranı grafiğinde (Şekil 4.43), 4. döngüde diğer döngülere göre düşük doğruluk oranı elde edilmiştir. Şekil 4.44’de verilen kayıp oranı grafiğinde ise 46. iterasyon sonrasında, kayıp oranının 1’in altına düştüğü görülmektedir.




Şekil 4.44. SqueezeNet ağı T1CE modalitesi beş döngüye ait kayıp oranı grafiği

Şekil 4.45a’da verilen karmaşıklık matrisinde, diğer modalitelere göre yanlış tahmin sayısı fazladır. 5. döngüde, 23 görüntünün yanlış tahmin edildiği görülmektedir. ROC grafiğinde (Şekil4.45b), HGG, LGG ve normal sınıf AUC değerleri sırasıyla 0,998, 0,999 ve 0,997 bulunmuştur.




Şekil 4.45. SqueezeNet ağı (a) T1CE modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

T2 modalitesi doğruluk grafiğinde, 316. iterasyonda döngülerin %90 üzerinde doğruluk sağladığı Şekil 4.46’da görülmektedir.




Şekil 4.46. SqueezeNet ağı T2 modalitesine ait beş döngünün doğruluk grafiği

T2 modalitesi kayıp oranı grafiği, Şekil 4.47’de verilmiştir. 46. iterasyona kadar olan süreçte kayıp oranı hızlıca düşmekte ve 226. iterasyon sonrası 0,5’in altına inmektedir.



Şekil 4.47. SqueezeNet ağı T2 modalitesine ait beş döngünün kayıp oranı grafiği

T2 modalitesi karmaşıklık matrisi (Şekil 4.48a) ve ROC grafiği (Şekil 4.48b) verilmiştir. 2 HGG görüntü normal olarak, 1 LGG ve 1 normal görüntü ise HGG olarak tahmin edilmiştir.




Şekil 4.48. SqueezeNet ağı (a) T2 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

4.1.5. Inception V3

InceptionV3 modelinin, 3 sınıf çıkışlı sınıflandırma performans değerleri Çizelge 4.5’te verilmiştir. FLAIR ve T2 modalitelerinde kesinlik, duyarlılık, özgüllük, doğruluk ve F1 puanı değerleri %99’un üzerinde bulunmuştur. Döngülerin ortalama eğitim süresi, yaklaşık 30 dk’dır. T1 modalitesi doğruluk oranı %98,90, T1CE modalitesi ise %98,30 olarak elde edilmiştir.


Çizelge 4.5. 3 sınıf çıkışlı InceptionV3 modelinde beş döngünün performans değerleri ve ortalamaları

Modalite	Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
FLAIR	1.Döngü	0,9952	0,9949	0,9975	0,9950	0,9950	00:26:09
	2.Döngü	0,9935	0,9934	0,9967	0,9933	0,9934	00:28:28
	3.Döngü	0,9984	0,9985	0,9991	0,9983	0,9984	00:28:48
	4.Döngü	1	1	1	1	1	00:29:25
	5.Döngü	1	1	1	1	1	00:29:17
	Ortalama	0,9974±(0,0029)	0,9973±(0,0030)	0,9986±(0,0015)	0,9973±(0,0030)	0,9973±(0,0029)	00:28:25
T1	1.Döngü	0,9966	0,9966	0,9984	0,9967	0,9966	00:26:03
	2.Döngü	0,9834	0,9833	0,9916	0,9833	0,9833	00:28:14
	3.Döngü	0,9862	0,9874	0,9934	0,9867	0,9868	00:28:26
	4.Döngü	0,9885	0,9883	0,9941	0,9883	0,9884	00:28:52
	5.Döngü	0,9894	0,9905	0,9952	0,9900	0,9900	00:29:22
	Ortalama	0,9888±(0,0049)	0,9892±(0,0048)	0,9945±(0,0024)	0,9890±(0,0049)	0,9890±(0,0048)	00:28:11
T1CE	1.Döngü	0,9900	0,9897	0,9950	0,9900	0,9899	00:26:01
	2.Döngü	0,9835	0,9834	0,9917	0,9833	0,9834	00:28:07
	3.Döngü	0,9738	0,9732	0,9865	0,9733	0,9735	00:28:32
	4.Döngü	0,9883	0,9887	0,9942	0,9883	0,9885	00:29:08
	5.Döngü	0,9793	0,9798	0,9902	0,9800	0,9795	00:29:07
	Ortalama	0,9829±(0,0066)	0,9829±(0,0067)	0,9915±(0,0034)	0,9830±(0,0067)	0,9829±(0,0066)	00:28:11
T2	1.Döngü	0,9916	0,9917	0,9959	0,9917	0,9917	00:26:06
	2.Döngü	0,9901	0,9900	0,9950	0,9900	0,9900	00:28:28
	3.Döngü	0,9887	0,9887	0,9941	0,9883	0,9887	00:28:39
	4.Döngü	1	1	1	1	1	00:29:17
	5.Döngü	0,9964	0,9968	0,9984	0,9967	0,9966	00:29:25
	Ortalama	0,9933±(0,0047)	0,9934±(0,0048)	0,9966±(0,0024)	0,9933±(0,0048)	0,9933±(0,0047)	00:28:23




Şekil 4.49. InceptionV3 ağı FLAIR modalitesine ait beş döngünün doğruluk grafiği

FLAIR modalitesi doğruluk grafiği (Şekil 4.49) ağ performansının yüksek olduğunu, kayıp oranı grafiği (Şekil 4.50) ise eğitim başlangıcında kayıp oranının 1,3'ün altında olduğunu göstermektedir.




Şekil 4.50. InceptionV3 ağı FLAIR modalitesine ait beş döngünün kayıp oranı grafiği

FLAIR modalitesi karmaşıklık matrisi (Şekil 4.51a) ve ROC grafiği (Şekil 4.51b), 5. döngüde yanlış tahmin yapılmadığını göstermektedir.




Şekil 4.51. InceptionV3 ağı (a) FLAIR modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.52.'de, T1 modalitesine ait doğruluk grafiği verilmiştir. 5. döngünün, diğer döngülere göre daha kısa sürede yüksek doğruluk değerine ulaştığı görülmektedir.




Şekil 4.52. InceptionV3 ağı T1 modalitesine ait beş döngünün doğruluk grafiği

Şekil 4.53'te T1 modalitesi kayıp oran grafiğinde, döngülerin kayıp oranı 1,2'nin altındadır.




Şekil 4.53. InceptionV3 ağı T1 modalitesine ait beş döngünün kayıp oranı grafiği

Şekil 4.54a'da gösterilen karmaşıklık matrisinde, 2 HGG ve 4 LGG görüntüsü normal sınıfa ait olarak tahmin edilmiştir. Şekil 4.54b'de ROC grafiği verilmiştir.




Şekil 4.54. InceptionV3 ağı (a) T1 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği




Şekil 4.55. InceptionV3 ağı T1CE modalitesine ait beş döngünün doğruluk grafiği

T1CE modalitesi, doğruluk grafiğinde (Şekil 4.55), tüm döngülerin 316. iterasyondan sonra %90 doğruluk değerinin üstünde olduğu, kayıp oran grafiğinde ise (Şekil 4.56) tüm döngülerin 1,2'in altında olduğu görülmektedir.




Şekil 4.56. InceptionV3 ağı T1CE modalitesine ait beş döngünün kayıp oranı grafiği

T1CE modalitesi karmaşıklık matrisinde (Şekil 4.57a), 5 HGG ve 3 LGG görüntü normal sınıfa ait, 4 normal görüntü ise 2 HGG ve 2 LGG olarak sınıflandırılmıştır. ROC grafiğinde (Şekil 4.57b), AUC değerleri HGG ve LGG için 0,999, normal sınıf için 0,997 bulunmuştur.




Şekil 4.57. InceptionV3 ağı (a) T1CE modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.58’de T2 modalitesi doğruluk grafiğinde, 316. iterasyondan sonra yüksek doğruluk oranı sağlandığı görülmektedir.




Şekil 4.58. InceptionV3 ağı T2 modalitesine ait beş döngünün doğruluk grafiği

Şekil 4.59’da 5 döngüye ait kayıp oran grafiği verilmiştir. Kayıp oranı 316. iterasyondan sonra 0,2’nin altına inmiştir.



Şekil 4.59. InceptionV3 ağı T2 modalitesine ait beş döngünün kayıp oranı grafiği

Şekil 4.60a’da verilen T2 modalitesi karmaşıklık matrisinde, 1 HGG ve 1 LGG görüntü normal MR görüntüsü olarak sınıflandırılmıştır. Şekil 4.60b’de ROC grafiğine yer verilmiştir.



(a)

(b)

Şekil 4.60. InceptionV3 ağı (a) T2 modalitesi 5. döngü karmaşıklık matrisi (b) ROC grafiği


4.2. 4 Sınıf Çıkışlı Sınıflandırma Sonuçları

4.2.1. AlexNet

AlexNet modelinin performans değerlerine bakıldığında (Çizelge 4.6), HGG ve LGG veri setlerinde %99'un üstünde performans sergilediği görülmektedir. Normal MR görüntülerinde ise ortalama %70,92 doğruluk değeri sağlanmaktadır. Normal sınıfa ait özgüllük değeri, gerçek negatif ve yanlış pozitif değerleri ile elde edildiğinden %90,35 olarak bulunmuştur.


Çizelge 4.6. 4 sınıf çıkışlı AlexNet modelinde beş döngünün performans değerleri ve ortalamaları

Derece	Ağ	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
HGG	1.Döngü	0,9977	0,9977	0,9991	0,9975	0,9977	00:03:47
	2.Döngü	0,9967	0,9959	0,9987	0,9963	0,9963	00:03:42
	3.Döngü	0,9923	0,9923	0,9975	0,9925	0,9923	00:03:43
	4.Döngü	0,9943	0,9954	0,9984	0,9950	0,9948	00:03:45
	5.Döngü	0,9961	0,9962	0,9988	0,9963	0,9962	00:03:48
	Ortalama	0,9954±(0,0022)	0,9955±(0,0020)	0,9985±(0,0006)	0,9955±(0,0019)	0,9955±(0,0020)	00:03:45
LGG	1.Döngü	0,99517	0,9942197	0,998319885	0,995	0,994695	00:03:49
	2.Döngü	0,99489	0,9945355	0,998351806	0,995	0,994713	00:03:46
	3.Döngü	0,997433	0,99757	0,999174837	0,9975	0,997502	00:03:46
	4.Döngü	0,995516	0,9955357	0,99827883	0,995	0,995526	00:03:51
	5.Döngü	0,997471	0,9975105	0,999169996	0,9975	0,997491	00:03:49
	Ortalama	0,9961±(0,0013)	0,9959±(0,0016)	0,9987±(0,0005)	0,9960±(0,0014)	0,9960±(0,0014)	00:03:48
NORMAL	1.Döngü	0,6067	0,7240	0,9095	0,7175	0,6602	00:04:12
	2.Döngü	0,6415	0,7280	0,9160	0,7413	0,6820	00:03:42
	3.Döngü	0,6516	0,7286	0,9097	0,7288	0,6880	00:03:42
	4.Döngü	0,6728	0,7047	0,8874	0,6750	0,6884	00:03:48
	5.Döngü	0,6792	0,6923	0,8951	0,6838	0,6857	00:03:49
	Ortalama	0,6503±(0,0287)	0,7155±(0,0162)	0,9035±(0,0118)	0,7092±(0,0287)	0,6808±(0,0118)	00:03:51




Şekil 4.61. AlexNet ağı HGG derecesine ait beş döngünün doğruluk grafiği

4 sınıf çıkışlı sınıflandırmada, doğruluk ve kayıp oranı grafikleri iterasyon değer aralığı 60 olarak çizdirilmiştir. Şekil 4.61’de AlexNet ağına, HGG derecesindeki verilerin doğruluk oran grafiği ve Şekil 4.62’de kayıp oranı grafiği verilmiştir.




Şekil 4.62. AlexNet ağı HGG derecesine ait beş döngünün kayıp oranı grafiği

HGG derecesinde 5. döngüye ait karmaşıklık matrisinde (Şekil 4.63a), 1 T1CE verisi ile 2 T2 verisi, T1 olarak tahmin edilmiş ve ROC grafiğinde (Şekil 4.63b), sınıfların AUC değerleri 1 olarak bulunmuştur.




Şekil 4.63. AlexNet ağı (a) HGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

AlexNet ağında, LGG veri seti ile yapılan eğitimlerin doğruluk grafiği Şekil 4.64'te verilmiştir. 121. iterasyondan sonra, tüm döngülerin %90 doğruluk oranının üstünde olduğu görülmektedir.




Şekil 4.64. AlexNet ağı LGG derecesine ait beş döngünün doğruluk grafiği

Kayıp oranı grafiğinde (Şekil 4.65) görüldüğü üzere, 61. iterasyon sırasında kayıp oranı 1'in altındadır.




Şekil 4.65. AlexNet ağı LGG derecesine ait beş döngünün kayıp oranı grafiği

Karmaşıklık matrisinde (Şekil 4.66a), 1 T1 verisi FLAIR olarak, 1 T1CE verisi ise T1 olarak tahmin edilmiştir. ROC grafiğinde (Şekil 4.66b), AUC değeri 4 sınıf için de 1 olarak bulunmuştur.




Şekil 4.66. AlexNet ağı (a) LGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Normal MR görüntüsü ile yapılan testlerin performans değerlerinin düşük olması, doğruluk grafiğine yansımaktadır. Şekil 4.67’de verilen beş döngünün de doğruluk değeri %85’in altındadır.




Şekil 4.67. AlexNet ağı normal sınıfa ait beş döngünün doğruluk grafiği

Şekil 4.68’de verilen normal MR görüntülerinin kayıp oran grafiğinde, 61. iterasyondan sonra, oranların birbirine yakın değerlerde olduğu görülmektedir.



Şekil 4.68. AlexNet ağı normal sınıfa ait beş döngünün kayıp oranı grafiği

Karmaşıklık matrisinde (Şekil 4.69a), T1 sınıfına ait görüntülerin T1CE, T1CE sınıfına ait görüntülerin T1 olarak tahmin edildiği görülmektedir. 1 adet T2 görüntüsü ise T1 olarak sınıflandırılmıştır. ROC grafinde (Şekil 4.69b), AUC değerinin T1 için 0,754 ve T1CE modalitesi için 0.774 olduğu görülmektedir. Sınıflandırma tahmini T1 ve T1CE modalitesinde düşük olduğu için AUC değerleri değişim çizgisine yaklaşmıştır.



Şekil 4.69. AlexNet ağı (a) normal sınıfı 5. döngü karmaşıklık matrisi (b) ROC grafiği


4.2.2. GoogleNet

GoogleNet modelinde, elde edilen 4 sınıf çıkışlı performans değerleri ve eğitim süreleri Çizelge 4.7’de verilmiştir. HGG ve LGG verilerinin sınıflandırma performansı %99’un, normal MR görüntüleri performans değerlerinin ise %65’in üzerinde olduğu görülmektedir. Döngülerin ortalama eğitim süresi yaklaşık 8 dk’dır.

Çizelge 4.7. 4 sınıf çıkışlı GoogleNet modelinde beş döngünün performans değerleri ve ortalamaları


Derece	Ağ	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
HGG	1.Döngü	0,9962	0,9966	0,9987	0,9963	0,9964	00:07:56
	2.Döngü	0,9883	0,9898	0,9963	0,9888	0,9891	00:08:00
	3.Döngü	0,9896	0,9898	0,9967	0,9900	0,9897	00:07:59
	4.Döngü	0,9896	0,9899	0,9967	0,9900	0,9897	00:08:04
	5.Döngü	0,9936	0,9937	0,9979	0,9938	0,9936	00:08:07
	Ortalama	0,9915±(0.0033)	0,9920±(0.0031)	0,9973±(0.0010)	0,9918±(0.0031)	0,9917±(0.0059)	00:08:01
LGG	1.Döngü	0,9950	0,9945	0,9983	0,9950	0,9947	00:07:47
	2.Döngü	0,9906	0,9907	0,9972	0,9913	0,9907	00:07:54
	3.Döngü	0,9950	0,9950	0,9983	0,9950	0,9950	00:07:57
	4.Döngü	0,9964	0,9966	0,9987	0,9963	0,9965	00:08:00
	5.Döngü	0,9975	0,9976	0,9992	0,9975	0,9975	00:08:09
	Ortalama	0,9949±(0,0026)	0,9949±(0,0026)	0,9983±(0,0005)	0,9950±(0,0023)	0,9949±(0,0026)	00:07:57
NORMAL	1.Döngü	0,6508	0,6523	0,8909	0,6663	0,6516	00:07:57
	2.Döngü	0,6510	0,6593	0,8957	0,6800	0,6551	00:07:58
	3.Döngü	0,6633	0,6678	0,8897	0,6688	0,6655	00:08:01
	4.Döngü	0,6420	0,7061	0,8871	0,6725	0,6725	00:08:03
	5.Döngü	0,6611	0,6608	0,8860	0,6588	0,6610	00:08:08
	Ortalama	0,6536±(0,0086)	0,6692±(0,0213)	0,8898±(0,0038)	0,6692±(0,0078)	0,6611±(0,0083)	00:08:01

Şekil 4.70’te, GoogleNet ağ modeline ait doğruluk grafiği verilmiştir. Ağın yüksek performans göstererek döngülerin kısa bir sürede %100 doğruluğa yaklaştığı görülmektedir.




