



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI

**EVİRİŞİMSEL SİNİR AĞLARI İLE BEYİN TÜMÖRÜ TÜRLERİNİN
TESPİT EDİLMESİ**

YÜKSEK LİSANS TEZİ

Alper ÖZATILGAN

Danışman: Dr. Öğr. Üyesi Mahir KAYA

TOKAT-2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzuna göre Dr. Öğr. Üyesi Mahir KAYA danışmanlığında hazırlamış olduğum “Evrişimsel Sinir Ağları ile Beyin Tümörü Türünün Tespit Edilmesi” adlı yüksek lisans tezimin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

...../...../.....

İMZA

Alper ÖZATILGAN

ÖNSÖZ

Hazırladığım bu tez çalışmasında, yardımlarını hiçbir zaman esirgemeyen tez danışmanım Dr. Öğr. Üyesi Mahir KAYA'ya ve öğrenim hayatım boyunca emeği geçen tüm hocalarıma teşekkürü bir borç bilirim.

Hayatımın her noktasında olduğu gibi bu süreçte hiçbir desteğini ve emeğini esirgemeyen biricik eşim Demet ve kızım İdil Duru'ya sonsuz teşekkürlerimi sunarım.

Alper ÖZATILGAN

TOKAT-2024



ÖZET

EVRIŞİMSEL SİNİR AĞLARI İLE BEYİN TÜMÖRÜ TÜRÜNÜN TESPİT EDİLMESİ

ÖZATILGAN, Alper

Yüksek Lisans, Bilgisayar Mühendisliği Ana Bilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Mahir KAYA

Ağustos 2024, X + 41 Sayfa

Görme, işitme ve hareketi sağlama gibi önemli yaşamsal fonksiyonları kontrol eden beyin, hastalığı söz konusu olduğunda yaşantımızı olumsuz yönde etkilemektedir. Bu hastalıklardan tüm yaş gruplarında ortaya çıkabilen ve iyi/kötü huylu olabilen ölümcül olan hiç şüphesiz beyin tümörüdür. Bu nedenle erken tanı ve teşhis çok önemlidir. Beyin tümörü türlerinin tespiti ve tedavi yöntemi için MR (Manyetik Rezonans) görüntüleri kullanılmaktadır. Evrişimsel Sinir Ağları (ESA) modellerinin medikal görüntülerden hastalıkların tespitinde başarılı sonuçlar elde etmesi, katman sayısı ve diğer hiper-parametrelerin optimum şekilde oluşturulmasına bağlıdır. Bu çalışmada en az katman ve parametre sayısı ile en yüksek doğruluğu elde edecek bir ESA modeli öneriyoruz. ESA modellerinin eğitiminde kullanılmak üzere elde edilen ve 4 farklı sınıftan oluşan (Menenjiyom, Glioma, Pituitary ve Normal) bir veri seti, katman ve filtre sayıları, filtre boyutları, yığın sayısı, en iyileme algoritmaları ve tur değerleri değiştirilerek 50 farklı geliştirilmiş derin öğrenme modeli üzerinde eğitilmiş ve test edilmiş olup, %99,47 doğruluk ve %99,44 fl-skoru değerleri ile en iyi model tespit edilmiştir. Ayrıca önerilen en iyi modelimiz, önceki çalışmalardan ve en iyileme algoritması, yığın ve tur sayıları aynı olmak koşuluyla bazı transfer öğrenme modellerinden daha iyi sonuç elde etmiştir.

Anahtar Kelimeler: Beyin Tümörü, Derin Öğrenme, Yapay Zeka, Evrişimsel sinir Ağları(ESA), Manyetik Rezonans(MR)

ABSTRACT

DETECTION OF BRAIN TUMOR TYPE USING CONVOLUTIONAL NEURAL NETWORKS

ÖZATILGAN, Alper

Master's Thesis, Department of Computer Engineering

Advisor: Assistant Professor Mahir KAYA

August 2024, X + 41 Pages

The brain, which controls important vital functions such as vision, hearing and movement, negatively affects our lives when it is sick. Of these diseases, the deadliest is undoubtedly the brain tumor, which can occur in all age groups and can be benign or malignant. Therefore, early diagnosis and prognosis are very important. MR (Magnetic Resonance) images are used for the detection and treatment of brain tumor types. Successful results in the detection of diseases from medical images with Convolutional Neural Networks (ESA) depend on the optimum creation of the number of layers and other hyper-parameters. In this study, we propose an ESA model that will achieve the highest accuracy with the least number of layers. A dataset consisting of four different classes (Meningioma, Glioma, Pituitary, and Normal) was used for the training of ESA models. After training and testing on 50 different deep learning models with variations in layer and the number of filters, kernel, batch size, optimizer, and epoch values, the best model was identified with an accuracy of 99.47% and an F1-score of 99.44%. Additionally, our proposed best model achieved better results compared to previous studies and some transfer learning models, given the same optimizer, batch size, and epoch numbers.