Şekil 4.70. GoogleNet ağı HGG derecesine ait beş döngünün doğruluk grafiği

Şekil 4.71’de verilen kayıp oran grafiğinde, ağın 121. iterasyondan sonra kararlı bir hale geçtiği görülmektedir.




Şekil 4.71. GoogleNet ağı HGG derecesine ait beş döngünün kayıp oranı grafiği

HGG dereceli görüntülerde, 5. döngüye ait karmaşıklık matrisinde (Şekil 4.72a), toplamda 5 adet hatalı sınıflandırma tahmini bulunmaktadır. Şekil 4.72b’de ROC grafiğinde, dört sınıfa ait AUC değerinin de 1 olduğu görülmektedir.




Şekil 4.72. GoogleNet ağı (a) HGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.73’te verilen doğruluk grafiğinde, 4. döngünün doğruluk değerinin başlangıçta diğer döngülerden düşük olduğu görülmektedir.




Şekil 4.73. GoogleNet ağı HGG derecesine ait beş döngünün doğruluk grafiği

Şekil 4.74'te LGG dereceli görüntülerin kayıp oran grafiğinde, 4. döngünün başlangıçta 5,7 olan kayıp oranının, 181. iterasyon itibariyle diğer döngülerle aynı seviyeye ulaştığı görülmektedir.




Şekil 4.74. GoogleNet ağı LGG derecesine ait beş döngünün kayıp oranı grafiği

Şekil 4.75a'da verilen karmaşıklık matrisinde, FLAIR modalitesinde 1 görüntü T1, T1CE modalitesinde 1 görüntü ise FLAIR olarak tahmin edilmiştir. Şekil 4.75b'de verilen ROC grafiği, tüm AUC değerinin 1 olduğunu göstermektedir.




Şekil 4.75. GoogleNet ağı (a) LGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Normal MR görüntülerinin doğruluk grafiği Şekil 4.76’da verilmiştir. Doğruluk grafiğinde 5 döngünün doğruluk değeri de %80’in altında olduğu görülmektedir.




Şekil 4.76. GoogleNet ağı normal sınıfa ait beş döngünün doğruluk grafiği

Şekil 4.77’de verilen kayıp oran grafiğinde ise 61. iterasyondan sonra kayıp oranı 0,5’in altına düşmüştür.



Şekil 4.77. GoogleNet ağı normal sınıfa ait beş döngünün kayıp oranı grafiği

Karmaşıklık matrisinde (Şekil 4.78a) gösterildiği üzere, 132 görüntü T1CE olarak, 141 görüntü ise T1 modalitesi olarak yanlış sınıflandırılmıştır. ROC grafiğinde (Şekil 4.78b), T1 ve T1CE modalitesi AUC değerleri düşük bulunmuştur.




Şekil 4.78. GoogleNet ağı (a) normal sınıfa ait 5. döngü karmaşıklık matrisi (b) ROC grafiği

4.2.3. ShuffleNet

ShuffleNet modeli performans deęerleri ve eęitim süresi Çizelge 4.8’de verilmiştir. AlexNet ve GoogleNet sonuçlarına benzer şekilde, HGG ve LGG sınıflandırması %99’un üstünde performans gösterirken, normal MR görüntüleri ise %59,62 ile düşük bir performans sergilemiştir. ShuffleNet modelinde eęitim her döngü için ortalama 18 dakikada gerçekleşmiştir.


Çizelge 4.8. 4 sınıf çıkışlı ShuffleNet modelinde beş döngünün performans deęerleri ve ortalamaları

Derece	Aę	Kesinlik	Duyarlılık	Özgüllük	Doęruluk	F1-Puanı	Eęitim Süresi (sa:dk:s)
HGG	1.Döngü	0,9977	0,9977	0,9991	0,9975	0,9977	00:17:36
	2.Döngü	0,9897	0,9906	0,9967	0,9900	0,9902	00:18:03
	3.Döngü	0,9871	0,9873	0,9959	0,9875	0,9872	00:18:10
	4.Döngü	0,9899	0,9892	0,9967	0,9900	0,9896	00:18:21
	5.Döngü	0,9948	0,9948	0,9984	0,9950	0,9948	00:18:28
	Ortalama	0,9918±(0,0043)	0,9919±(0,0042)	0,9973±(0,0013)	0,9920±(0,0041)	0,9919±(0,0042)	00:18:08
LGG	1.Döngü	0,9834	0,9823	0,9946	0,9838	0,9828	00:17:24
	2.Döngü	0,9908	0,9907	0,9971	0,9913	0,9907	00:18:01
	3.Döngü	0,9962	0,9962	0,9988	0,9963	0,9962	00:18:07
	4.Döngü	0,9932	0,9931	0,9974	0,9925	0,9932	00:18:19
	5.Döngü	0,9900	0,9900	0,9967	0,9900	0,9900	00:18:30
	Ortalama	0,9908±(0,0048)	0,9905±(0,0052)	0,9969±(0,0015)	0,9908±(0,0046)	0,9906±(0,0050)	00:18:04
NORMAL	1.Döngü	0,5822	0,5813	0,8700	0,6038	0,5818	00:17:29
	2.Döngü	0,5762	0,5818	0,8727	0,6100	0,5790	00:18:04
	3.Döngü	0,5701	0,5714	0,8576	0,5725	0,5708	00:18:12
	4.Döngü	0,5921	0,6034	0,8480	0,5600	0,5977	00:18:21
	5.Döngü	0,5941	0,6456	0,8790	0,6350	0,6188	00:18:36
	Ortalama	0,5829±(0,0102)	0,5967±(0,0297)	0,8654±(0,0124)	0,5962±(0,0301)	0,5896±(0,0190)	00:18:08




Şekil 4.79. ShuffleNet ağı HGG derecesine ait beş döngünün doğruluk grafiği

Şekil 4.79’da verilen doğruluk grafiğinde, 181. iterasyon sonrasında ağın yüksek doğruluk değerine ulaştığı görülmüştür. Şekil 4.80’de verilen kayıp oran grafiğinde ise tüm döngülerin 2,5’in altında bir orana sahip olduğu ve 181. iterasyon sonrasında 0’a yaklaştığı görülmektedir.




Şekil 4.80. ShuffleNet ağı HGG derecesine ait beş döngünün kayıp oranı grafiği

Şekil 4.81a’da verilen karmaşıklık matrisinde, 4 hatalı tahmin yapılmış ve ROC grafiği(Şekil 4.81b) AUC değerleri tüm modalitelerde 1 bulunmuştur.




Şekil 4.81. ShuffleNet ağı (a) HGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

LGG derecesine ait MR görüntülerinin doğruluk grafiğinde (Şekil 4.82), tüm döngüler 421. iterasyon sonrası yaklaşık %100 doğruluğa ulaşmaktadır.




Şekil 4.82. ShuffleNet ağı LGG derecesine ait beş döngünün doğruluk grafiği

Kayıp oranı grafiğinde (Şekil 4.83), döngülerin sınıflandırma başarısının birbirine yakın olduğu görülmektedir.




Şekil 4.83. ShuffleNet ağı LGG derecesine ait beş döngünün kayıp oranı grafiği

LGG derecesine ait karmaşıklık matrisinde (Şekil 4.84a), 4 T1 ve 4 T1CE görüntüsü yanlış tahmin edilmiştir. ROC grafiğinde (Şekil 4.84b), T1 modalitesi AUC değeri 0,999 ile diğer AUC değerlerinden düşüktür.




Şekil 4.84. ShuffleNet ağı (a) LGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.85'te verilen doğruluk grafiğinde, doğruluk oranı beş döngü için de yaklaşık %80'dir.




Şekil 4.85. ShuffleNet ağı normal sınıfa ait beş döngünün doğruluk grafiği

Şekil 4.86'da ShuffleNet ağı normal sınıfın kayıp oran grafiği verilmiştir. 181. iterasyon sonrasında kayıp oranı 0,5 değerine düşmüştür.



Şekil 4.86. ShuffleNet ağı normal sınıfa ait beş döngünün kayıp oranı grafiği

Şekil 4.87a’da, 5. döngüye ait karmaşıklık matrisi, Şekil 4.87b’de ROC grafiği verilmiştir. 210 T1CE verisi T1 olarak, 81 T1 verisi T1CE olarak tahmin edilmiştir. Bunun yanı sıra 3 T1CE verisi normal, 1 T2 verisi ise T1 olarak sınıflandırılmıştır. ROC grafiğinde, AUC değerleri T1 ve T1CE modalitesi için sırasıyla 0,678, 0,702 olarak bulunmuştur.



Şekil 4.87. ShuffleNet ağı (a) normal sınıfa ait 5. döngü karmaşıklık matrisi (b) ROC grafiği


4.2.4. SqueezeNet

SqueezeNet modeline ait beş döngünün performans değerleri ve eğitim süreleri Çizelge 4.9’da verilmiştir. SqueezeNet en düşük eğitim süresine sahip olmasına rağmen HGG ve LGG derecelerinde %99’un üzerinde doğruluk, kesinlik, duyarlılık, özgüllük ve F1 puanı performans değerleri elde etmiştir. Normal MR görüntülerinde ise özgüllük değeri haricinde yüksek performans gösterememiştir. Özgüllük değeri, TN değerlerinin yanlış tahmin sonucu yüksek olmasından kaynaklanmaktadır.

Çizelge 4.9. 4 sınıf çıkışlı SqueezeNet modelinde beş döngünün performans değerleri ve ortalamaları


Derece	Ağ	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
HGG	1.Döngü	0,9963	0,9960	0,9987	0,9963	0,9962	00:03:29
	2.Döngü	0,9882	0,9898	0,9963	0,9888	0,9890	00:03:20
	3.Döngü	0,9871	0,9873	0,9959	0,9875	0,9872	00:03:15
	4.Döngü	0,9885	0,9886	0,9963	0,9888	0,9885	00:03:16
	5.Döngü	0,9909	0,9914	0,9971	0,9913	0,9912	00:03:17
	Ortalama	0,9902±(0,0037)	0,9906±(0,0034)	0,9969±(0,0011)	0,9905±(0,0035)	0,9904±(0,0035)	00:03:19
LGG	1.Döngü	0,9986	0,9988	0,9996	0,9988	0,9987	00:03:17
	2.Döngü	0,9817	0,9795	0,9938	0,9813	0,9806	00:03:14
	3.Döngü	0,9927	0,9925	0,9975	0,9925	0,9926	00:03:15
	4.Döngü	0,9933	0,9933	0,9974	0,9925	0,9933	00:03:16
	5.Döngü	0,9923	0,9928	0,9975	0,9925	0,9926	00:03:17
	Ortalama	0,9917±(0,0062)	0,9914±(0,0071)	0,9972±(0,0021)	0,9915±(0,0063)	0,9915±(0,0066)	00:03:16
NORMAL	1.Döngü	0,6778	0,7341	0,9215	0,7663	0,7048	00:03:17
	2.Döngü	0,6549	0,7030	0,9086	0,7188	0,6781	00:03:15
	3.Döngü	0,6810	0,7198	0,9068	0,7200	0,6999	00:03:15
	4.Döngü	0,6896	0,7021	0,8857	0,6688	0,6958	00:03:22
	5.Döngü	0,6659	0,6854	0,8926	0,6763	0,6755	00:03:19
	Ortalama	0,6738±(0,0135)	0,7088±(0,0186)	0,9030±(0,0140)	0,7100±(0,0393)	0,6908±(0,0132)	00:03:18

SqueezeNet ağında HGG derecesindeki MR görüntülerinin doğruluk grafiği Şekil 4.88’de verilmekte ve doğruluk oranının yüksek olduğu görülmektedir.




Şekil 4.88. SqueezeNet ağı HGG derecesine ait beş döngünün doğruluk grafiği

Kayıp oranı grafiği ise Şekil 4.89’da verilmiştir. 2. döngünün kayıp oranı, başlangıçta yaklaşık 8 iken 61. iterasyon sonrası 1’in altına düşmektedir.




Şekil 4.89. SqueezeNet ağı HGG derecesine ait beş döngünün kayıp oranı grafiği

HGG dereceli MR görüntülerinin 5. döngüye ait karmaşıklık matrisi (Şekil 4.90a) ve ROC grafiği (Şekil 4.90b) verilmiştir. Karmaşıklık matrisinde 2 T1 verisi T2 olarak, 4 T1CE ve 1 T2 verisi T1 olarak tahmin edilmiştir.




Şekil 4.90. SqueezeNet ağı (a) HGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

LGG dereceli MR görüntülerinin sınıflandırılmasına ait 5 döngünün doğruluk grafiği Şekil 4.91’de verilmiştir. 181. iterasyondan sonra 5 döngünün de doğruluk değeri %90’ın üzerindedir.




Şekil 4.91. SqueezeNet ağı LGG derecesine ait beş döngünün doğruluk grafiği

SqueezeNet modelinin LGG sınıflandırmasında, 2. döngüye ait kayıp oranı yaklaşık 5 ile başlarken 61. iterasyondan sonra azalmaktadır. 5 döngüye ait kayıp oranı grafiği, Şekil 4.92’de verilmiştir.



Şekil 4.92. SqueezeNet ağı LGG derecesine ait beş döngünün kayıp oranı grafiği

Şekil 4.93a’da verilen karmaşıklık matrisinde, 1 T1 verisi FLAIR, 5 T1CE verisi T1 olarak yanlış tahmin edilmiştir. Şekil 4.93b’de ROC grafiği verilmiştir.




(a)

(b)


Şekil 4.93. SqueezeNet ağı (a) LGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.94'te verilen SqueezeNet ağı normal MR görüntülerinin doğruluk grafiğinde, performansın düşük olduğu ve ağın kararlı bir seviyeye ulaşmadığı görülmektedir.




Şekil 4.94. SqueezeNet ağı normal sınıfa ait beş döngünün doğruluk grafiği

Normal MR görüntülerinin kayıp oranı grafiği Şekil 4.95'te verilmiştir. 2. döngü en çok kayıp değerine sahipken 61. iterasyon sonrasında diğer döngülerle eşit seviyeye ulaşmıştır.



Şekil 4.95. SqueezeNet ağı normal sınıfa ait beş döngünün kayıp oranı grafiği

Normal MR görüntülerinin karmaşıklık matrisi Şekil 4.96a'da ve ROC grafiği Şekil 4.96b'de verilmiştir. 75 T1 verisi T1CE olarak, 184 T1CE verisi ise T1 olarak sınıflandırılmıştır. T1 ve T1CE modaliteleri, normal MR görüntülerinde düşük doğrulukla sınıflandırılmaktadır.



Şekil 4.96. SqueezeNet ağı (a) normal sınıfa ait 5. döngü karmaşıklık matrisi (b) ROC grafiği


4.2.5. Inception V3

Çizelge 4.10’da 4 sınıf çıkışlı sınıflandırmada, InceptionV3 ağı performans değerleri ve eğitim süreleri verilmiştir. Diğer dört derin öğrenme modelindeki eğitim süreleri, InceptionV3 eğitim süresinden oldukça kısadır. Eğitim süresinin çok uzun olmasına rağmen performans değerleri birbirine çok yakındır.

Çizelge 4.10. 4 sınıf çıkışlı InceptionV3 modelinde beş döngünün performans değerleri ve ortalamaları


Derece	Ağ	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
HGG	1.Döngü	0,9977	0,9977	0,9991	0,9975	0,9977	00:35:50
	2.Döngü	0,9883	0,9898	0,9963	0,9888	0,9891	00:39:41
	3.Döngü	0,9871	0,9873	0,9959	0,9875	0,9872	00:38:52
	4.Döngü	0,9896	0,9896	0,9967	0,9900	0,9896	00:39:47
	5.Döngü	0,9948	0,9948	0,9984	0,9950	0,9948	00:39:27
	Ortalama	0,9915±(0,0045)	0,9918±(0,0043)	0,9973±(0,0014)	0,9918±(0,0043)	0,9916±(0,0044)	00:38:43
LGG	1.Döngü	0,9935	0,9933	0,9979	0,9938	0,9934	00:35:45
	2.Döngü	0,9974	0,9973	0,9992	0,9975	0,9974	00:38:37
	3.Döngü	0,9988	0,9987	0,9996	0,9988	0,9987	00:38:11
	4.Döngü	0,9966	0,9967	0,9987	0,9963	0,9966	00:40:05
	5.Döngü	0,9974	0,9977	0,9992	0,9975	0,9975	00:39:36
	Ortalama	0,9967±(0,0020)	0,9967±(0,0021)	0,9989±(0,0006)	0,9968±(0,0019)	0,9967±(0,0020)	00:38:27
NORMAL	1.Döngü	0,5643	0,5679	0,8647	0,5863	0,5661	00:36:11
	2.Döngü	0,5793	0,5980	0,8770	0,6225	0,5885	00:43:32
	3.Döngü	0,5669	0,5690	0,8568	0,5700	0,5679	00:41:53
	4.Döngü	0,5922	0,6174	0,8538	0,5775	0,6045	00:38:44
	5.Döngü	0,5770	0,6114	0,8679	0,6025	0,5937	00:39:12
	Ortalama	0,5759±(0,0111)	0,5927±(0,0232)	0,8640±(0,0092)	0,5917±(0,0210)	0,5841±(0,0166)	00:39:54

HGG derecesindeki MR görüntüleri doğruluk grafiğinde (Şekil 4.97), 61. iterasyon sonrası tüm döngülerde maksimum doğruluk değerine yaklaşılmıştır.




Şekil 4.97. InceptionV3 ağı HGG derecesine ait beş döngünün doğruluk grafiği

Şekil 4.98’de verilen kayıp oranı grafiğinde, 181. iterasyon sonrasında beş döngüde de kayıp oranının 0’a yaklaştığı görülmektedir.




Şekil 4.98. InceptionV3 ağı HGG derecesine ait beş döngünün kayıp oranı grafiği

Şekil 4.99a’da verilen karmaşıklık matrisinde, 3 T1 verisi T2 olarak, 1 T2 verisi ise T1 olarak yanlış tahmin edilmiştir. Şekil 4.99b’de ROC grafiği verilmiştir.




Şekil 4.99. InceptionV3 ağı (a) HGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.100’de, LGG dereceli MR görüntülerinin doğruluk grafiğinde, eğitimin yüksek performansla gerçekleştiği görülmektedir.




Şekil 4.100. InceptionV3 ağı LGG derecesine ait beş döngünün doğruluk grafiği

Şekil 4.101’de verilen kayıp oranı grafiğinde, 481. iterasyon sonrasında tüm döngülerde kayıp oranının 0’a yaklaştığı görülmektedir.




Şekil 4.101. InceptionV3 ağı LGG derecesine ait beş döngünün kayıp oranı grafiği

Şekil 4.102a’da gösterilen karmaşıklık matrisinde, 2 T1CE verisinin T1 olarak yanlış sınıflandırılmasının dışında hata bulunmamaktadır. Şekil 4.102’deki ROC grafiğinde, AUC değerleri maksimum sonucu vermektedir.




Şekil 4.102. InceptionV3 ağı (a) LGG derecesi 5. döngü karmaşıklık matrisi (b) ROC grafiği

Şekil 4.103'te, normal MR görüntülerinin sınıflandırıldığı doğruluk grafiği verilmiştir. Grafikte, ağıın doğruluk performansının düşük olduğu görülmektedir.




Şekil 4.103. InceptionV3 ağı normal sınıfa ait beş döngünün doğruluk grafiği

Şekil 4.104'te normal MR görüntülerinin kayıp oranı grafiği verilmiştir. Ağıın performansı düşük olduğu için kayıp oranı 0 'a yaklaşmamıştır.



Şekil 4.104. InceptionV3 ağı normal sınıfa ait beş döngünün kayıp oranı grafiği

Karmaşıklık matrisinde (Şekil 4.105a), T1 ve T1CE sınıflarının yanlış tahmin edilmesi SqueezeNet modelinde de gerçekleşmiştir. Şekil 4.105b’de verilen ROC grafiğinde T1 ve T1CE modalitelerinde düşük AUC değeri göze çarpmaktadır.



Şekil 4.105. InceptionV3 ağı (a) normal sınıfa ait 5. döngü karmaşıklık matrisi (b) ROC grafiği


4.3. 12 Sınıf Çıkışlı Sınıflandırma Sonuçları

4.3.1. AlexNet

Çizelge 4.11, AlexNet modeli ile yapılan eğitim sonucunda elde edilen performans değerlerini ve eğitim sürelerini vermektedir. AlexNet modelinin, tüm performans kriterleri %98’in üzerinde bir değerle yüksek başarı sağlamıştır. Döngülerin eğitim yaklaşık 15 dk sürmüştür.


Çizelge 4.11. 12 sınıf çıkışlı AlexNet modelinde beş döngünün performans değerleri ve ortalamaları

Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
1.Döngü	0,9819	0,9821	0,9983	0,9817	0,9820	00:14:40
2.Döngü	0,9846	0,9845	0,9985	0,9842	0,9846	00:14:34
3.Döngü	0,9799	0,9798	0,9981	0,9796	0,9799	00:14:40
4.Döngü	0,9863	0,9858	0,9987	0,9863	0,9861	00:14:49
5.Döngü	0,9888	0,9884	0,9990	0,9888	0,9886	00:14:46
Ortalama	0,9843±(0,0035)	0,9841±(0,0033)	0,9985±(0,0003)	0,9840±(0,0036)	0,9842±(0,0034)	00:14:42




Şekil 4.106. AlexNet ağına ait beş döngünün doğruluk grafiği

12 sınıf çıkışlı sınıflandırmaya ait doğruluk ve kayıp oranı grafikleri sırasıyla Şekil 4.106'da ve Şekil 4.107'de verilmiştir. Grafiklerde iterasyon değer aralığı 180 olarak alınmıştır. İterasyon değer aralığının sınıflandırmalarda farklı olması, tüm grafiklerin 25 iterasyon sayısı ile gösterilmesini sağlamaktır.



Şekil 4.107. AlexNet ağına ait beş döngünün kayıp oranı grafiği

Karmaşıklık matrisinde (Şekil 4.108a), 2400 görüntüden 27 tanesi yanlış tahmin edilmiştir. ROC grafiğinde (Şekil 4.108b), 12 sınıfa ait AUC değerleri verilmiştir.




Şekil 4.108. AlexNet ağı (a) 5. döngü karmaşıklık matrisi (b) ROC grafiği

4.3.2. GoogleNet

GoogleNet modelinin 12 sınıf çıkışlı sınıflandırılmasına ait performans değerleri ve eğitim süreleri Çizelge 4.12’de verilmiştir. Döngülerin eğitim süresi yaklaşık 29 dk’dır. %97,19 doğruluk, %97,22 kesinlik, %97,19 duyarlılık, %99,74 özgüllük ve %97,20 F1 puanı ortalama performans kriterleridir.


Çizelge 4.12. 12 sınıf çıkışlı GoogleNet modelinde beş döngünün performans değerleri ve ortalamaları

Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
1.Döngü	0,9818	0,9815	0,9983	0,9813	0,9816	00:28:01
2.Döngü	0,9770	0,9771	0,9979	0,9767	0,9771	00:28:13
3.Döngü	0,9610	0,9612	0,9964	0,9604	0,9611	00:28:29
4.Döngü	0,9702	0,9701	0,9973	0,9708	0,9702	00:28:38
5.Döngü	0,9710	0,9700	0,9973	0,9704	0,9705	00:28:46
Ortalama	0,9722±(0,0078)	0,9719±(0,0077)	0,9974±(0,0007)	0,9719±(0,0078)	0,9720±(0,0077)	00:28:25




Şekil 4.109. GoogleNet ağına ait beş döngünün doğruluk grafiği

Doğruluk grafiği Şekil 4.109’da verilen GoogleNet ağına ait, 2161. iterasyon sonrası doğruluk oranının %90’ın üzerine çıktığı görülmektedir. Kayıp oranı grafiğinde (Şekil 4.110), 541. iterasyon sonrasında kayıp oranı 1’in altına inmiştir.



Şekil 4.110. GoogleNet ağına ait beş döngünün kayıp oranı grafiği

GoogleNet ağında 5. döngüye ait karmaşıklık matrisi Şekil 4.111a’da verilmiştir. T2 modalitesine ait verilerin tamamı doğru tahmin edilmiştir. T1CE modalitesinde yanlış tahmin edilen görüntüler diğer sınıflara göre daha fazladır. ROC grafiğinde (Şekil 4.111b), T1CE modalitesi HGG, LGG ve normal sınıfı AUC değerleri 0,999 bulunurken diğer sınıfların AUC değerleri 1 olarak bulunmuştur.




Şekil 4.111. GoogleNet ağı (a) 5. döngü karmaşıklık matrisi (b) ROC grafiği

4.3.3. ShuffleNet

ShuffleNet ağ modelinde, performans değerleri ve eğitim süreleri verilen Çizelge 4.13’te görüldüğü üzere GoogleNet modeline çok yakın değerler elde edilmiştir. %97,10 doğruluk değeri ve 1 saat eğitim süresi ortalamasına sahiptir.


Çizelge 4.13. 12 sınıf çıkışlı ShuffleNet modelinde beş döngünün performans değerleri ve ortalamaları

Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
1.Döngü	0,9753	0,9758	0,9977	0,9750	0,9755	00:57:50
2.Döngü	0,9725	0,9725	0,9974	0,9721	0,9725	01:00:30
3.Döngü	0,9716	0,9719	0,9974	0,9713	0,9717	01:00:41
4.Döngü	0,9655	0,9650	0,9969	0,9658	0,9652	01:01:11
5.Döngü	0,9715	0,9702	0,9974	0,9713	0,9709	01:01:38
Ortalama	0,9712±(0,0036)	0,9710±(0,0039)	0,9973±(0,0003)	0,9710±(0,0033)	0,9711±(0,0037)	01:00:22




Şekil 4.112. ShuffleNet ağına ait beş döngünün doğruluk grafiği

Şekil 4.112’de verilen doğruluk grafiği, ağın 181. iterasyon sonrası performansının arttığını ve Şekil 4.113’te verilen kayıp oran grafiği ise kayıp oranının 1’in altına indiğini göstermektedir.



Şekil 4.113. ShuffleNet ağına ait beş döngünün kayıp oranı grafiği

Karmaşıklık matrisinde (Şekil 4.114a), en fazla yanlış tahmin 8 FLAIR-LGG görüntüsünün T1-LGG görüntüsü olarak ve 8 T1CE-Normal görüntüsünün T1CE-HGG olarak sınıflandırılmasıdır. ROC grafiğinde (Şekil 4.114b), T1-HGG, T1-LGG ile T1CE-Normal sınıfları 0,999 AUC değerine diğer sınıflar ise 1 AUC değerine sahiptir.




Şekil 4.114. ShuffleNet ağı (a) 5. döngü karmaşıklık matrisi (b) ROC grafiği

4.3.4. SqueezeNet

Çizelge 4.14'te SqueezeNet modeli performans değerleri ve eğitim süreleri verilmiştir. Ortalama doğruluk değeri %96,61 olan ağın, ortalama eğitim süresi yaklaşık 13 dk'dır. Performans değerleri diğer ağlara nispeten daha düşük bulunmuştur.


Çizelge 4.14. 12 sınıf çıkışlı SqueezeNet modelinde beş döngünün performans değerleri ve ortalamaları

Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
1.Döngü	0,9673	0,9673	0,9969	0,9667	0,9673	00:12:30
2.Döngü	0,9647	0,9635	0,9966	0,9633	0,9641	00:12:23
3.Döngü	0,9631	0,9615	0,9964	0,9608	0,9623	00:12:27
4.Döngü	0,9691	0,9674	0,9971	0,9688	0,9683	00:12:32
5.Döngü	0,9714	0,9710	0,9974	0,9713	0,9712	00:12:36
Ortalama	0,9671±(0,0033)	0,9661±(0,0037)	0,9968±(0,0003)	0,9661±(0,0041)	0,9666±(0,0035)	00:12:30




Şekil 4.115. SqueezeNet ağına ait beş döngünün doğruluk grafiği

Şekil 4.115 ağı doğruluk oran grafiğini, Şekil 4.116 ise kayıp oran grafiğini göstermektedir. Kayıp oranı grafiğinde, 1441. iterasyonla birlikte ağı kayıp oranı azalmaktadır.



Şekil 4.116. SqueezeNet ağına ait beş döngünün kayıp oranı grafiği

Şekil 4.117a’da verilen karmaşıklık matrisinde, yanlış tahmin edilen görüntülerin sayısı ve sınıfı gösterilmektedir. FLAIR-Normal görüntülerde, yanlış tahmin yapılmamıştır. AUC değerleri T1-HGG ve T1CE-Normal sınıfları için 0,999, T1-LGG sınıfı için 0,998 bulunurken diğer sınıflar için AUC değerleri 1 olarak bulunmuştur.




Şekil 4.117. SqueezeNet ağı a) 5. döngü karmaşıklık matrisi (b) ROC grafiği

4.3.5. Inception V3

12 sınıf çıkışlı sınıflandırmada, InceptionV3 ağı performans değerleri ve eğitim süreleri Çizelge 4.15’te verilmiştir. InceptionV3 ağı, 2s 31 dk 51 sn ile en uzun eğitim süresine sahiptir. %97,94’ün üzerinde performans değerleriyle yüksek başarı göstermiştir.


Çizelge 4.15. 12 sınıf çıkışlı InceptionV3 modelinde beş döngünün performans değerleri ve ortalamaları

Döngü	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
1.Döngü	0,9819	0,9821	0,9983	0,9817	0,9820	02:20:38
2.Döngü	0,9802	0,9800	0,9981	0,9796	0,9801	02:41:17
3.Döngü	0,9768	0,9769	0,9978	0,9767	0,9768	02:41:11
4.Döngü	0,9796	0,9795	0,9982	0,9800	0,9796	02:30:17
5.Döngü	0,9800	0,9793	0,9982	0,9800	0,9797	02:25:54
Ortalama	0,9796±(0,0018)	0,9795±(0,0018)	0,9981±(0,0001)	0,9795±(0,0018)	0,9796±(0,0018)	02:31:51




Şekil 4.118. InceptionV3 ağına ait beş döngünün doğruluk grafiği

InceptionV3 modeline ait doğruluk grafiği Şekil 4.118’de, kayıp oranı grafiği ise Şekil 4.119’da verilmiştir. Grafiklerde 541. iterasyon sonrasında başarının görünür bir şekilde arttığı, 1621. iterasyon sonunda ise kararlı bir yapıya geçtiği görülmektedir.



Şekil 4.119. InceptionV3 ağına ait beş döngünün kayıp oranı grafiği

Şekil 4.120a'da karmaşıklık matrisinde, 7 FLAIR-HGG görüntüsü T1-HGG olarak, 8 FLAIR-LGG görüntüsü ise T1-LGG olarak yanlış tahmin edilmiştir. 7 T2-HGG görüntüsü de T1-HGG olarak yanlış sınıflandırılmıştır. ROC grafiğinde (Şekil 4.120b), tüm sınıfların AUC değerleri 1 olarak bulunmuştur.



Şekil 4.120. InceptionV3 ağı (a) 5. döngü karmaşıklık matrisi (b) ROC grafiği

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Tez çalışmasında, 3 sınıf çıkışlı sınıflandırmada AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve InceptionV3 derin öğrenme modeli 5 kat çapraz doğrulama yapılarak elde edilen performans değerleri Çizelge 5.1.'de verilmiştir.