Keywords: Brain Tumor, Deep Learning, Artificial Intelligence, Convolutional Neural Networks(CNN), Magnetic Resonance(MR)

İÇİNDEKİLER

ETİK SÖZLEŞME	I
JÜRİ KABUL VE ONAY	Hata! Yer işareti tanımlanmamış.
ÖNSÖZ.....	II
ÖZET.....	III
ABSTRACT	IV
İÇİNDEKİLER.....	V
ŞEKİLLER LİSTESİ.....	VII
ÇİZELGELER LİSTESİ	VIII
SİMGELER VE KISALTMALAR	IX
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	3
3. MATERYAL VE METOT.....	5
3.1. Beyin ve Beyin Tümörü	5
3.1.1. Glioma.....	6
3.1.2. Meninjiyoma	6
3.1.3. Pituitary (Hipofiz Bezi)	6
3.2. Beyin Tümörleri İçin Kullanılan Görüntüleme Teknikleri.....	7
3.2.1. Pozitron Emisyon Tomografisi (PET).....	7
3.2.2. Tek Foton Emisyonlu Bilgisayarlı Tomografi (SPECT).....	7
3.2.3. Bilgisayarlı Tomografi (CT).....	8
3.2.4. Manyetik Rezonans Spektroskopisi (MRS)	8
3.2.5. Manyetik Rezonans Görüntüleme (MRI)	8
3.3. Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme	8
3.3.1. Yapay Zeka.....	8
3.3.2. Makine Öğrenmesi	9
3.3.3. Derin Öğrenme	10
3.4. Evrişimsel Sinir Ağları(CNN).....	10
3.4.1. Evrişim(Convolution) Katmanı	11
3.4.2. Aktivasyon Fonksiyonları	12
3.4.3. Havuzlama (Pooling) Katmanı	14

3.4.4.	Tam Bağlı (Fully Connected) Katman	15
3.4.5.	Seyreltme(Dropout) Katmanı	15
3.5.	CNN’de Kullanılan Hiperparametreler	16
3.5.1.	Öğrenme Oranı(Learning Rate).....	16
3.5.2.	Kayıp Fonksiyonu (Loss Function)	17
3.5.3.	Tur (Epoch) Sayısı.....	17
3.5.4.	Optimizasyon algoritmaları	17
3.5.5.	Yığın(Batch Size) Boyutu	18
3.6.	Transfer Öğrenme.....	19
3.6.1.	VGG16	20
3.6.2.	ResNet50	20
3.6.3.	DenseNet121	20
3.6.4.	InceptionV3.....	20
3.7.	Çalışmada Kullanılan Yazılımlar ve Kütüphaneleri.....	21
3.7.1.	Python.....	21
3.7.2.	Numpy	21
3.7.3.	Scikit-Plot.....	21
3.7.4.	Tensorflow.....	21
3.7.5.	Keras.....	21
4.	BULGULAR.....	22
4.1.	Veri Seti.....	22
4.2.	Değerlendirme Metrikleri.....	22
4.3.	Önerilen Model.....	24
4.4.	En Yüksek Performanslı CNN Mimarilerinin Karşılaştırılması.....	27
4.5.	Çalışmadaki CNN Mimarilerinin Karşılaştırılması	27
4.6.	Önerilen Modelin Transfer Öğrenme Modelleri ile Karşılaştırılması	28
4.7.	Önerilen Modelin Literatürdeki Çalışmalarla Karşılaştırılması	28
5.	TARTIŞMA ve SONUÇ.....	30
5.1.	Tartışma.....	30
5.2.	Sonuç	31
6.	KAYNAKÇA.....	31
ÖZGEÇMİŞ	Hata! Yer işareti tanımlanmamış.	

ŞEKİLLER LİSTESİ

Şekil 3. 1 Glioma, Meningioma, Pituitary ve Sağlıklı Beyin MR Görüntüleri (Yazdan ve ark., 2022)..	7
Şekil 3. 2 Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme Arasındaki İlişki (Kavuncu, 2018)	10
Şekil 3. 3 CNN Mimarisi. (Gurkahraman ve Karakış, 2021)	11
Şekil 3. 4 Evrişim katmanı işlemi (*:Evrişim işlemi, ϕ :Aktivasyon Fonksiyonu) (Kim, 2017)	12
Şekil 3. 5 Evrişim İşlemi Örneği (Kızrak ve Bolat, 2018)	12
Şekil 3. 6 Havuzlama Katmanı Örneği (Arı ve Hanbay, 2019)	14
Şekil 3. 7 Tam Bağlantılı Katmanın Yapısı (Stanford.edu)	15
Şekil 3. 8 (a) Basit Sinir Ağı Yapısı (b) Dropout katmanlı Ağ Yapısı (Türkoğlu ve ark., 2020)	16
Şekil 3. 9 Öğrenme Oranına Göre Kayıp Değişim Grafiği (Akman, 2022)	16
Şekil 3. 10 Transfer Öğrenme Modellerinin Çalışma Prensibi	19
Şekil 4. 1 Önerilen Modelin CNN Mimarisi	25
Şekil 4. 2 Önerilen Modelin Confusion Matrix Tablosu	26
Şekil 4. 3 Önerilen Modelin Doğruluk ve Kayıp Tablosu	26
Şekil 4. 4 (a) 4 Conv. (b) 5 Conv. (c) 7 Conv. Katmanlı ESA Modellerin Doğruluk ve Kayıp Grafiği	28
Şekil 4. 5 (a) 4 Conv. (b) 5 Conv. (c) 7 Conv. Katmanlı Modellerin Confusion Matrix Tablosu	28
Şekil 4. 6 Modelimiz ve Transfer Öğrenme Modellerinin Toplam Parametre Sayıları	27