Çizelge 5.1. 3 sınıf çıkışlı sınıflandırmada tüm modellerin performans kriterleri

Modalite	Ağ	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
FLAIR	AlexNet	0,9976±(0,0014)	0,9977±(0,0014)	0,9988±(0,0007)	0,9976±(0,0014)	0,9976±(0,0014)	00:13:44
	GoogleNet	0,9914±(0,0072)	0,9919±(0,0062)	0,9959±(0,0031)	0,9916±(0,0067)	0,9916±(0,0067)	00:29:27
	ShuffleNet	0,9937±(0,0021)	0,9936±(0,0021)	0,9968±(0,0010)	0,9936±(0,0021)	0,9936±(0,0021)	01:07:38
	SqueezeNet	0,9946±(0,0028)	0,9946±(0,0025)	0,9973±(0,0013)	0,9946±(0,0027)	0,9946±(0,0026)	00:12:01
	Inception V3	0,9974±(0,0029)	0,9973±(0,0030)	0,9986±(0,0015)	0,9973±(0,0030)	0,9973±(0,0029)	02:22:07
T1	AlexNet	0,9918±(0,0073)	0,9915±(0,0074)	0,9958±(0,0037)	0,9916±(0,0075)	0,9917±(0,0073)	00:13:40
	GoogleNet	0,9810±(0,0051)	0,9810±(0,0051)	0,9905±(0,0025)	0,9810±(0,0050)	0,9810±(0,0051)	00:29:27
	ShuffleNet	0,9842±(0,0110)	0,9839±(0,0110)	0,9919±(0,0055)	0,9840±(0,0110)	0,9841±(0,0110)	01:07:08
	SqueezeNet	0,9726±(0,0110)	0,9721±(0,0114)	0,9861±(0,0056)	0,9723±(0,0114)	0,9724±(0,0112)	00:11:53
	Inception V3	0,9888±(0,0049)	0,9892±(0,0048)	0,9945±(0,0024)	0,9890±(0,0049)	0,9890±(0,0048)	02:20:57
T1CE	AlexNet	0,9928±(0,0045)	0,9930±(0,0042)	0,9965±(0,0021)	0,9930±(0,0044)	0,9929±(0,0044)	00:13:45
	GoogleNet	0,9617±(0,0069)	0,9612±(0,0080)	0,9807±(0,0039)	0,9613±(0,0075)	0,9614±(0,0074)	00:29:33
	ShuffleNet	0,9718±(0,0038)	0,9716±(0,0045)	0,9858±(0,0024)	0,9716±(0,0045)	0,9717±(0,0041)	01:07:10
	SqueezeNet	0,9516±(0,0085)	0,9518±(0,0087)	0,9756±(0,0048)	0,9510±(0,0097)	0,9517±(0,0086)	00:11:56
	Inception V3	0,9829±(0,0066)	0,9829±(0,0067)	0,9915±(0,0034)	0,9830±(0,0067)	0,9829±(0,0066)	02:20:55
T2	AlexNet	0,9969±(0,0007)	0,9970±(0,0007)	0,9985±(0,0003)	0,9970±(0,0007)	0,9969±(0,0007)	00:13:51
	GoogleNet	0,9877±(0,0053)	0,9876±(0,0055)	0,9938±(0,0027)	0,9876±(0,0054)	0,9876±(0,0054)	00:29:35
	ShuffleNet	0,9910±(0,0046)	0,9909±(0,0049)	0,9955±(0,0024)	0,9919±(0,0048)	0,9909±(0,0047)	01:07:10
	SqueezeNet	0,9850±(0,0083)	0,9851±(0,0082)	0,9925±(0,0042)	0,9850±(0,0084)	0,9851±(0,0083)	00:11:49
	Inception V3	0,9933±(0,0047)	0,9934±(0,0048)	0,9966±(0,0024)	0,9933±(0,0048)	0,9933±(0,0047)	02:21:55

Modalite bazlı yapılan sınıflandırmada, tüm ağlar %99'un üzerinde yüksek performans göstermiştir. 3 sınıf çıkışlı sınıflandırmada FLAIR modalitesinde, tüm performans değerleri göz önüne alındığında AlexNet ve InceptionV3 modelleri en yüksek sonuçları vermiştir. Eğitim süreleri karşılaştırıldığında, SqueezeNet 12 dk ile en kısa InceptionV3 ise 2 saatten fazla bir süreyle en uzun eğitim zamanına sahiptir. T1, T1CE ve T2 modalitesinde AlexNet modeli tüm performans değerleri ele alındığında %99'un üzerinde bir sonuçla en yüksek performansa sahiptir. FLAIR ve T2 modaliteleri performans değeri, tüm ağlara bakıldığında daha yüksek performans göstermiştir.

FLAIR, T1, T1CE ve T2 modalitelerinde, tüm modellerde 5 döngüye ait ortalama AUC değerleri Çizelge 5.2’de verilmiştir. Hiper parametre seçimleri, veri seti göz önüne alınarak belirlendiği için tüm modeller %99’un üstünde AUC ortalamasına sahiptir. AlexNet modeli tüm modalitelerde, diğer ağlara göre çok az bir farkla da olsa en yüksek performansı vermiştir.

















Çizelge 5.2. 3 sınıf çıkışlı sınıflandırmada tüm modellerin AUC değerleri

Modalite	Ağ	AUC-	AUC-	AUC-	AUC-
FLAIR	AlexNet	1	0,999997	0,999992	0,999996
	GoogleNet	0,999786	0,999859	0,999953	0,999866
	ShuffleNet	0,999934	0,999866	0,999875	0,999892
	SqueezeNet	0,999843	0,999770	0,999932	0,999849
	Inception V3	0,999995	0,999982	0,999945	0,999974
T1	AlexNet	0,999827	0,999896	0,999819	0,999847
	GoogleNet	0,999158	0,999027	0,998387	0,998858
	ShuffleNet	0,998774	0,999760	0,998350	0,998962
	SqueezeNet	0,998213	0,998549	0,997598	0,998121
	Inception V3	0,999711	0,999479	0,998948	0,999379
T1CE	AlexNet	0,999945	0,999920	0,999830	0,999898
	GoogleNet	0,997674	0,998340	0,995002	0,997006
	ShuffleNet	0,997979	0,999210	0,996400	0,997864
	SqueezeNet	0,996837	0,998219	0,993899	0,996319
	Inception V3	0,998934	0,999464	0,997970	0,998789
T2	AlexNet	0,999989	0,999997	0,999982	0,999989
	GoogleNet	0,999618	0,999707	0,999162	0,999496
	ShuffleNet	0,999923	0,999974	0,999872	0,999924
	SqueezeNet	0,999587	0,999902	0,999399	0,999629
	Inception V3	0,999926	0,999974	0,999901	0,999934

Tüm eğitimlerin sonucunda test verilerine model tahminlerinin görselleştirilmesi ile ilgili çalışma yapılmıştır. Derin öğrenme modellerinin, tahminlerini ısı haritaları ile görselleştirilmesi Gradient-weighted Class Activation Mapping (Grad-CAM) olarak adlandırılan bir algoritma ile gerçekleştirilir. Gradyan ağırlıklı sınıf aktivasyon haritalama yöntemi olan Grad-CAM ile görüntüdeki önemli bölgeleri vurgulayan genel bir yerleştirme haritası elde ederken, son evrişim katmanına iletilen hedef kavramın gradyanları tahmin için kullanılmaktadır (Selvaraju ve ark., 2017). Tez çalışmasında, her bir sınıf içerisinde AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve InceptionV3 modellerinde tahmin edilen test verilerine Grad-CAM yöntemi uygulanmıştır. Orijinal görüntü ile modellerin tahmini sonucunda verilere göre elde edilen Grad-CAM ısı haritaları karşılaştırılmıştır. Orijinal MR görüntüsü ve elde edilen Grad-CAM görüntüleri,

en yüksek doğruluk değeri veren ağdan seçilmiştir. Çizelge 5.3'te 3 sınıf çıkışlı sınıflandırma sonucu elde edilen AlexNet modelinde orijinal MR görüntüsü ile Grad-CAM görüntüsü verilmiştir.

Çizelge 5.3. 3 sınıf çıkışlı orijinal MR görüntüleri ve Grad-CAM uygulanması

Modalite	Orijinal Görüntü	Grad-CAM Görüntüsü	Modalite	Orijinal Görüntü	Grad-CAM Görüntüsü
FLAIR HGG			T1CE HGG		
FLAIR LGG			T1CE LGG		
T1 HGG			T2 HGG		
T1 LGG			T2 LGG		

4 sınıf çıkışlı sınıflandırmada HGG, LGG ve normal MR görüntüleri kesinlik, duyarlılık, özgüllük, doğruluk, F1 puanı performans kriterleri ve döngülerin toplam eğitim süreleri Çizelge 5.4'te verilmiştir. HGG dereceli FLAIR, T1, T1CE ve T2 modaliteleri performans değerlerine bakıldığında tüm kriterlerin AlexNet %99,50'den yüksek bir değerle en yüksek performansı göstermiştir. AlexNet yaklaşık 19 dk ile en düşük 2. eğitim süresine sahiptir.

Çizelge 5.4. 4 sınıf çıkışlı sınıflandırmada tüm modellerin performans kriterleri

Derece	Ağ	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
HGG	AlexNet	0,9954±(0,0022)	0,9955±(0,0020)	0,9985±(0,0006)	0,9955±(0,0019)	0,9955±(0,0020)	00:18:45
	GoogleNet	0,9915±(0,0033)	0,9920±(0,0031)	0,9973±(0,0010)	0,9918±(0,0031)	0,9917±(0,0059)	00:40:06
	ShuffleNet	0,9918±(0,0043)	0,9919±(0,0042)	0,9973±(0,0013)	0,9920±(0,0041)	0,9919±(0,0042)	01:30:38
	SqueezeNet	0,9902±(0,0037)	0,9906±(0,0034)	0,9969±(0,0011)	0,9905±(0,0035)	0,9904±(0,0035)	00:16:37
	Inception V3	0,9915±(0,0045)	0,9918±(0,0043)	0,9973±(0,0014)	0,9918±(0,0043)	0,9916±(0,0044)	03:13:37
LGG	AlexNet	0,9961±(0,0013)	0,9959±(0,0016)	0,9987±(0,0005)	0,9960±(0,0014)	0,9960±(0,0014)	00:19:01
	GoogleNet	0,9949±(0,0026)	0,9949±(0,0026)	0,9983±(0,0005)	0,9950±(0,0023)	0,9949±(0,0026)	00:39:47
	ShuffleNet	0,9908±(0,0048)	0,9905±(0,0052)	0,9969±(0,0015)	0,9908±(0,0046)	0,9906±(0,0050)	01:30:21
	SqueezeNet	0,9917±(0,0062)	0,9914±(0,0071)	0,9972±(0,0021)	0,9915±(0,0063)	0,9915±(0,0066)	00:16:19
	Inception V3	0,9967±(0,0020)	0,9967±(0,0021)	0,9989±(0,0006)	0,9968±(0,0019)	0,9967±(0,0020)	03:12:14
NORMAL	AlexNet	0,6503±(0,0287)	0,7155±(0,0162)	0,9035±(0,0118)	0,7092±(0,0287)	0,6808±(0,0118)	00:19:13
	GoogleNet	0,6536±(0,0086)	0,6692±(0,0213)	0,8898±(0,0038)	0,6692±(0,0078)	0,6611±(0,0083)	00:40:07
	ShuffleNet	0,5829±(0,0102)	0,5967±(0,0297)	0,8654±(0,0124)	0,5962±(0,0301)	0,5896±(0,0190)	01:30:42
	SqueezeNet	0,6738±(0,0135)	0,7088±(0,0186)	0,9030±(0,0140)	0,7100±(0,0393)	0,6908±(0,0132)	00:16:28
	Inception V3	0,5759±(0,0111)	0,5927±(0,0232)	0,8640±(0,0092)	0,5917±(0,0210)	0,5841±(0,0166)	03:19:32

LGG dereceli görüntülerin performans kriteri tüm modeller değerlendirildiğinde, ağların yüksek performans göstermesiyle birlikte InceptionV3 modeli en düşük %99,67 değeriyle en iyi performansa sahiptir. InceptionV3 modeli, en yüksek performansa sahip olmakla beraber toplam ~3 s 13 dk ile en uzun eğitimin gerçekleştiği modeldir. Normal MR görüntülerinin 4 modalite üzerinde sınıflandırılmasında, tümör kitlesi olmadığı için sınıflandırma performansının düşük olduğu görülmüştür.

















Tüm modellerin ortalama AUC değerleri Çizelge 5.5'te verilmiş ve tüm modellerde FLAIR ve T2 modalitesinin diğer modalitelere nazaran daha yüksek performans gösterdiği görülmüştür. Normal MR görüntülerinin sınıflandırılmasında T1 ve T1CE modalitesinin düşük doğruluk verdiği, FLAIR ve T2 modalitesinin ise çok yüksek bir doğruluk elde ettiği görülmüştür.

Çizelge 5.5. 4 sınıf çıkışlı sınıflandırmada tüm modellerin AUC değerleri

Derece	Ağ	AUC-FLAIR	AUC-T1	AUC-T1CE	AUC-T2	AUC-Ortalama
HGG	AlexNet	1	0,99989	1	0,999899	0,999949
	GoogleNet	1	0,99985	1	0,999892	0,999937
	ShuffleNet	1	0,99984	0,999998	0,999882	0,999930
	SqueezeNet	0,999998	0,99978	0,999980	0,999894	0,999913
	Inception V3	1	0,99986	1	0,999871	0,999935
LGG	AlexNet	1	0,99999	0,999991	1	0,999995
	GoogleNet	0,999991	0,99989	0,999869	1	0,999938
	ShuffleNet	0,999995	0,99958	0,999554	1	0,999783
	SqueezeNet	0,999997	0,99993	0,999916	1	0,999961
	Inception V3	1	0,99996	0,999958	1	0,999981
NORM	AlexNet	1	0,75886	0,759104	0,999996	0,879491
	GoogleNet	1	0,75617	0,755389	1	0,877892
	ShuffleNet	1	0,69254	0,692586	1	0,846283
	SqueezeNet	1	0,77309	0,773207	1	0,886575
	Inception V3	1	0,68576	0,685621	1	0,842847

Çizelge 5.6'da 4 sınıf çıkışlı sınıflandırma sonucu elde edilen orijinal MR görüntüleri ile Grad-CAM görüntüleri gösterilmiştir.

Çizelge 5.6. 4 sınıf orijinal MR görüntüleri ve Grad-CAM uygulanması

Modalite	Orijinal Görüntü	Grad-CAM Görüntüsü	Modalite	Orijinal Görüntü	Grad-CAM Görüntüsü
FLAIR HGG			T1CE HGG		
FLAIR LGG			T1CE LGG		
T1 HGG			T2 HGG		
T1 LGG			T2 LGG		

12 sınıf çıkışlı sınıflandırmada, 5 modele ait performans değerleri Çizelge 5.7’de verilmiştir. AlexNet modeli tüm performans değerlerinde %98,40 oranında performans göstererek ilk sırada yer almaktadır. SqueezeNet en kısa, InceptionV3 ise en uzun eğitim süresine sahiptir. SqueezeNet diğer ağlara nazaran daha düşük bir performans göstermiştir.

Çizelge 5.7. 12 sınıf çıkışlı sınıflandırmada tüm modellerin performans kriterleri

Ağ	Kesinlik	Duyarlılık	Özgüllük	Doğruluk	F1-Puanı	Eğitim Süresi (sa:dk:s)
AlexNet	0,9843±(0,0035)	0,9841±(0,0033)	0,9985±(0,0003)	0,9840±(0,0036)	0,9842±(0,0034)	01:13:29
GoogleNet	0,9722±(0,0078)	0,9719±(0,0077)	0,9974±(0,0007)	0,9719±(0,0078)	0,9720±(0,0077)	02:22:07
ShuffleNet	0,9712±(0,0036)	0,9710±(0,0039)	0,9973±(0,0003)	0,9710±(0,0033)	0,9711±(0,0037)	05:01:50
SqueezeNet	0,9671±(0,0033)	0,9661±(0,0037)	0,9968±(0,0003)	0,9661±(0,0041)	0,9666±(0,0035)	01:02:28
Inception V3	0,9796±(0,0018)	0,9795±(0,0018)	0,9981±(0,0001)	0,9795±(0,0018)	0,9796±(0,0018)	12:39:17

















Çizelge 5.8’de ise 12 sınıf çıkışlı sınıflandırmada tüm modellerin ortalama AUC değerleri verilmiştir. AlexNet modeli ortalama AUC değerinde %99,99 ile en yüksek performansa sahipken InceptionV3 modeli ikincidir.