ÇİZELGELER LİSTESİ

Tablo 1 Bazı Aktivasyon Fonksiyonların Grafiği ve Matematiksel İfadeleri	14
Tablo 2 Confusion Matrix Parametreleri.....	23
Tablo 3 Önerilen Modelin Hiperparametre Değerleri	24
Tablo 4 Önerilen Modelin Değerleri	26
Tablo 5 Farklı katmanlara sahip en iyi modellere ait performans metrikleri	27
Tablo 6 Oluşturulan farklı CNN modelleri ve elde edilen sonuçlar(*:ADAM, **:SGD)	28
Tablo 7 Modelimizin Transfer Öğrenme Modelleriyle Karşılaştırılması	28
Tablo 8 Önerilen Modelin Literatür'deki Çalışmalarla Karşılaştırılması	30



SİMGELER VE KISALTMALAR

MÖ	: Milattan Önce
WHO	: World Health Organization
PET	: Pozitron Emisyon Tomografisi
SPECT	: Tek Foton Emisyonlu Bilgisayarlı Tomografi
BT	: Bilgisayarlı Tomografi
MRI	: Manyetik Rezonans Görüntüleme
MRS	: Manyetik Rezonans Spektroskopisi
YZ	: Yapay Zeka
DL	: Derin Öğrenme
BPNN	: Back-Propagation Neural Network
ELM	: Aşırı Öğrenme Makineleri
GAN	: Generative Adversarial Networks
CNN	:Convolutional Neural Network
NADE	: Sinirsel Oto regresif Dağılım Tahmini
RF	: Random Forest
LDA	: Lineer Diskriminant Analizi
SVM	: Support Vector Machine
PCA	: Principal Component Analysis
YSA	: Yapay Sinir Ağları
ADAM	: Adaptive Moment Estimation

1. GİRİŞ

MÖ 3000 yılına kadar uzanan, latinceye yengeç anlamına gelen kanser, herhangi bir organizmada kontrolsüz bir şekilde anormal derecede bölünerek oluşan hasarlı hücrelerin çoğalması veya birikmesi ile meydana gelen ve DNA tarafından yok edilemeyen bir hastalıktır (Baykara, 2016). Kısaca tanımlamak gerekirse kanser, mutant bir klonun bölgesel genişlemesi olarak belirtilmiştir (Mora, 2012). Bundan dolayı insanlarda ve hayvanlarda görülen sağlık problemi olmuştur (Baykara, 2016). Radyasyon etkisinde kalma, sağlığa zararlı yiyecek ve içeceklerin tüketimi, alkol ve sigara kullanımı, aşırı stresin etkisinde kalma gibi nedenlerle ortaya çıkabilen ve asrın hastalığı olarak görülen kanser, son zamanlarda giderek yaygınlaşmakta ve kalp damar hastalıklarından sonra geleceğin en ölümcül hastalığı olacağı tahmin edilmektedir (Dandıl, 2015).

Kanserli hücreler bir araya gelerek tümör denilen kitleyi oluşturur. Bu kitle, tek bir organı etkilediği gibi, başka organlara sıçraması (metastaz) ile yayılımı arttırabilir (Bali, 2020). Aşırı büyüyen ve metastaz yapan tümörler kötü huylu olarak kabul edilirken, kitle içerisinde kanser hücresi içermeyen tümörler ise iyi huylu tümör olarak adlandırılır (Wrensch ve ark, 1993). Bazı iyi huylu tümörler, histolojik yapılarından dolayı kötü huylu olarak tümörlere dönüşebilir (Arlı, 2013).

Dünya genelinde insan vücudunu etkileyen ve teşhis anında tümörün birincil bölgesi olarak adlandırılan beyin, deri, kan, kemik ve prostat başta olmak üzere 100'den fazla kanser türü bulunmaktadır (Pavlopoulou ve ark, 2015). Yapılan araştırmalara bakıldığında erkeklerde tüm yaş grubunda en sık görülen kanser türü akciğer kanseri, kadınlarda tüm yaş grubunda en sık görülen kanser türü meme kanseri, 0-14 yaş aralığındaki çocuklarda en sık görülen kanser türü ise lösemi (kan kanseri) olarak belirlenmiştir (Muratdağı ve ark., 2019). Çalışmamıza konu olan beyin tümörü ise çocukluk dönemi tümörleri arasında ikinci, 50 yaş ve üzeri kişilerde özellikle başka organlardan sıçraması göze alındığında üçüncü en sık görülen tümör grubunu oluşturmaktadır (İlçe ve ark., 2010).