Çizelge 5.8. 12 sınıf çıkışlı sınıflandırmada tüm modellerin AUC değerleri

AUC	AlexNet	GoogleNet	ShuffleNet	SqueezeNet	Inception V3
AUC - FLAIR HGG	0,999902	0,999739	0,999642	0,999574	0,999889
AUC - FLAIR LGG	0,999761	0,999598	0,99946	0,999454	0,999698
AUC - FLAIR NORMAL	0,999998	0,999963	0,99998	0,999965	1
AUC - T1 HGG	0,999714	0,99933	0,998877	0,99815	0,99959
AUC - T1 LGG	0,999749	0,999294	0,999081	0,998106	0,999601
AUC - T1 NORMAL	0,999956	0,999678	0,999764	0,999528	0,9999147
AUC - T1CE HGG	0,999992	0,99976	0,99981	0,99966	0,999972
AUC - T1CE LGG	0,999992	0,999588	0,999737	0,999422	0,999974
AUC - T1CE NORMAL	0,999971	0,999163	0,999456	0,998665	0,999893
AUC - T2 HGG	0,999956	0,999805	0,999877	0,999734	0,999903
AUC - T2 LGG	0,999999	0,999962	0,999971	0,999942	0,999999
AUC - T2 NORMAL	0,999998	0,999927	0,999931	0,999893	0,999992
AUC - ORTALAMA	0,999916	0,999651	0,999633	0,999342	0,999869

Çizelge 5.9’da, 12 sınıf çıkışlı sınıflandırmada AlexNet modeline uygulanan Grad-CAM algoritması sonucu elde edilen ısı haritaları ve orijinal MR görüntüleri verilmiştir.

Çizelge 5.9. 12 sınıf çıkışlı orijinal MR görüntüleri ve Grad-CAM uygulanması

Modalite	Orijinal Görüntü	Grad-CAM Görüntüsü	Modalite	Orijinal Görüntü	Grad-CAM Görüntüsü
FLAIR HGG			T1CE HGG		
FLAIR LGG			T1CE LGG		
T1 HGG			T2 HGG		
T1 LGG			T2 LGG		

Performans değerleri kadar eğitim süresi de modellerin değerlendirilmesinde önemli bir faktördür. InceptionV3 modeli her eğitimde en uzun, SqueezeNet ise en kısa sürede eğitim işlemini gerçekleştirmiştir. 3 sınıf çıkışlı sınıflandırmada toplam eğitim süresi 17 s 35 dk 47 sn, 4 çıkışlı sınıflandırmada 18 s 3 dk 27 sn, 12 sınıf çıkışlı sınıflandırmada toplam 22 s 19 dk 7 sn ’de eğitim gerçekleşmiştir. Yapılan eğitimlerin toplam süresi 57 s 58 dk 21 sn’dir. 3, 4, ve 12 sınıf çıkışlı eğitimlerin sonuçları incelendiğinde tüm modellerin %96 üzerinde yüksek performans değerleri elde ettiği görülmektedir. Farklı sınıf çıkışlı eğitimlerin yüksek başarı göstermesinde, seçilen hiper

parametreler en önemli faktörlerden biridir. Modellerin farklı hiper parametreler kullanılarak daha yüksek sonuç vermesi mümkündür. Tez çalışmasında, hedef aynı hiper parametrelerle ağ performanslarının karşılaştırılmasını sağlamaktır. 4 sınıf çıkışlı ağlarda HGG ve LGG dereceli görüntülerde yüksek başarı sağlanırken normal MR görüntülerinde performansın düştüğü gözlemlenmiştir. Normal MR görüntüleri sınıflandırılırken beklenen sonuç elde edilmiştir. Modeller sınıflandırmada farklı piksel değerlerine göre tümörlü bölgeyi tahmin ederek sınıflandırma yaptığı için tümör olmayan görüntülerde performansın düşmesi beklenen bir durumdur. Aynı zamanda normal görüntüler arasında FLAIR ve T2 sekansları yüksek doğruluk sağlarken T1 ve T1CE sekanslarında görüntülerin sınıflandırma değerlerinin fazlasıyla düştüğü gözlemlenmiştir. Tüm eğitimlerde, SqueezeNet modelinden sonra en düşük süreye sahip olması AlexNet'in doğruluk değeri ve eğitim süresiyle en yüksek performansa sahip model olduğunu göstermektedir. InceptionV3 modeli eğitim süresi, diğer ağlara göre fazla uzundur. SqueezeNet modeli en kısa eğitim süresine sahipken, performans değerlerine bakıldığında diğer ağlardan düşük olduğu izlenmiştir. MR görüntü kesitleri kullanılarak, tümör derecelerinin sınıflandırılması noktasında literatürde çalışmalar mevcuttur. Ancak modalite bazlı ve dereceye göre yapılan çalışmalar güncel ve kısıtlıdır.

Sharif ve ark. (2021), tarafından MGA ve Entropi-Kurtosis tabanlı teknikler kullanılarak yapılan çalışmada, HGG ve LGG derecesinde T1, T1CE, T2 ve FLAIR modaliteleri sınıflandırılmıştır. Veri seti olarak BRATS 2018 ve BRATS 2019 kullanılmıştır. Önerilen yöntem, BRATS 2018 veri setinde doğruluk değeri HGG derecesinde %99,7, LGG derecesinde %98,8 olarak elde edilmiştir. BRATS 2019 veri setinde ise doğruluk değeri HGG derecesinde %99,8, LGG derecesinde %99,3 ile en yüksek sonucu vermiştir. Literatürde, veri setleri genellikle %80 eğitim ve %20 test olarak ayrılmaktadır. Bu çalışmada ise %50 eğitim ve %50 test olarak veri setleri ayrılarak 10 kat çapraz doğrulama yapılmıştır. Sadece HGG ve LGG derece sınıflandırması için seçilen hiper parametreler, çalışmada doğruluğu artırmaktadır.

Ranjbar ve ark. (2020), T1, T1CE, T2 ve FLAIR modalite görüntüleri ile derin öğrenme tekniklerini kullanarak sınıflandırma çalışması gerçekleştirmiştir. Çalışmada hastalık öncesi ve sonrasına ait görüntülerin olduğu veri seti 9600 eğitim, 2400 doğrulama ve 2400 test olarak üç parçaya ayrılmıştır. Sekansların tümünde eşit sayıda görüntü ile toplamda 14400 görüntü ile eğitim yapılmıştır. VGGNet ağ modelinin farklı bir kombinasyonu ile yapılan denemelerde, tüm sekanslarda sistemin daha önce görmediği veriler kullanılarak %99'un üzerinde doğruluk sağlanmıştır. Yapılan çalışmada eğitim

süreleri ile ilgili herhangi bir bilgi bulunmamaktadır. Farklı ağ modelleri ile karşılaştırmalar yapılmamakla birlikte sadece modalite bazlı görüntü sınıflandırma yapılmıştır.

Amin ve ark. (2019), tarafından yapılan çalışmada, dört MR dizisi dalgacık dönüşüm yöntemi kullanılarak tek bir görüntüde birleştirilmiş, tüm sekanslardaki doku ve yapı bilgilerini içeren ayrıntılı bir bilgi sağlanmıştır. Çalışmada füzyon görüntülerinin, segmentasyon yapılan tümör bölgesi ve normal MR kesitleri ile sınıflandırılması yapılmıştır. BRATS 2013, BRATS 2015 ve BRATS 2018’de sırasıyla doğruluk değerleri 0,98, 0,96 ve 0,97, duyarlılık değerleri 0,99, 0,98 ve 0,99 ve özgüllük değerleri 0,95, 0,92 ve 0,93 olarak bulunmuştur. Sekansların ve füzyon görüntülerin segmentasyon sonucu ile edilen tümürlü kesitlerin, normal görüntüler ile karşılaştırılması ağın sınıflandırma doğruluğunu artıracak bir faktördür. Çalışma doğruluğu, diğer ağ modelleri ile karşılaştırılmamış ve eğitim sürelerine değinilmemiştir.

Khan ve ark. (2020b), tarafından yapılan çalışmada BRATS 2015, BRATS 2017 ve BRATS 2018 veri setleri kullanılarak multimodal beyin tümörü sınıflandırılmıştır. VGG16 ve VGG19 modellerinde elde edilen özniteliklere füzyon işlemi yapılmıştır. Veri seti %60 eğitim, %40 test olarak ayrılmış ve 10 kat çapraz doğrulama yapılmıştır. Transfer öğrenme ve ELM tekniği kullanılan çalışmada, BRATS 2015 doğruluğu %98,16, BRATS 2017 doğruluğu %97,26 ve BRATS 2018 doğruluğu ise %93,40 olarak elde edilmiştir. Çalışmada sadece T1, T1CE, T2 ve FLAIR modalitelerinin doğruluk değeri karşılaştırmaları yapılmıştır. Tez çalışmasında modalite bazlı görüntülerde doğruluk değerleri %99’un üzerindeyken bu çalışmada doğruluk değeri en yüksek %98,16 olarak bulunmuştur.

Ge ve ark., (2018), tarafından T1CE, T2, FLAIR sekanslarına ait HGG ve LGG dereceli görüntülerin sınıflandırılması yapılmıştır. Çalışmada, sekansların eğitimi sonucu elde edilen doğruluk değerleri ile modalitelerin füzyon olarak verilmesiyle elde edilen doğruluk değerleri karşılaştırılmıştır. Füzyon yönteminde, HGG derecesinde %91,27, LGG derecesinde ise %90,48 en yüksek doğruluk değeri elde edilmiştir. Çalışmada elde edilen doğruluk değerleri, tez çalışmasıyla kıyaslandığında performansının çok düşük olduğu görülmektedir. Üç farklı sekans kullanılması, farklı ağ modelleri ile karşılaştırmaların yapılmaması ve eğitim sürelerinin verilmemesi çalışmadaki yetersiz konulardır.

Tez çalışmasında, sekansların kendi içerisinde HGG, LGG, normal sınıflandırılması, sadece HGG, LGG, normal görüntülerin kendi içerisinde sekans

sınıflandırması, son aşamada sekanslara ek olarak tümör dereceli olan ve olmayan MR görüntülerinin derin öğrenme modellerine tümüyle verilmesi senaryoları detaylı bir şekilde gerçekleştirilmiştir. Yukarıda ve kaynak araştırmasında belirtildiği gibi, literatürde HGG, LGG MR görüntü sınıflandırması veya HGG, LGG tanısına sahip sekansların kendi içerisinde sınıflandırılmasına dönük çalışmalar mevcuttur. Aynı zamanda tümör derecesi bilinen MR görüntülerinin ilgili bölge segmentasyon çalışmaları da öne çıkmaktadır. Hastanelerde tümör tanısı için radyolojik görüntülerin belirtilen dört sekansı aynı anda analiz edilmektedir. Dolayısıyla dört sekansın ve derecelerin beraber bir sınıflandırıcıya verilerek performansının izlenmesi tez çalışmasının en önemli hedefini oluşturmaktadır. Literatürde yapılan tümör derecelendirme ve sekans sınıflandırmalarının 12 sınıf çıkışa göre nasıl performans sergileyeceğinin belirlenmesi için tüm denemeler aynı veri kümelerinde ve aynı hiper parametre değerlerinde gerçekleştirilmiştir. Tümör derece sınıflandırılması ve derece sekanslarının kendi için sınıflandırılması literatür ile yakın sonuçlar vermiştir. 12 çıkış veren sınıflandırma için ise literatürde karşılaştırılabilecek bir çalışma bulunmamaktadır. Hem sekans hem de derecelerin beraber bulunduğu sınıflandırma AlexNet modeli ile %98,40 doğruluk oranı ile yüksek bir performans sergilemiştir. Sadece derece ve sekans sınıflandırma için ayrı ayrı modeller eğitilirken tüm görüntülerin sınıflandırılması için tek bir model yeterli olabilmektedir. Bu noktada, tez çalışmasında ortaya konulan tüm derecelerin ve sekansların tek bir modelle eğitilerek yüksek tahmin sonucu verebileceği, sadece sekans veya sadece derece sınıflandırılmasının maliyetli ve tahmin açısından eksik kalabileceği fikirleri en önemli çıktıları oluşturmaktadır.

5.2. Öneriler

Yapay zeka algoritmaları finans, robotik, otomotiv, sağlık başta olmak üzere hemen her alanda problemlerin pratik bir şekilde çözümlenmesinde kolaylık sağlamaktadır. Geçmiş veriler ile eğitilen algoritmalar yüksek performans değerleri ile güçlü tahminler yapabilmektedir. Yapay zekanın bir alt dalı olan derin öğrenme algoritmaları, güçlü donanımların ve bulut sistemlerin piyasaya sürülmesi ile beraber daha popüler hale gelmiştir. Özellikle sağlık alanında radyolojik görüntüler kullanılarak hastalık tahmini, anlamsal bölütleme ve ilgili bölgelerin tespit işlemleri hızlı ve yüksek doğruluk değerleri ile yapılabilmektedir. Radyolojik görüntüler üzerinden özellik çıkarma ve özellik seçme yöntemleri kullanılarak makine öğrenmesi algoritmaları ile

hastalık tahmini ve sınıflandırma işlemleri literatürde uzun süreler çalışılmıştır. Ancak özellik çıkarma ve özellik seçme yöntemlerinin çok fazla olması, aynı zamanda çok fazla makine öğrenmesi algoritmasının literatüre önerilmesi ile araştırmacılar uygun kombinasyonu bulmak için çok fazla süre harcamışlardır. Derin öğrenme metotları ise özellik çıkarma ve seçme işlemini kullanıcıya bırakmadan özellikleri katmanlar boyunca kendiliğinden çıkarıp kendiliğinden seçmektedir. Bu algoritmalar uluslararası düzeyde belli Benchmark veri setleri ile yapılan yarışmalarda üstünlüklerini, hızlarını ve güçlü performanslarını ortaya koymuşlardır. Bu kıstaslardan dolayı geliştirilmek istenen bilgisayar destekli radyolojik karar destek sistemlerinde klasik makine öğrenmesi yöntemleri yerine derin öğrenme algoritmalarının kullanılması araştırmacılara pratik kullanımlar sunacaktır.

Tez çalışmasında, BRATS 2019 veri setinde yer alan FLAIR, T1, T1CE ve T2 modalitelerine ait MR görüntüleri AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve InceptionV3 olmak üzere 5 farklı derin öğrenme modeli kullanılarak eğitim ve test işlemi gerçekleştirilmiştir. Denemelerde aynı hiper parametreler kullanılarak farklı derin öğrenme modellerinin performansı ve eğitim süreleriyle ilgili sonuçlar elde edilmiştir. Herhangi bir hiper parametrenin ya da veri setinin değişmesi modellerin performansını büyük ölçüde etkileyebilmektedir. Performansların değerlendirilmesinde kesinlik, duyarlılık, özgüllük, doğruluk ve F1 puanı kriterleri ve eğitim süresi etkili olmuştur. Tüm modellerin 3, 4 ve 12 sınıf çıkışlı sınıflandırmalarda %95'in üzerinde bir performansla sonuçlar verdiği izlenmiştir.

Tümör şüphesi ile hastaneye gelen bir kişiye T1, T2, T1CE ve FLAIR olmak üzere dört farklı sekansta MR görüntüsü çekilmektedir. Tümörün derecesi, şekli ve içeriğine göre farklı sekanslarda farklı özellikleri izlenmektedir. Dolayısıyla dört sekans birden değerlendirilerek tanı konulması tedavi süreçlerinde daha doğru bir adım atılması için önemlidir. Literatürde genellikle tek bir sekansta derecelerin veya sekansların kendi içinde sınıflandırılmasına dönük çalışmalar mevcuttur. Hem dereceleri hem de sekansları aynı anda sınıflandırarak 12 çıkış veren modellerin performans değerlerinin izlenmesi bu tez çalışmasının en önemli motivasyonunu oluşturmaktadır. Yüksek doğruluk değerlerinin elde edilmesi ile sadece derece veya sekans sınıflandıran çalışmalara göre üstünlüğü ortaya konulmuştur. Tez çalışması, gerçekleştirilen uygulamaya ek olarak tümörlü bölgelerin ve tümörün alt bölgelerinin segmentasyonu yapılarak daha kapsamlı bir sisteme dönüştürülebilir. Segmentasyon yönteminin sınıflandırma ile birleştirilmesi sonucunda tümöre ait birçok bilgiye erişmek mümkün olacaktır. MR görüntülerinin

sınıflandırma için hazır hale getirilmesinde tümörlü dilimlerin seçilmesi ve uygun olmayan görüntülerin atılması işlemlerinin tam otomatik yapılması için bir algoritma geliştirmek ön işlem adımlarını büyük ölçüde hızlandıracaktır. Farklı veri setleri kullanımı eğitimlerin doğruluğu ve hiper parametre seçimini etkilemektedir. MR görüntüleri birkaç farklı topluluk ile anonim hale getirilmiş ve birçok çalışma aynı veri seti ile yapılmaktadır. Farklı hastanelerden ve farklı hastalardan belli aralıklarda alınan MR görüntüleri ile ilgili yapılacak olan çalışmalar literatüre katkı sağlayacaktır.