Beyin tümörü, beyni çok sıkı bir şekilde çevreleyen anormal hücrelerin yayılarak artması ile tanımlanmaktadır. Baş ağrıları, nedeni bilinmeyen kusma, konuşma ve duyma güçlüğü ve vücut kontrolünün kaybolması, beyin tümörü hastalığının belirtileri arasındadır (Tanash, 2020). Diğer kanser türlerinden farklı olarak beyin tümörü türleri aşamalı değil, Dünya Sağlık Örgütü'nün (WHO) I-IV arası derecelendirilmesi ile iyi huylu ya da kötü huyludur. Derecesi I-II olan tümör türleri iyi huylu, III-IV olan tümör türleri ise kötü huylu olarak kabul edilmektedir (Barnholtz-

Sloan ve ark., 2018). Beyin tümörlerinin teşhisi, derecelendirilmesi ve takibi için Pozitron Emisyon Tomografisi (PET), Tek Foton Emisyonlu Bilgisayarlı Tomografi (SPECT), Bilgisayarlı Tomografi (BT), Manyetik Rezonans Görüntüleme (MRI) ve Manyetik Rezonans Spektroskopisi (MRS) gibi birçok görüntüleme teknikleri vardır. Bu görüntüleme tekniklerinden yumuşak dokulardaki yüksek kontrastı sayesinde daha iyi görüntü veren MRI görüntüleme tekniği tercih edilmektedir (Pınar, 2022). Beyin tümörünün tedavisi, tümörün tipine, konumuna ve boyutuna bağlıdır (Aşlıyan, 2022). Beyin tümörü hücrelerinin heterojenite yapısında olması, türünün belirlenmesini zorlaştırmakta ve tedavi yöntemi belirlenememektedir (Yazol ve Öner, 2016). İstatistiklere göre beyin tümörü, dünya genelinde kansere bağlı morbidite ve mortalitenin nedeni olarak kabul edilen, insanların en sık karşılaştığı yaşam riski bakımından en ölümcül kanser türlerinden biridir (Afshar ve ark., 2018).

Beyin kanseri dahil tüm kanser türleri için erken teşhis ve tedavi çok önemlidir (Kaya ve ark., 2023). Yapay Zeka (YZ) sayesinde tıp alanında yeni gelişmeler olmaktadır. YZ teknolojilerinden olan Makine Öğrenmesi alanında yeni geliştirilen Derin Öğrenme(DL)'nin sunduğu olanaklar ile doktorlar ve radyologlar hastalıkların tespiti konusunda daha hızlı ve daha doğru sonuçlar elde edebilir, hastalıkların ortaya çıkma riskini önceden tahmin edebilir ve araştırmacıların, hastalıklara yol açan genetik etkenleri anlamalarını sağlayabilir (Keleş, 2018).

Bu çalışmada MR görüntüleri ile glioma, meningioma ve pituitary beyin tümörü türlerinin tespiti ve sınıflandırılması amaçlanmıştır. Çalışmada kaggle (kaggle.com) sitesinden elde edilen veri seti kullanılmıştır. Oluşturduğumuz derin öğrenme modelleri, veri setimiz ile eğitilmiş ve bu modellerin sonuçları gözlemlenmiş ve karşılaştırılmıştır.

Bu çalışmada en az katman ve parametre sayısı ile en yüksek doğruluk ve en az kayıp değerini elde eden modeli geliştirmeyi amaçladık. Bunun için eğitilemeyen parametrelerden en iyileştirme algoritması, yığın değeri, kernel sayısı, tur sayısı, evrişim ve tam bağlantılı katman ve filtre sayıları değiştirilerek 50 farklı model oluşturduk. Bu modeller arasında, en yüksek doğruluğu ve en az kayıp değerini, en az katman ve parametre sayısına sahip bir model elde ettik. Ayrıca bu modelin, hem literatürdeki çalışmaların hem de bazı transfer öğrenme modellerinin, aynı veri seti üzerinde elde edilen doğruluk değerlerinden daha iyi bir sonuç aldık.

Tez çalışmasının ikinci bölümünde çalışmada söz konusu olan beyin tümörü türlerinin tespiti ile ilgili literatürde bulunan çalışmaların genel özetleri verilmiştir. Üçüncü bölümde görüntüleme teknikleri, MR görüntüleme tekniği, beyin tümörleri ve türleri, yapay zeka, derin öğrenme, derin öğrenme mimarileri ile derin öğrenme tekniğinde kullanılan kütüphaneler ve

programlama dilleri hakkında genel bilgiler verilmiştir. Dördüncü bölümde tez konusu olan beyin tümörü türlerinin tespiti için geliştirilen derin öğrenme modelleriyle gerçekleştirilen işlemlerin sonuçları gösterilmiştir. Beşinci bölümde tez çalışmasında geliştirilmiş derin öğrenme modelleri arasından önerilen model belirlenerek diğer mimarilerle yapılan çalışmalarla karşılaştırılmış ve önerilen modelin pozitif, negatif ve geliştirilebilir yönleri üzerinden tartışılması yapılmıştır.

2. LİTERATÜR TARAMASI

Beyin tümörünün tespiti ve sınıflandırılması ile ilgili birçok araştırmacı tarafından ele alınmış ve çeşitli yöntemler geliştirmişlerdir. Bu yöntemlerin çoğunda MR görüntüleri ile birlikte makine öğrenmesi ve görüntü işleme algoritmaları kullanılmıştır.

Literatürdeki makalelerde beyin tümörünün türünün sınıflandırılması üzerine bir çalışma yürütmüştür. (Ismael ve Qader, 2018) çalışmada Geri Yayılım Sinir Ağı (Back-Propagation Neural Network(BPNN)) mimarisi kullanılmıştır. Önerilen mimari, üç sınıftan oluşan MRI görüntülerinin bulunduğu veri seti üzerinde test edilmiş ve %91,9 doğruluk elde edilmiştir. (Pashaei ve ark., 2018) çalışmada bir CNN yapısıyla Aşırı Öğrenme Makineleri (ELM) algoritmasından elde edilen model kullanılmıştır. Önerilen model, üç sınıftan oluşan (menenjiyom, glioma, ve hipofiz) MRI görüntülerinin bulunduğu veri seti üzerinde test edilmiş ve %93,68 doğruluk değerine ulaşılmıştır. (Deepak ve Ameer, 2019) çalışmada beyin MRI görüntülerinden özellik çıkarımı için GoogleNet ile birlikte transfer öğrenme yöntemi kullanılmıştır. Sınıflandırma işlemi için Softmax ile birlikte SVM ve KNN algoritmaları uygulanmıştır. Çalışmada en iyi doğruluk oranı %98 ile KNN algoritması elde edilmiştir. (Swati ve ark., 2019) çalışmada transfer öğrenmeye dayalı blok bazında ince ayar stratejisini kullanarak önceden eğitilmiş bir CNN modeli önerilmiştir. Önerilen model, CE-MRI veri seti üzerinde test edilmiş ve %94,82 doğruluk elde edilmiştir. (Sultan ve ark., 2019) çalışmada, oluşturdukları yeni modelin iki farklı etikete sahip veri seti üzerinde sınıflandırma yeteneğini göstermeyi amaçlamışlardır. Önerilen modelde doğruluk oranı %96,13 olarak elde edilmiştir. (Ghassemi ve ark., 2020) çalışmada beyin MRI görüntülerinin bulunduğu veri seti üzerinde özellik çıkarımı için Generative Adversarial Networks (GAN) yapay sinir ağı tabanlı CNN modeli önerilmiştir. Önerilen model, veri seti üzerinde test edilmiş ve %95,6 doğruluk elde edilmiştir. (Hashemzahi ve ark., 2020) çalışmada Sinirsel Otoregresif Dağılım Tahmini (NADE) ve Evrişimli Sinir Ağlarından (CNN) oluşan hibrit bir model kullanılmıştır. Önerilen model, veri seti üzerinde test edilmiş ve %94,49 doğruluk elde edilmiştir. (Kaplan ve ark., 2020) çalışmada veri setinde bulunan görüntüler, önce Local Binary Pattern (Yerel İkili Model) ile

etkili özellikler elde edildikten sonra K-Nearest Neighbor (k-en yakın komşu) Yapay Sinir Ağları (ANN), Random Forest (RF) ve Lineer Diskriminant Analizi (LDA) sınıflandırma yöntemleri kullanılmıştır. Önerilen yöntem, veri seti üzerinde test edilmiş ve %95,56 doğruluk elde edilmiştir. (Rehman ve ark., 2020) çalışmada, AlexNet, GoogleNet ve VGGNet CNN modellerini kullanmışlardır. VGGNet ile %98,69 gibi en yüksek doğruluk değerini elde etmişlerdir. (Ayadi ve ark., 2021) çalışmada beyin tümörü türlerini sınıflandırmak amacıyla çeşitli katmanlara sahip yeni CNN modeli önerilmiştir. Önerilen modelin üç tür veri seti üzerinde elde ettiği %94,74 doğruluk değeri ile diğer modellere göre daha iyi performans gösterdiği görülmüştür. (Haq ve ark., 2021) çalışmada tanımlama ve sınıflandırma için iki farklı CNN mimarisi kullanılmıştır. Önerilen CNN mimarisinin, kullanılan iki veri seti üzerinde test edilmesi ile %97,3'lük bir doğruluk değeri elde edilmiştir. (Sowrirajan ve ark., 2023) çalışmada yeni oluşturulmuş CNN modellerinden VGG16-NADE kullanılmış ve diğer yöntemlerle karşılaştırılmıştır. Önerilen modelin tahmin doğruluğu %96,01 olarak elde edilmiştir. (Yerukalareddy ve Pavlovskiy, 2021) çalışmada, önerilen yeni derin öğrenme modelini, iki farklı veri seti üzerinde test etmişlerdir. Önerilen model, %98,57 doğruluk oranını göstermiştir. (Kibriya ve ark., 2022) çalışmada 13 katmanlı bir CNN mimarisi kullanılmıştır. Önerilen CNN mimarisini, üç sınıftan oluşan 3064 MRI görüntüsüne sahip veri seti üzerinde test edilmiş ve %97,2'lik en yüksek doğruluk elde edilmiştir. (Asiri ve ark., 2022) çalışmada ince ayarlı (Block-Wise) Visual Geometry Group19 (BW-VGG19) mimarisi önerilmiştir. Önerilen yöntem, CE-NRI veri seti üzerinde test edilmiş ve %98 doğruluk elde edilmiştir. (Kaya ve Çetin-Kaya, 2024) çalışmada, X-ray ile elde edilen akciğer görüntülerinde zatürre(pnömoni) hastalığının tespiti amaçlanmıştır. Dengeli ve dengesiz olarak ayrı ayrı düzenlenen veri setindeki röntgen görüntüleri, gürültülerinden ayrıştırılıp akciğer görüntüsü alınarak düzenlenmiş ve Genetik Algoritma(GA) tarafından belirlenen optimum ağırlıklarla oluşturulan yeni bir CNN mimarisi tarafından eğitilmiş ve test edilmiştir. Çalışmanın sonunda optimum sonucu veren modelin dengeli veri setinde GA tabanlı topluluk CNN mimarisi olduğu ve %97,23 doğruluk ile en yüksek değerine ulaştığı görülmüştür. (Kaya ve Çetin-Kaya, 2024) çalışmada Alzheimer hastalığının şiddetini tespit etmek için ince ayarlamalı hiperparametrelere dayalı basit bir CNN geliştirilmiştir. Önerilen model, herkese açık olan Alzheimer veri seti üzerinde eğitilmiş ve %99,53 doğruluk elde edilmiştir. (Kaya, 2023) çalışmada MRI görüntüleriyle beyin tümörü türlerinin tespiti amaçlanmıştır. Bu çalışmada veri seti 1 ve veri seti 2 olmak üzere iki ayrı veri seti kullanılmış olup, veri seti 1'deki görüntü sayısı veri seti 2'den daha azdır. Önerilen model, veri seti 2 üzerinde eğitilen, 9 evrişim katmanlı CNN mimari, %99,62 doğruluk değeri ile olağanüstü performans göstermiştir. (Çetin-Kaya ve Kaya, 2024)