Ülkemizde hastalardan çekilen tüm görüntüler veri tabanlarında kayıt edilmekte ancak yapay zeka tabanlı otomatik tanı sistemleri ile analiz edilmemektedir. Bu noktadan Sağlık Bakanlığı veri tabanları radyolojik görüntü analizi için araştırmacılara güçlü veriler sunabilecek niteliktedir. Görüntülerin doktorlar tarafından etiketlenmesi ve yapay zeka ile bilgisayar tabanlı karar destek sistemlerinin geliştirilmesi için büyük bir potansiyel bulunmaktadır. Bu tez çalışmasında gerçekleştirilen uygulamalar gibi diğer birçok radyolojik görüntülerin ve hastalıkların analizi doktorlara teşhis için kolaylıklar sağlayabilir. Medikal cihazlardan çekilen görüntülerin güçlü donanımlara aktarılarak radyolojik görüntülerden yapay zeka tabanlı yerli karar destek sistemlerinin geliştirilmesi ülkemize büyük katma değer sunacaktır.

6. KAYNAKLAR

- Abd El Kader, I., Xu, G., Shuai, Z., Saminu, S., Javaid, I. ve Salim Ahmad, I., 2021, Differential deep convolutional neural network model for brain tumor classification, *Brain Sciences*, 11 (3), 352.
- Amin, J., Sharif, M., Yasmin, M., Saba, T., Anjum, M. A. ve Fernandes, S. L., 2019, A new approach for brain tumor segmentation and classification based on score level fusion using transfer learning, *Journal of medical systems*, 43 (11), 1-16.
- Anaraki, A. K., Ayati, M. ve 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.
- Anonim, 2019, Sinir Sisteminin Yapısı [Online], <https://bikifi.com/biki/sinir-sisteminin-yapisi>: [Ziyaret Tarihi: 20 Eylül 2021].
- Anonim, 2020a, Multimodal Brain Tumor Segmentation Challenge 2019: Data [Online], <https://www.med.upenn.edu/cbica/brats2019/data.html>: [Ziyaret Tarihi : 5 Ekim 2020].
- Anonim, 2020b, MRicro [Online], University of South Carolina, <https://www.nitrc.org/projects/mricro/>: [Ziyaret Tarihi : 14.01.2020].
- Anonim, 2021, Brain Tumor: Statistics [Online], <https://www.cancer.net/cancer-types/brain-tumor/statistics>: [Ziyaret Tarihi : 15 Eylül 2021].
- Arı, A., 2019, Derin Öğrenme Tabanlı Beyin Mr Görüntülerinden Beyin Tümörlerinin Tespit Edilmesi Ve Sınıflandırılması, Doktora Tezi, *İnönü Üniversitesi Fen Bilimleri Enstitüsü*, Malatya, 2-4.
- Bakas, S., Akbari, H., Sotiras, A., Bilello, M., Rozycki, M., Kirby, J. S., Freymann, J. B., Farahani, K. ve Davatzikos, C., 2017, Advancing the cancer genome atlas glioma MRI collections with expert segmentation labels and radiomic features, *Scientific data*, 4 (1), 1-13.
- Bakas, S., Reyes, M., Jakab, A., Bauer, S., Rempfler, M., Crimi, A., Shinohara, R. T., Berger, C., Ha, S. M. ve Rozycki, M., 2018, Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge, *arXiv preprint arXiv:1811.02629*.
- Banerjee, S., Mitra, S., Masulli, F. ve Rovetta, S., 2019, Deep radiomics for brain tumor detection and classification from multi-sequence MRI, *arXiv preprint arXiv:1903.09240*.
- Can, F., 2019, Transfer Derin Öğrenme İle Hibrit El Yazısı Karakter Tanıma, Yüksek Lisans Tezi, *Milli Savunma Üniversitesi Hezarfen Havacılık Ve Uzun Teknolojileri Enstitüsü*, İstanbul, 34-46.
- Cantemir, Z., 2019, Derin Öğrenme Yöntemleriyle Medikal Görüntü Sınıflandırma, Yüksek Lisans Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, 15-27.
- Chatterjee, S., Nizamani, F. A., Nürnberger, A. ve Speck, O., 2021, Classification of Brain Tumours in MR Images using Deep Spatiotemporal Models, *arXiv preprint arXiv:2105.14071*.
- Coşkun, Y., 2019, Beyin Metastazlarının Derin Öğrenme İle Sınıflandırılması, Yüksek Lisans Tezi, *Kocaeli Üniversitesi Fen Bilimleri Enstitüsü*, Kocaeli, 10-51.
- Çarkacı, N., 2018, Derin Öğrenme Uygulamalarında Hiper Parametre Seçim Yöntemleri [Online], <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-model-dogrulama-ve-hiper-parametre-secim-yontemleri-823812d95f3>: [Ziyaret Tarihi: 17 Temmuz 2021].

- Çayıroğlu, İ., 2015, Yapay Sinir Ağları [Online], Karabük Üniversitesi, http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu_Isleme_Ders_Notlari-11.Hafta.pdf: [Ziyaret Tarihi: 8 Haziran 2021].
- Dandıl, E., 2015, MR görüntüleri ve MR spektroskopisi verileri ile yapay öğrenme tabanlı beyin tümörü tespit yöntemi ve uygulaması, Doktora Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya, 2-43.
- De Mello, J. P. V., Paixão, T. M., Berriel, R., Reyes, M., Badue, C., De Souza, A. F. ve Oliveira-Santos, T., 2021, Deep Learning-based Type Identification of Volumetric MRI Sequences, *2020 25th International Conference on Pattern Recognition (ICPR)*, 1-8.
- Deng, L. ve Yu, D., 2014, Deep learning: methods and applications, *Foundations and trends in signal processing*, 7 (3–4), 197-387.
- Diker, A., 2020, Sıtma Hastalığının Sınıflandırılmasında Evrimsel Sinir Ağlarının Performanslarının Karşılaştırılması, *BEÜ Fen Bilimleri Dergisi*, 9 (4), 187-1829.
- Ferlay, J., Colombet, M., Soerjomataram, I., Parkin, D. M., Piñeros, M., Znaor, A. ve Bray, F., 2021, Cancer statistics for the year 2020: An overview, *International Journal of Cancer*.
- Ge, C., Gu, I. Y.-H., Jakola, A. S. ve Yang, J., 2018, Deep learning and multi-sensor fusion for glioma classification using multistream 2D convolutional networks, *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 5894-5897.
- Ghosh, S., 2020, Automatic Brain Tumor Detection and Classification on MRI Images Using Machine Learning Techniques, Yüksek Lisans Tezi, *University of Technology*, West Bengal, 14-15.
- Gökalg, S. ve Aydın, İ., 2021, Farklı Derin Sinir Ağı Modellerinin Duygu Tanımadaki Performanslarının Karşılaştırılması, *Muş Alparslan Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 2 (1), 37-38.
- Gültekin, T., 2020, Küçük Veri Setleri İçin Derin Öğrenme, Doktora Tezi, *Ege Üniversitesi Fen Bilimleri Enstitüsü*, İzmir, 3-46.
- Hao, R., Namdar, K., Liu, L. ve Khalvati, F., 2021, A Transfer Learning-Based Active Learning Framework for Brain Tumor Classification, *Frontiers in Artificial Intelligence*, 4.
- İnik, Ö. ve Ülker, E., 2017, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- Khan, H. A., Jue, W., Mushtaq, M. ve Mushtaq, M. U., 2020a, Brain tumor classification in MRI image using convolutional neural network, *Math. Biosci. Eng.*, 17, 6203.
- Khan, M. A., Ashraf, I., Alhaisoni, M., Damaševičius, R., Scherer, R., Rehman, A. ve Bukhari, S. A. C., 2020b, Multimodal brain tumor classification using deep learning and robust feature selection: A machine learning application for radiologists, *Diagnostics*, 10 (8), 565.
- Kızrak, A., 2018, Şu Kara Kutuyu Açalım : Yapay Sinir Ağları [Online], <https://ayyucekizrak.medium.com/%C5%9Fu-kara-kutuyu-a%C3%A7alim-yapay-sinir-a%C4%9Flar%C4%B1-7b65c6a5264a>: [Ziyaret Tarihi: 2.11.2020].
- Koçer, B., 2012, Transfer Öğrenmede Yeni Yaklaşımlar, Doktora Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 10-15.
- Kurt, F., 2018, Evrimsel Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi, Yüksek Lisans, *Hacettepe Üniversitesi*, Ankara, 30-40.
- Kutlu, H., 2020, Derin Öğrenme Yöntemleri Kullanılarak Kalın Bağırsak Poliplerinin Tespiti Takibi Ve Sınıflandırılması, Doktora Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 9-17.

- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278-2324.
- Menze, B. H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., Burren, Y., Porz, N., Slotboom, J. ve Wiest, R., 2014, The multimodal brain tumor image segmentation benchmark (BRATS), *IEEE transactions on medical imaging*, 34 (10), 1993-2024.
- Msonda, P., 2020, Derin Öğrenme Tekniklerini Kullanarak Otomatik Tüberküloz Teşhisi, Yüksek Lisans Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Konya, 10-22.
- Mzoughi, H., Njeh, I., Wali, A., Slima, M. B., BenHamida, A., Mhiri, C. ve Mahfoudhe, K. B., 2020, Deep multi-scale 3D convolutional neural network (CNN) for MRI gliomas brain tumor classification, *Journal of digital imaging*, 33, 903-915.
- Oyar, O., 2008, Magnetik Rezonans Görüntüleme Mrg'nin Klinik Uygulamaları Ve Endikasyonları, *Harran Üniversitesi Tıp Fakültesi Dergisi*, 5 (2), 31-40.
- Öğretmenoğlu Fıçıcı, C., 2016, MR Görüntülerinde Baş Bölgesine Ait Yapıların Belirlenmesi Ve Hacimlerinin Hesaplanması, Yüksek Lisans Tezi, *Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği ...*, Ankara, 2-16.
- Ölmez, E., 2020, Derin Öğrenme Ve Morfolojik Görüntü İşleme Yöntemleri İle MR Görüntülerinde Otomatik Menüsküs Segmentasyonu, Doktora Tezi, *Yozgat Bozok Üniversitesi Fen Bilimleri Enstitüsü*, Yozgat, 10-13.
- Özdoğan, M., 2021, Türkiye Kanseri İstatistikleri 2020 [Online], <https://www.drozdogan.com/turkiye-kanser-istatistikleri-2020/>: [Ziyaret Tarihi: 29.10.2021].
- Öziç, M., 2013, Ü., " MR Görüntülerinde Alzheimer Hastalığının Özneliklerinin Belirlenmesi, *Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü*.
- Öztürk, K. ve Şahin, M. E., 2018, Yapay sinir ağları ve yapay zekâ'ya genel bir bakış, *Takvim-i Vekayi*, 6 (2), 25-36.
- Raghav, P., 2018, CNN Architectures - LeNet, AlexNet, VGG, GoogLeNet and ResNet [Online], <https://medium.com/@RaghavPrabhu/cnn-architectures-lenet-alexnet-vgg-googlenet-and-resnet-7c81c017b848>: [Ziyaret Tarihi: 16 Temmuz 2021].
- Rajasree, R., Columbus, C. C. ve Shilaja, C., 2021, Multiscale-based multimodal image classification of brain tumor using deep learning method, *Neural Computing and Applications*, 33 (11), 5543-5553.
- Ranjbar, S., Singleton, K. W., Jackson, P. R., Rickertsen, C. R., Whitmire, S. A., Clark-Swanson, K. R., Mitchell, J. R., Swanson, K. R. ve Hu, L. S., 2020, A deep convolutional neural network for annotation of magnetic resonance imaging sequence type, *Journal of digital imaging*, 33 (2), 439-446.
- Rezaee, K., Mousavirad, S. J., Khosravi, M. R., Moghimi, M. K. ve Heidari, M., 2021, An Autonomous UAV-Assisted Distance-Aware Crowd Sensing Platform Using Deep ShuffleNet Transfer Learning, *IEEE Transactions on Intelligent Transportation Systems*, 1-3.
- Saba, T., Mohamed, A. S., El-Affendi, M., Amin, J. ve Sharif, M., 2020, Brain tumor detection using fusion of hand crafted and deep learning features, *Cognitive Systems Research*, 59, 221-230.
- Sameer, M. A., Bayat, O. ve Mohammed, H. J., 2020, Brain Tumor Segmentation and Classification approach for MR Images Based on Convolutional Neural Networks, *2020 1st. Information Technology To Enhance e-learning and Other Application (IT-ELA)*, 138-143.

- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D. ve Batra, D., 2017, Grad-cam: Visual explanations from deep networks via gradient-based localization, *Proceedings of the IEEE international conference on computer vision*, 618-626.
- Sertkaya, M. E., 2018, Derin öğrenme tekniklerinin biyomedikal imgeler üzerine uygulamaları/Applications of deep learning techniques on biomedical images, Yüksek Lisans Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 2-25.
- Shahzadi, I., Tang, T. B., Meriadeau, F. ve Quyyum, A., 2018, CNN-LSTM: Cascaded framework for brain Tumour classification, *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, 633-637.
- Sharif, M. I., Khan, M. A., Alhussein, M., Aurangzeb, K. ve Raza, M., 2021, A decision support system for multimodal brain tumor classification using deep learning, *Complex & Intelligent Systems*, 1-14.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826.
- Şengöz, N., 2017, Yapay Sinir Ağları [Online], <https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/>: [Ziyaret Tarihi: 4 Haziran 2021].
- Şimşek, A. B. ve Dicle, A., 2017, Primer beyin tümörü: Klinik özellikler, tedavi ve bakım, *Dokuz Eylül Üniversitesi Hemşirelik Fakültesi Elektronik Dergisi*, 6 (2), 102-113.
- Tanash, A., 2020, Developing A Deep Learning Approach For Detecting Brain Cancer From MRI Images, Yüksek Lisans Tezi, *Bahçeşehir Üniversitesi*, İstanbul, 5-9.
- Temür, G., 2021, Derin Öğrenme Tabanlı Nesne Tespit Algoritmaları İle Hisse Senedi Al-Sat Karar Destek Sisteminin Modellenmesi Doktora Tezi, *Düzce Üniversitesi Fen Bilimleri Enstitüsü*, Düzce, 46-58.
- Tosun, S., 2007, Sınıflandırmada yapay sinir ağları ve karar ağaçları karşılaştırması: Öğrenci başarıları üzerine bir uygulama, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 2-10.
- Tuncer, E., 2018, Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır?, <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>: [Ziyaret Tarihi: 5 Temmuz 2020].
- Yang, Y., Yan, L.-F., Zhang, X., Han, Y., Nan, H.-Y., Hu, Y.-C., Hu, B., Yan, S.-L., Zhang, J. ve Cheng, D.-L., 2018, Glioma grading on conventional MR images: a deep learning study with transfer learning, *Frontiers in neuroscience*, 12, 804.
- Yiğit, G. ve Yeğin, M. N., 2020, Öğrenme Aktarımı/Transfer Learning [Online], <https://medium.com/novaresearchlab/%C3%B6%C4%9Frenme-aktar%C4%B1m%C4%B1-transfer-learning-c0b8126965c4>: [Ziyaret Tarihi: 17 Temmuz 2021].
- Yıldırım, Ö., 2020, Derin Öğrenme Yöntemleri Kullanılarak Covid-19 Vaka Tahmini Ve Mevsimsel Etkilerin Analizi, Yüksek Lisans Tezi, *Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü*, Karabük, 10-20.
- Yüksel, Z., 2019, Manyetik Rezonans Görüntüleme Fizik Temelleri ve Sistem Bileşenleri, *Black Sea Journal of Engineering and Science* (2 2), 57-65.
- Zhang, X., Zhou, X., Lin, M. ve Sun, J., 2018, Shufflenet: An extremely efficient convolutional neural network for mobile devices, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 6848-6856.

Zhuge, Y., Ning, H., Mathen, P., Cheng, J. Y., Krauze, A. V., Camphausen, K. ve Miller, R. W., 2020, Automated glioma grading on conventional MRI images using deep convolutional neural networks, *Medical physics*, 47 (7), 3044-3053.