çalışmada MRI görüntülerinden beyin tümörü türlerinin tespiti için farklı CNN mimarileri ile birlikte transfer öğrenme ve ince ayarlı olarak, veri ve sınıf sayıları farklı üç veri seti üzerinde eğitilmiştir. Önerilen model, en çok veriye sahip olan veri seti üzerinde eğitilmiş ve %99,92 doğruluk değeri ile yüksek bir performans göstermiştir.

3. MATERYAL VE METOT

3.1. Beyin ve Beyin Tümörü

Birbirine yakın veya aynı özellik ve fonksiyonlara sahip hücreler dokuları meydana getirirler. Beyin, omurilik ve dokulara bağlı sinir hücreleri ile desteklenen bir organdır (Dandıl, 2015). Beyin, beyincik, beyin sapı ve meninksler, beyni oluşturan yapılardır. Beynin merkezi sinir sistemini oluşturan Serebrum, beynin iki tarafında bulunan iki serebral yarıküreden oluşan en büyük bölümüdür. Frontal Lob, Parietal Lob, Temporal Lob ve Oksipital Lob gibi özel işlevlere sahip dört loba bölünmüştür. Bu loblar, konuşma, görme, işitme, akıl yürütme, hareket, duyguları kontrol edebilme, problem çözme gibi görevleri kontrol eder. Beyni, beyincik ve omuriliğe bağlantısını sağlayan beyin sapı, yaşam için önemli işlevleri kontrol eder. Beyin ve beyincik tarafından kontrol edilen işlevlere ait gerekli olan mesajlar beyin sapı tarafından iletilir. Araknoid, pia mater ve dura mater katmanlarından oluşan Meninksler, beyin ve omuriliğin korunmasını sağlar. Beyin ve omurilikte bulunan sıvı, beyin ve omurilik bölümlerinde pia ile araknoid katmanları arasında dolaşmaktadır (Salçın, 2019).

Beyin tümörü, beyin ve beyin bölgesi çevresinde bulunan bazı hücrelerin anormal derecede çoğalması ile ortaya çıkmaktadır (Polat ve Güngen, 2021). Tümör, beyinde bulunan doku üzerinde meydana gelirse birincil beyin tümörü, vücudun farklı bölgelerinde ortaya çıkan tümörün, beyin bölgesine metastaz ile ortaya çıkması ise ikincil beyin tümörü olarak tanımlanmaktadır (Saranya ve ark. 2021). Beyin tümörleri, tümörün büyüme hızı ve tedavi sonrası tekrar nüksetme durumlarına göre Derece-1, Derece-2, Derece-3 ve Derece-4 olarak derecelendirilmektedir. Derece-1 ve Derece-2 dereceli beyin tümörleri, kanser hücresi bulunmayan iyi huylu (benign), Derece-3 ve Derece-4 dereceli beyin tümörleri ise kanser hücresi bulunduran kötü huylu (malign) tümör olarak adlandırılmaktadır. İyi huylu (malign) tümörler, bulunduğu yerde yavaşça büyüyebilir, ancak çevresindeki dokulara yada organlara yayılamazlar. Kötü huylu tümörler ise yakınındaki dokulara ve diğer organlara kan ve lenf sistemleri üzerinden yayılarak tüm vücudu etkisi altına almaktadırlar (Wang ve ark., 2022). Bu tez çalışmasında Glioma, Meninjiyoma, Pituitary (Hipofiz bezi) beyin tümörü türlerinin tespiti amaçlanmaktadır. Bu türlerin ne olduğu hakkında gerekli bilgiler aşağıda anlatılmıştır.

3.1.1. Glioma


Gliomalar, beyin ve omurilikte en sık görülen tümör türüdür. Histolojik açıdan sağlıklı glial hücrelerin özelliklerine sahip oldukları için bu benzerliklerine göre adlandırılmaktadır. Gliomaların, glial hücrelerden mi, glial yada nöral sorunlarından mı, kök hücrelerden mi yoksa diğer hücre tiplerinden ortaya çıkan sorunlardan mı ortaya çıktığı belirlenememektedir (Modrek ve ark., 2014). Gliomalar, menenjiyomlar gibi en sık görülen beyin tümörlerinden biridir ve astrositom, oligodendroglioma, glioblastoma ve ependimomlar gibi türleri barındırır. Gliomalar, WHO'ya göre III-IV arasında derecelendirildiği için kötü huylu olarak sınıflandırılmaktadır. Kadınlara nazaran erkeklerde daha sık görülen gliomalar, histopatoloji yöntemiyle teşhis edilmektedir (Bush ve ark., 2017).