EKLER

EK-1 FLAIR, T1, T1CE ve T2 modalitesi HGG görüntüleri

BraTS19_2013_10_1_058	BraTS19_2013_19_1_089	BraTS19_2013_7_1_090	BraTS19_CBICA_ALU_1_069	BraTS19_CBICA_AOO_1_096
BraTS19_2013_10_1_059	BraTS19_2013_19_1_090	BraTS19_2013_7_1_091	BraTS19_CBICA_ALU_1_070	BraTS19_CBICA_AOO_1_097
BraTS19_2013_10_1_060	BraTS19_2013_19_1_091	BraTS19_2013_7_1_092	BraTS19_CBICA_ALU_1_071	BraTS19_CBICA_AOO_1_098
BraTS19_2013_10_1_061	BraTS19_2013_19_1_092	BraTS19_2013_7_1_093	BraTS19_CBICA_ALU_1_072	BraTS19_CBICA_AOO_1_099
BraTS19_2013_10_1_062	BraTS19_2013_19_1_093	BraTS19_2013_7_1_094	BraTS19_CBICA_ALU_1_073	BraTS19_CBICA_AOO_1_100
BraTS19_2013_10_1_063	BraTS19_2013_19_1_094	BraTS19_2013_7_1_095	BraTS19_CBICA_ALU_1_074	BraTS19_CBICA_AOO_1_101
BraTS19_2013_10_1_064	BraTS19_2013_19_1_095	BraTS19_2013_7_1_096	BraTS19_CBICA_ALU_1_075	BraTS19_CBICA_AOO_1_102
BraTS19_2013_10_1_065	BraTS19_2013_19_1_096	BraTS19_2013_7_1_097	BraTS19_CBICA_ALU_1_076	BraTS19_CBICA_AOO_1_103
BraTS19_2013_10_1_066	BraTS19_2013_19_1_097	BraTS19_2013_7_1_098	BraTS19_CBICA_ALU_1_077	BraTS19_CBICA_AOO_1_104
BraTS19_2013_10_1_067	BraTS19_2013_19_1_098	BraTS19_2013_7_1_099	BraTS19_CBICA_ALX_1_084	BraTS19_CBICA_AOO_1_105
BraTS19_2013_10_1_068	BraTS19_2013_19_1_099	BraTS19_2013_7_1_100	BraTS19_CBICA_ALX_1_085	BraTS19_CBICA_AOO_1_106
BraTS19_2013_10_1_069	BraTS19_2013_19_1_100	BraTS19_2013_7_1_101	BraTS19_CBICA_ALX_1_086	BraTS19_CBICA_AOO_1_107
BraTS19_2013_10_1_070	BraTS19_2013_19_1_101	BraTS19_2013_7_1_102	BraTS19_CBICA_ALX_1_087	BraTS19_CBICA_AOO_1_108
BraTS19_2013_10_1_071	BraTS19_2013_19_1_102	BraTS19_2013_7_1_103	BraTS19_CBICA_ALX_1_088	BraTS19_CBICA_AOO_1_109
BraTS19_2013_10_1_072	BraTS19_2013_19_1_103	BraTS19_2013_7_1_104	BraTS19_CBICA_ALX_1_089	BraTS19_CBICA_AOO_1_110
BraTS19_2013_10_1_073	BraTS19_2013_19_1_104	BraTS19_2013_7_1_105	BraTS19_CBICA_ALX_1_090	BraTS19_CBICA_AOO_1_111
BraTS19_2013_10_1_074	BraTS19_2013_19_1_105	BraTS19_2013_7_1_106	BraTS19_CBICA_ALX_1_091	BraTS19_CBICA_AOO_1_112
BraTS19_2013_10_1_075	BraTS19_2013_19_1_106	BraTS19_2013_7_1_107	BraTS19_CBICA_ALX_1_092	BraTS19_CBICA_AOO_1_113
BraTS19_2013_10_1_076	BraTS19_2013_19_1_107	BraTS19_2013_7_1_108	BraTS19_CBICA_ALX_1_093	BraTS19_CBICA_AOO_1_114
BraTS19_2013_10_1_077	BraTS19_2013_19_1_108	BraTS19_2013_7_1_109	BraTS19_CBICA_ALX_1_094	BraTS19_CBICA_AOO_1_115
BraTS19_2013_10_1_078	BraTS19_2013_19_1_109	BraTS19_2013_7_1_110	BraTS19_CBICA_ALX_1_095	BraTS19_CBICA_AOS_1_076
BraTS19_2013_10_1_079	BraTS19_2013_19_1_110	BraTS19_2013_7_1_111	BraTS19_CBICA_AMH_1_076	BraTS19_CBICA_AOS_1_077
BraTS19_2013_10_1_080	BraTS19_2013_19_1_111	BraTS19_2013_7_1_112	BraTS19_CBICA_AMH_1_077	BraTS19_CBICA_AOS_1_078
BraTS19_2013_10_1_081	BraTS19_2013_19_1_112	BraTS19_2013_7_1_113	BraTS19_CBICA_AMH_1_078	BraTS19_CBICA_AOS_1_079
BraTS19_2013_10_1_082	BraTS19_2013_19_1_113	BraTS19_2013_7_1_114	BraTS19_CBICA_AMH_1_079	BraTS19_CBICA_AOS_1_080
BraTS19_2013_10_1_083	BraTS19_2013_19_1_114	BraTS19_2013_7_1_115	BraTS19_CBICA_AMH_1_080	BraTS19_CBICA_AOS_1_081
BraTS19_2013_10_1_084	BraTS19_2013_21_1_075	BraTS19_2013_7_1_116	BraTS19_CBICA_AMH_1_081	BraTS19_CBICA_AOS_1_082
BraTS19_2013_10_1_085	BraTS19_2013_21_1_076	BraTS19_2013_7_1_117	BraTS19_CBICA_AMH_1_082	BraTS19_CBICA_AOS_1_083
BraTS19_2013_10_1_086	BraTS19_2013_21_1_077	BraTS19_2013_7_1_118	BraTS19_CBICA_AMH_1_083	BraTS19_CBICA_AOS_1_084
BraTS19_2013_10_1_087	BraTS19_2013_21_1_078	BraTS19_2013_7_1_119	BraTS19_CBICA_AMH_1_084	BraTS19_CBICA_AOS_1_085
BraTS19_2013_10_1_088	BraTS19_2013_21_1_079	BraTS19_2013_7_1_120	BraTS19_CBICA_AMH_1_085	BraTS19_CBICA_AOS_1_086
BraTS19_2013_10_1_089	BraTS19_2013_21_1_080	BraTS19_2013_7_1_121	BraTS19_CBICA_AMH_1_086	BraTS19_CBICA_AOS_1_087
BraTS19_2013_10_1_090	BraTS19_2013_21_1_081	BraTS19_CBICA_AAB_1_073	BraTS19_CBICA_AMH_1_087	BraTS19_CBICA_AOS_1_088
BraTS19_2013_10_1_091	BraTS19_2013_21_1_082	BraTS19_CBICA_AAB_1_074	BraTS19_CBICA_AMH_1_088	BraTS19_CBICA_AOS_1_089
BraTS19_2013_10_1_092	BraTS19_2013_21_1_083	BraTS19_CBICA_AAB_1_075	BraTS19_CBICA_AMH_1_089	BraTS19_CBICA_AOS_1_090
BraTS19_2013_10_1_093	BraTS19_2013_21_1_084	BraTS19_CBICA_AAB_1_076	BraTS19_CBICA_AMH_1_090	BraTS19_CBICA_AOS_1_091
BraTS19_2013_10_1_094	BraTS19_2013_21_1_085	BraTS19_CBICA_AAB_1_077	BraTS19_CBICA_AMH_1_091	BraTS19_CBICA_AOS_1_092
BraTS19_2013_10_1_095	BraTS19_2013_21_1_086	BraTS19_CBICA_AAB_1_078	BraTS19_CBICA_AMH_1_092	BraTS19_CBICA_AOS_1_093
BraTS19_2013_10_1_096	BraTS19_2013_21_1_087	BraTS19_CBICA_AAB_1_079	BraTS19_CBICA_AMH_1_093	BraTS19_CBICA_AOS_1_094
BraTS19_2013_10_1_097	BraTS19_2013_21_1_088	BraTS19_CBICA_AAB_1_080	BraTS19_CBICA_AMH_1_094	BraTS19_CBICA_AOS_1_095

[illegible]

BraTS19_2013_18_1_112	BraTS19_2013_5_1_086	BraTS19_CBICA_ALN_1_084	BraTS19_CBICA_AOH_1_103	BraTS19_CBICA_APZ_1_079
BraTS19_2013_18_1_113	BraTS19_2013_5_1_087	BraTS19_CBICA_ALN_1_085	BraTS19_CBICA_AOH_1_104	BraTS19_CBICA_APZ_1_080
BraTS19_2013_18_1_114	BraTS19_2013_5_1_088	BraTS19_CBICA_ALN_1_086	BraTS19_CBICA_AOH_1_105	BraTS19_CBICA_APZ_1_081
BraTS19_2013_18_1_115	BraTS19_2013_5_1_089	BraTS19_CBICA_ALN_1_087	BraTS19_CBICA_AOH_1_106	BraTS19_CBICA_APZ_1_082
BraTS19_2013_18_1_116	BraTS19_2013_5_1_090	BraTS19_CBICA_ALN_1_088	BraTS19_CBICA_AOH_1_107	BraTS19_CBICA_APZ_1_083
BraTS19_2013_18_1_117	BraTS19_2013_5_1_091	BraTS19_CBICA_ALN_1_089	BraTS19_CBICA_AOH_1_108	BraTS19_CBICA_APZ_1_084
BraTS19_2013_18_1_118	BraTS19_2013_5_1_092	BraTS19_CBICA_ALN_1_090	BraTS19_CBICA_AOH_1_109	BraTS19_CBICA_APZ_1_085
BraTS19_2013_18_1_119	BraTS19_2013_5_1_093	BraTS19_CBICA_ALN_1_091	BraTS19_CBICA_AOH_1_110	BraTS19_CBICA_APZ_1_086
BraTS19_2013_18_1_120	BraTS19_2013_5_1_094	BraTS19_CBICA_ALN_1_092	BraTS19_CBICA_AOH_1_111	BraTS19_CBICA_APZ_1_087
BraTS19_2013_18_1_121	BraTS19_2013_5_1_095	BraTS19_CBICA_ALN_1_093	BraTS19_CBICA_AOH_1_112	BraTS19_CBICA_APZ_1_088
BraTS19_2013_18_1_122	BraTS19_2013_5_1_096	BraTS19_CBICA_ALN_1_094	BraTS19_CBICA_AOH_1_113	BraTS19_CBICA_APZ_1_089
BraTS19_2013_18_1_123	BraTS19_2013_5_1_097	BraTS19_CBICA_ALN_1_095	BraTS19_CBICA_AOH_1_114	BraTS19_CBICA_APZ_1_090
BraTS19_2013_19_1_076	BraTS19_2013_5_1_098	BraTS19_CBICA_ALN_1_096	BraTS19_CBICA_AOH_1_115	BraTS19_CBICA_APZ_1_091
BraTS19_2013_19_1_077	BraTS19_2013_5_1_099	BraTS19_CBICA_ALN_1_097	BraTS19_CBICA_AOO_1_084	BraTS19_CBICA_AQO_1_084
BraTS19_2013_19_1_078	BraTS19_2013_5_1_100	BraTS19_CBICA_ALN_1_098	BraTS19_CBICA_AOO_1_085	BraTS19_CBICA_AQO_1_085
BraTS19_2013_19_1_079	BraTS19_2013_5_1_101	BraTS19_CBICA_ALN_1_099	BraTS19_CBICA_AOO_1_086	BraTS19_CBICA_AQO_1_086
BraTS19_2013_19_1_080	BraTS19_2013_5_1_102	BraTS19_CBICA_ALN_1_100	BraTS19_CBICA_AOO_1_087	BraTS19_CBICA_AQO_1_087
BraTS19_2013_19_1_081	BraTS19_2013_5_1_103	BraTS19_CBICA_ALN_1_101	BraTS19_CBICA_AOO_1_088	BraTS19_CBICA_AQO_1_088
BraTS19_2013_19_1_082	BraTS19_2013_5_1_104	BraTS19_CBICA_ALN_1_102	BraTS19_CBICA_AOO_1_089	BraTS19_CBICA_AQO_1_089
BraTS19_2013_19_1_083	BraTS19_2013_5_1_105	BraTS19_CBICA_ALN_1_103	BraTS19_CBICA_AOO_1_090	BraTS19_CBICA_AQO_1_090
BraTS19_2013_19_1_084	BraTS19_2013_7_1_085	BraTS19_CBICA_ALN_1_104	BraTS19_CBICA_AOO_1_091	BraTS19_CBICA_AQO_1_091
BraTS19_2013_19_1_085	BraTS19_2013_7_1_086	BraTS19_CBICA_ALN_1_105	BraTS19_CBICA_AOO_1_092	BraTS19_CBICA_AQO_1_092
BraTS19_2013_19_1_086	BraTS19_2013_7_1_087	BraTS19_CBICA_ALN_1_106	BraTS19_CBICA_AOO_1_093	BraTS19_CBICA_AQO_1_093
BraTS19_2013_19_1_087	BraTS19_2013_7_1_088	BraTS19_CBICA_ALN_1_107	BraTS19_CBICA_AOO_1_094	BraTS19_CBICA_AQO_1_094
BraTS19_2013_19_1_088	BraTS19_2013_7_1_089	BraTS19_CBICA_ALU_1_068	BraTS19_CBICA_AOO_1_095	BraTS19_CBICA_AQO_1_095