3.1.2. Meninjiyoma

En sık görülen beyin tümörü türüdür (Fathi ve ark., 2013). Dünya Sağlık Örgütü(WHO) tarafından en sık görüleni Derece-1(iyi huylu), intrakranyal olarak ortaya çıkan ölümcül türü ise Derece-3(kötü huylu) olarak belirtilmiştir (Wiemels ve ark., 2010). Tipik olmayan menenjiyomlar ise Derece-II olarak belirtilmiş olup, bu tür menenjiyom daha çok erkeklerde görülür. Kadınlarda daha sık görülen Menenjiyomlar, nörolojik bozukluklar, epilepsi, kafa içi basınç artışı gibi nörolojik semptomlar ile kulak çınlaması, baş ağrısı gibi spesifik olmayan semptomlar için beyin görüntüleme teknikleriyle teşhis edilebilir (Apra ve ark., 2018).

3.1.3. Pituitary (Hipofiz Bezi)

Pituitary, beynin alt bölgesinde bulunan hipofiz bezinde oluşur. Hipofiz bezi, yaşam fonksiyonları kontrol eden hormonlar üretir. Bu hormonlar sayesinde vücudun temel fonksiyonlarını ve hormonal sistemlerini kontrol edebilmektedir. Bu bölgede oluşan tümör, hormon üretimine hasar vererek hayati fonksiyonları kontrol eden bazı hormonların fazlalığına ya da eksikliğine neden olabilir (Muhammad ve Kopti, 2023). Bu tümör türü, yayılma eğilimi göstermediğinden iyi huylu olarak tanımlanmaktadır. Her ne kadar iyi huylu olarak nitelendirilse de, hipofiz tümörü, beyne yakın olduğu ve vücudun temel fonksiyonlarına ve hormonal sistemlerine etki edebileceği için kitlenin orada bırakılması sakıncalıdır (Gab Allah ve ark., 2021).



Şekil 3. 1 Glioma, Meningioma, Pituitary ve Sağlıklı Beyin MR Görüntüleri (Yazdan ve ark., 2022)

3.2. Beyin Tümörleri İçin Kullanılan Görüntüleme Teknikleri

Beyin Tümörlerinin teşhisi, türünün derecelendirilmesi, tedavi yöntemi ve takibi için Pozitron Emisyon Tomografisi (PET), Tek Foton Emisyonlu Bilgisayarlı Tomografi (SPECT), Bilgisayarlı Tomografi (CT), Manyetik Rezonans Spektroskopisi (MRS) ve Manyetik Rezonans Görüntüleme (MRI) teknikleri kullanılmaktadır. Bu tekniklerden yumuşak dokularda bile elde edilen görüntülerin yüksek kontrasta sahip olmaları ile daha iyi görüntü veren MRI tercih edilmektedir (Abd-Allah ve ark., 2019).

Beyin tümörleri için kullanılan bu görüntüleme tekniklerin her birinin ne olduğuna kısaca değinelim;

3.2.1. Pozitron Emisyon Tomografisi (PET)

Pozitron Emisyon Tomografisi (PET), nörolojik bozukluklar, enfeksiyon, epilepsi, psikiyatrik bozukluklar ve beyin tümörleri gibi hastalıkların incelenmesinde ve normal beynin fizyolojik yapısı gibi çeşitli klinik ve araştırma uygulamalarını barındıran görüntüleme tekniğidir. PET, çok az miktarda radyoaktif ilaç ile hiçbir hücre veya dokuya zarar vermeden, üç boyutlu görüntü elde edilmesine olanak tanır (Lameka ve ark., 2016).

3.2.2. Tek Foton Emisyonlu Bilgisayarlı Tomografi (SPECT)

Nükleer tıp alanında kullanılan SPECT, vücutta bulunan radyoaktif içeren bölgeyi üç boyutlu olarak görüntülenmesini sağlayan görüntüleme tekniğidir (Ritt ve ark., 2011). Metabolik ve fonksiyonel olması nedeniyle beyin tümörünün derecesinin belirlenmesinde olanak tanır (Zhang ve ark., 2020). Görüntü kalitesi, vücuda verilen ışınla ilgili sorunlar, kısmi hacim etkisi, hareket gibi nedenlerle düşmektedir. Bu durum, vücutta bulunan radyoaktif bölgenin hacimsel olarak yanlış ölçülmesine neden olmaktadır (Ritt ve ark., 2011). SPECT ve PET'in çözünürlük kalitesi, MRI ve BT'ye göre düşük olmasına karşın, tespit hassasiyeti daha yüksektir (Khalil ve ark., 2011).

3.2.3. Bilgisayarlı Tomografi (CT)

Bilgisayarlı Tomografi (Computed Tomography(CT)) insan vücudunun belirli bir bölgesinin enine kesitini görüntülemek için X-ışınını kullanan bir görüntüleme tekniğidir (Xu ve Tsui, 2013). CT, beyin farklı alanlarını tarayarak, beyinde ortaya çıkan lezyonların görüntülenmesinde kullanılır. Hastanın, protez, kalp pili gibi önemli durumları varsa, beyin tümörünün görüntülenmesinde bilgisayarlı tomografi (CT), ilk başvurulması gereken görüntüleme tekniği olmalıdır (Kördemir, 2021).