EK-2 FLAIR, T1, T1CE ve T2 modalitesi LGG görüntüleri

BraTS19_2013_15_1_100	BraTS19_TCIA09_255_1_092	BraTS19_TCIA10_103_1_078	BraTS19_TCIA10_276_1_081	BraTS19_TCIA10_410_1_076
BraTS19_2013_15_1_101	BraTS19_TCIA09_255_1_093	BraTS19_TCIA10_103_1_079	BraTS19_TCIA10_276_1_082	BraTS19_TCIA10_410_1_077
BraTS19_2013_15_1_102	BraTS19_TCIA09_255_1_094	BraTS19_TCIA10_103_1_080	BraTS19_TCIA10_276_1_083	BraTS19_TCIA10_410_1_078
BraTS19_2013_15_1_103	BraTS19_TCIA09_255_1_095	BraTS19_TCIA10_103_1_081	BraTS19_TCIA10_276_1_084	BraTS19_TCIA10_410_1_079
BraTS19_2013_15_1_104	BraTS19_TCIA09_255_1_096	BraTS19_TCIA10_103_1_082	BraTS19_TCIA10_276_1_085	BraTS19_TCIA10_410_1_080
BraTS19_2013_15_1_105	BraTS19_TCIA09_255_1_097	BraTS19_TCIA10_103_1_083	BraTS19_TCIA10_276_1_086	BraTS19_TCIA10_410_1_081
BraTS19_2013_15_1_106	BraTS19_TCIA09_255_1_098	BraTS19_TCIA10_103_1_084	BraTS19_TCIA10_276_1_087	BraTS19_TCIA10_410_1_082
BraTS19_2013_15_1_107	BraTS19_TCIA09_255_1_099	BraTS19_TCIA10_103_1_085	BraTS19_TCIA10_276_1_088	BraTS19_TCIA10_410_1_083
BraTS19_2013_15_1_108	BraTS19_TCIA09_312_1_084	BraTS19_TCIA10_103_1_086	BraTS19_TCIA10_276_1_089	BraTS19_TCIA10_410_1_084
BraTS19_2013_15_1_109	BraTS19_TCIA09_312_1_085	BraTS19_TCIA10_103_1_087	BraTS19_TCIA10_276_1_090	BraTS19_TCIA10_410_1_085
BraTS19_2013_15_1_110	BraTS19_TCIA09_312_1_086	BraTS19_TCIA10_103_1_088	BraTS19_TCIA10_276_1_091	BraTS19_TCIA10_410_1_086
BraTS19_2013_15_1_111	BraTS19_TCIA09_312_1_087	BraTS19_TCIA10_103_1_089	BraTS19_TCIA10_282_1_076	BraTS19_TCIA10_410_1_087
BraTS19_2013_15_1_112	BraTS19_TCIA09_312_1_088	BraTS19_TCIA10_103_1_090	BraTS19_TCIA10_282_1_077	BraTS19_TCIA10_410_1_088
BraTS19_2013_15_1_113	BraTS19_TCIA09_312_1_089	BraTS19_TCIA10_103_1_091	BraTS19_TCIA10_282_1_078	BraTS19_TCIA10_410_1_089
BraTS19_2013_15_1_114	BraTS19_TCIA09_312_1_090	BraTS19_TCIA10_103_1_092	BraTS19_TCIA10_282_1_079	BraTS19_TCIA10_410_1_090
BraTS19_2013_15_1_115	BraTS19_TCIA09_312_1_091	BraTS19_TCIA10_103_1_093	BraTS19_TCIA10_282_1_080	BraTS19_TCIA10_410_1_091
BraTS19_2013_15_1_116	BraTS19_TCIA09_312_1_092	BraTS19_TCIA10_103_1_094	BraTS19_TCIA10_282_1_081	BraTS19_TCIA10_410_1_092
BraTS19_2013_15_1_117	BraTS19_TCIA09_312_1_093	BraTS19_TCIA10_103_1_095	BraTS19_TCIA10_282_1_082	BraTS19_TCIA10_410_1_093
BraTS19_2013_15_1_118	BraTS19_TCIA09_312_1_094	BraTS19_TCIA10_103_1_096	BraTS19_TCIA10_282_1_083	BraTS19_TCIA10_410_1_094
BraTS19_2013_15_1_119	BraTS19_TCIA09_312_1_095	BraTS19_TCIA10_103_1_097	BraTS19_TCIA10_282_1_084	BraTS19_TCIA10_410_1_095
BraTS19_2013_15_1_120	BraTS19_TCIA09_312_1_096	BraTS19_TCIA10_103_1_098	BraTS19_TCIA10_282_1_085	BraTS19_TCIA10_410_1_096
BraTS19_2013_15_1_121	BraTS19_TCIA09_312_1_097	BraTS19_TCIA10_103_1_099	BraTS19_TCIA10_282_1_086	BraTS19_TCIA10_410_1_097
BraTS19_2013_15_1_122	BraTS19_TCIA09_312_1_098	BraTS19_TCIA10_103_1_100	BraTS19_TCIA10_282_1_087	BraTS19_TCIA10_410_1_098
BraTS19_2013_15_1_123	BraTS19_TCIA09_312_1_099	BraTS19_TCIA10_103_1_101	BraTS19_TCIA10_282_1_088	BraTS19_TCIA10_410_1_099
BraTS19_2013_16_1_074	BraTS19_TCIA09_312_1_100	BraTS19_TCIA10_103_1_102	BraTS19_TCIA10_282_1_089	BraTS19_TCIA10_410_1_100
BraTS19_2013_16_1_075	BraTS19_TCIA09_312_1_101	BraTS19_TCIA10_103_1_103	BraTS19_TCIA10_282_1_090	BraTS19_TCIA10_410_1_101
BraTS19_2013_16_1_076	BraTS19_TCIA09_312_1_102	BraTS19_TCIA10_103_1_104	BraTS19_TCIA10_282_1_091	BraTS19_TCIA10_410_1_102
BraTS19_2013_16_1_077	BraTS19_TCIA09_312_1_103	BraTS19_TCIA10_103_1_105	BraTS19_TCIA10_282_1_092	BraTS19_TCIA10_410_1_103
BraTS19_2013_16_1_078	BraTS19_TCIA09_312_1_104	BraTS19_TCIA10_103_1_106	BraTS19_TCIA10_282_1_093	BraTS19_TCIA10_410_1_104
BraTS19_2013_16_1_079	BraTS19_TCIA09_312_1_105	BraTS19_TCIA10_103_1_107	BraTS19_TCIA10_282_1_094	BraTS19_TCIA10_410_1_105
BraTS19_2013_16_1_080	BraTS19_TCIA09_312_1_106	BraTS19_TCIA10_103_1_108	BraTS19_TCIA10_282_1_095	BraTS19_TCIA10_410_1_106
BraTS19_2013_16_1_081	BraTS19_TCIA09_312_1_107	BraTS19_TCIA10_103_1_109	BraTS19_TCIA10_282_1_096	BraTS19_TCIA10_410_1_107
BraTS19_2013_16_1_082	BraTS19_TCIA09_312_1_108	BraTS19_TCIA10_103_1_110	BraTS19_TCIA10_282_1_097	BraTS19_TCIA10_410_1_108
BraTS19_2013_16_1_083	BraTS19_TCIA09_312_1_109	BraTS19_TCIA10_103_1_111	BraTS19_TCIA10_282_1_098	BraTS19_TCIA10_410_1_109
BraTS19_2013_16_1_084	BraTS19_TCIA09_312_1_110	BraTS19_TCIA10_103_1_112	BraTS19_TCIA10_282_1_099	BraTS19_TCIA10_410_1_110
BraTS19_2013_16_1_085	BraTS19_TCIA09_312_1_111	BraTS19_TCIA10_103_1_113	BraTS19_TCIA10_282_1_100	BraTS19_TCIA10_410_1_111
BraTS19_2013_16_1_086	BraTS19_TCIA09_312_1_112	BraTS19_TCIA10_103_1_114	BraTS19_TCIA10_282_1_101	BraTS19_TCIA10_410_1_112
BraTS19_2013_16_1_087	BraTS19_TCIA09_312_1_113	BraTS19_TCIA10_103_1_115	BraTS19_TCIA10_282_1_102	BraTS19_TCIA10_410_1_113
BraTS19_2013_16_1_088	BraTS19_TCIA09_312_1_114	BraTS19_TCIA10_109_1_068	BraTS19_TCIA10_282_1_103	BraTS19_TCIA10_410_1_114
BraTS19_2013_16_1_089	BraTS19_TCIA09_312_1_115	BraTS19_TCIA10_109_1_069	BraTS19_TCIA10_282_1_104	BraTS19_TCIA10_410_1_115
BraTS19_2013_16_1_090	BraTS19_TCIA09_402_1_068	BraTS19_TCIA10_109_1_070	BraTS19_TCIA10_282_1_105	BraTS19_TCIA10_442_1_068
BraTS19_2013_16_1_091	BraTS19_TCIA09_402_1_069	BraTS19_TCIA10_109_1_071	BraTS19_TCIA10_282_1_106	BraTS19_TCIA10_442_1_069
BraTS19_2013_16_1_092	BraTS19_TCIA09_402_1_070	BraTS19_TCIA10_109_1_072	BraTS19_TCIA10_282_1_107	BraTS19_TCIA10_442_1_070

BraTS19 TCIA09 255 1 070	BraTS19 TCIA09 493 1 080	BraTS19 TCIA10 241 1 083	BraTS19 TCIA10 393 1 094	BraTS19 TCIA10 639 1 097
BraTS19 TCIA09 255 1 071	BraTS19 TCIA09 493 1 081	BraTS19 TCIA10 241 1 084	BraTS19 TCIA10 393 1 095	BraTS19 TCIA10 639 1 098
BraTS19 TCIA09 255 1 072	BraTS19 TCIA09 493 1 082	BraTS19 TCIA10 241 1 085	BraTS19 TCIA10 393 1 096	BraTS19 TCIA10 639 1 099
BraTS19 TCIA09 255 1 073	BraTS19 TCIA09 493 1 083	BraTS19 TCIA10 241 1 086	BraTS19 TCIA10 393 1 097	BraTS19 TCIA10 639 1 100
BraTS19 TCIA09 255 1 074	BraTS19 TCIA09 493 1 084	BraTS19 TCIA10 241 1 087	BraTS19 TCIA10 393 1 098	BraTS19 TCIA10 639 1 101
BraTS19 TCIA09 255 1 075	BraTS19 TCIA09 493 1 085	BraTS19 TCIA10 241 1 088	BraTS19 TCIA10 393 1 099	BraTS19 TCIA10 639 1 102
BraTS19 TCIA09 255 1 076	BraTS19 TCIA09 493 1 086	BraTS19 TCIA10 241 1 089	BraTS19 TCIA10 393 1 100	BraTS19 TCIA10 639 1 103
BraTS19 TCIA09 255 1 077	BraTS19 TCIA09 493 1 087	BraTS19 TCIA10 241 1 090	BraTS19 TCIA10 393 1 101	BraTS19 TCIA10 639 1 104
BraTS19 TCIA09 255 1 078	BraTS19 TCIA09 493 1 088	BraTS19 TCIA10 241 1 091	BraTS19 TCIA10 393 1 102	BraTS19 TCIA10 639 1 105
BraTS19 TCIA09 255 1 079	BraTS19 TCIA09 493 1 089	BraTS19 TCIA10 276 1 068	BraTS19 TCIA10 393 1 103	BraTS19 TCIA10 639 1 106
BraTS19 TCIA09 255 1 080	BraTS19 TCIA09 493 1 090	BraTS19 TCIA10 276 1 069	BraTS19 TCIA10 393 1 104	BraTS19 TCIA10 639 1 107
BraTS19 TCIA09 255 1 081	BraTS19 TCIA09 493 1 091	BraTS19 TCIA10 276 1 070	BraTS19 TCIA10 393 1 105	BraTS19 TCIA10 639 1 108
BraTS19 TCIA09 255 1 082	BraTS19 TCIA09 493 1 092	BraTS19 TCIA10 276 1 071	BraTS19 TCIA10 393 1 106	BraTS19 TCIA10 639 1 109
BraTS19 TCIA09 255 1 083	BraTS19 TCIA09 493 1 093	BraTS19 TCIA10 276 1 072	BraTS19 TCIA10 393 1 107	BraTS19 TCIA10 639 1 110
BraTS19 TCIA09 255 1 084	BraTS19 TCIA09 493 1 094	BraTS19 TCIA10 276 1 073	BraTS19 TCIA10 393 1 108	BraTS19 TCIA10 639 1 111
BraTS19 TCIA09 255 1 085	BraTS19 TCIA09 493 1 095	BraTS19 TCIA10 276 1 074	BraTS19 TCIA10 393 1 109	BraTS19 TCIA10 639 1 112
BraTS19 TCIA09 255 1 086	BraTS19 TCIA09 493 1 096	BraTS19 TCIA10 276 1 075	BraTS19 TCIA10 393 1 110	BraTS19 TCIA10 639 1 113
BraTS19 TCIA09 255 1 087	BraTS19 TCIA09 493 1 097	BraTS19 TCIA10 276 1 076	BraTS19 TCIA10 393 1 111	BraTS19 TCIA10 639 1 114
BraTS19 TCIA09 255 1 088	BraTS19 TCIA09 493 1 098	BraTS19 TCIA10 276 1 077	BraTS19 TCIA10 393 1 112	BraTS19 TCIA10 639 1 115
BraTS19 TCIA09 255 1 089	BraTS19 TCIA09 493 1 099	BraTS19 TCIA10 276 1 078	BraTS19 TCIA10 393 1 113	BraTS19 TCIA10 639 1 116
BraTS19 TCIA09 255 1 090	BraTS19 TCIA10 103 1 076	BraTS19 TCIA10 276 1 079	BraTS19 TCIA10 393 1 114	BraTS19 TCIA10 639 1 117
BraTS19 TCIA09 255 1 091	BraTS19 TCIA10 103 1 077	BraTS19 TCIA10 276 1 080	BraTS19 TCIA10 393 1 115	BraTS19 TCIA10 639 1 118

EK-3 FLAIR, T1, T1CE ve T2 modalitesi Normal MR görüntüleri

[illegible]

[illegible]

BraTS19_2013_29_1_127	BraTS19_CBICA_AME_1_100	BraTS19_CBICA_AQA_1_079	BraTS19_TCIA10_152_1_108	BraTS19_TCIA10_449_1_072
BraTS19_2013_7_1_068	BraTS19_CBICA_AME_1_101	BraTS19_CBICA_AQA_1_080	BraTS19_TCIA10_152_1_109	BraTS19_TCIA10_449_1_073
BraTS19_2013_7_1_069	BraTS19_CBICA_AME_1_102	BraTS19_CBICA_AQA_1_081	BraTS19_TCIA10_152_1_110	BraTS19_TCIA10_449_1_074
BraTS19_2013_7_1_070	BraTS19_CBICA_AME_1_103	BraTS19_CBICA_AQA_1_082	BraTS19_TCIA10_152_1_111	BraTS19_TCIA10_449_1_075
BraTS19_2013_7_1_071	BraTS19_CBICA_AME_1_104	BraTS19_CBICA_AQA_1_083	BraTS19_TCIA10_152_1_112	BraTS19_TCIA10_449_1_076
BraTS19_2013_7_1_072	BraTS19_CBICA_AME_1_105	BraTS19_CBICA_AQA_1_084	BraTS19_TCIA10_152_1_113	BraTS19_TCIA10_449_1_077
BraTS19_2013_7_1_073	BraTS19_CBICA_AME_1_106	BraTS19_CBICA_AQA_1_085	BraTS19_TCIA10_152_1_114	BraTS19_TCIA10_449_1_078
BraTS19_CBICA_AAB_1_116	BraTS19_CBICA_AME_1_107	BraTS19_CBICA_AQA_1_086	BraTS19_TCIA10_152_1_115	BraTS19_TCIA10_449_1_079
BraTS19_CBICA_AAB_1_117	BraTS19_CBICA_AME_1_108	BraTS19_CBICA_AQA_1_087	BraTS19_TCIA10_152_1_116	BraTS19_TCIA10_449_1_080
BraTS19_CBICA_AAB_1_118	BraTS19_CBICA_AME_1_109	BraTS19_CBICA_AQA_1_088	BraTS19_TCIA10_152_1_117	BraTS19_TCIA10_628_1_100
BraTS19_CBICA_AAB_1_119	BraTS19_CBICA_AME_1_110	BraTS19_CBICA_AQA_1_089	BraTS19_TCIA10_152_1_118	BraTS19_TCIA10_628_1_101
BraTS19_CBICA_AAB_1_120	BraTS19_CBICA_AME_1_111	BraTS19_CBICA_AQA_1_090	BraTS19_TCIA10_152_1_119	BraTS19_TCIA10_628_1_102
BraTS19_CBICA_AAB_1_121	BraTS19_CBICA_AME_1_112	BraTS19_CBICA_AQA_1_091	BraTS19_TCIA10_152_1_120	BraTS19_TCIA10_628_1_103
BraTS19_CBICA_AAB_1_122	BraTS19_CBICA_AME_1_113	BraTS19_CBICA_AQA_1_092	BraTS19_TCIA10_152_1_121	BraTS19_TCIA10_628_1_104
BraTS19_CBICA_AAB_1_123	BraTS19_CBICA_AME_1_114	BraTS19_CBICA_AQA_1_093	BraTS19_TCIA10_152_1_122	BraTS19_TCIA10_628_1_105
BraTS19_CBICA_AAB_1_124	BraTS19_CBICA_AME_1_115	BraTS19_CBICA_AQA_1_094	BraTS19_TCIA10_152_1_123	BraTS19_TCIA10_628_1_106
BraTS19_CBICA_AAB_1_125	BraTS19_CBICA_AME_1_116	BraTS19_CBICA_AQA_1_095	BraTS19_TCIA10_175_1_120	BraTS19_TCIA10_628_1_107
BraTS19_CBICA_AAB_1_126	BraTS19_CBICA_AME_1_117	BraTS19_CBICA_AQA_1_096	BraTS19_TCIA10_175_1_121	BraTS19_TCIA10_628_1_108
BraTS19_CBICA_AAB_1_127	BraTS19_CBICA_AME_1_118	BraTS19_CBICA_AQA_1_097	BraTS19_TCIA10_175_1_122	BraTS19_TCIA10_628_1_109
BraTS19_CBICA_AAG_1_084	BraTS19_CBICA_AME_1_119	BraTS19_CBICA_AQA_1_098	BraTS19_TCIA10_175_1_123	BraTS19_TCIA10_628_1_110
BraTS19_CBICA_AAG_1_085	BraTS19_CBICA_AME_1_120	BraTS19_CBICA_AQA_1_099	BraTS19_TCIA10_175_1_124	BraTS19_TCIA10_628_1_111
BraTS19_CBICA_AAG_1_086	BraTS19_CBICA_AME_1_121	BraTS19_CBICA_AQA_1_100	BraTS19_TCIA10_175_1_125	BraTS19_TCIA10_628_1_112
BraTS19_CBICA_AAG_1_087	BraTS19_CBICA_AME_1_122	BraTS19_CBICA_AQA_1_101	BraTS19_TCIA10_202_1_112	BraTS19_TCIA10_628_1_113