3.2.4. Manyetik Rezonans Spektroskopisi (MRS)

MRS, beyinde bulunan çeşitli biyokimyasal bileşiklerin canlı olarak sayısal değerler kazandırılmasına olanak sağlayarak beyin görüntüleme alanında devrim yaratmış bir tekniktir. Bilinen Manyetik Rezonans Görüntüleme (MRI)'nin aksine, detaylı görüntüler sunmanın ötesinde, dokuların metabolik ve biyokimyasal durumu hakkında bilgi sağlar. Bu özellikleri sayesinde MRS, çeşitli nörolojik ve psikiyatrik bozuklukların altında yatan mekanizmaları anlama konusunda güçlü bir görüntüleme tekniğidir (Singh, 2024) .

3.2.5. Manyetik Rezonans Görüntüleme (MRI)

Manyetik Rezonans Görüntüleme (MRI), canlı dokunun yüksek kontrastlı üç boyutlu görüntüsünü oluşturan ve cerrahi işlem gerektirmeyen görüntüleme teknolojisidir (Valverde ve ark., 2021). MRI, yüksek radyasyon etkisinden uzak tutarak, beyin tümörlerinin şekli, boyutu ve yeri hakkında önemli bilgiler sağlar. Mevcut klinikte, T1-ağırlıklı MR(T1w), kontrast iyileştirmeli T1-ağırlıklı MRI (T1wc), T2 ağırlıklı MRI(T2w), Proton Yoğunluklu-ağırlıklı MRI(PDw) ve sıvı zayıflatılmış inversiyon geri kazanımı (FLAIR) gibi farklı MRI dizileri ile beyin tümörü bölgelerinin teşhis edilmekte ve görüntüleri çizilebilmektedir (Liu ve ark., 2014).

3.3. Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme

3.3.1. Yapay Zeka

Zeka, karmaşık problemleri çözmek için gerekli bilgileri toplama ve bu bilgiler ışığında akıl yürütme yeteneğidir (Pannu, 2015). Bilgisayar teknolojisinin gelişmesi, internet ağının yaygınlaşması ve büyük verilerin varlığı, yapay zeka sistemlerinin gelişimini de beraberinde getirmiştir (Kavuncu, 2018). Yapay Zeka, akıllı makinelerin ve yazılımların akıl yürütebilmesi, öğrenebilmesi, bilgi toplayabilmesi, iletişim kurabilmesi nesneleri tanıyabilmesi ve algılayabilmesi gibi yeteneklerin kazanılması çalışmalarıdır. Yapay zeka, insan zekası gibi karmaşık problemleri çözebilmeyi mümkün kılan hesaplamanın çalışmaları ile ilgilidir. Yapay

zeka, hesaplama odaklı olduğundan psikolojiden farklıdır. Yapay zeka sayesinde makineler daha akıllı ve kullanışlı hale gelir. Başlıca yapay zeka alanları; Uzman Sistemler, Doğal Dil İşleme, Konuşma Anlama, Robotik ve Duygusal Sistemleri, Akıllı Bilgisayar Destekli Eğitim v.s. sayılabilir (Pannu, 2015).

3.3.2. Makine Öğrenmesi

Makine öğrenmesi, kendisine sağlanan verileri bilgisayar sistemleri aracılığıyla analiz ederek elde ettiği deneyimlerle mevcut sistemi iyileştirerek hızlı çıkarımlarda bulunabilen yapay zekanın bir alanıdır. Makine öğrenmesi algoritmaları, kurallara ihtiyaç duymadan, sahip olduğu verileri analiz ederek eğitilip benzer sorunların çözümü için öğrenilen bilgilerden tahminler üretecek şekilde yapılandırılmıştır. Metin ve belge tanıma, sınıflandırma, konuşma tanıma, bilgisayarlı görü, otonom sürüş, tıbbi teşhis, fiyat tahmini gibi birçok alanda makine öğrenmesi algoritmaları kullanılmaktadır (Choudhary ve Gianey, 2017). Denetimli, denetimsiz ve takviyeli öğrenme olmak üzere kategorilere ayrılmıştır (Çürükoğlu, 2019).

Denetimli öğrenme, girdi olarak kullanılan veri seti ile etiketli çıktı verileri üzerinden eğitilme durumudur. Denetimli öğrenme algoritmaların test aşamasında çıktı sonucu bilinmeyen verilerin, algoritmanın eğitim sonucunda elde ettiği deneyimi kullanarak, sınıflandırma yada regresyon yöntemleri ile sonuç tahmin edilmektedir. Oluşturulan bu eğitim modeli ile etiket bilgisi olmayan verilerin de sonuç tahmini yapılabilir. k-En Yakın Komşu(k-Nearest Neighbors), Destek Vektör Makinesi (Support Vector Machine(SVM)), Doğrusal ve Lojistik Regresyon, en çok kullanılan denetimli öğrenme algoritmalarıdır (Çürükoğlu, 2019).

Denetimsiz öğrenmesinde ise veri kümesine ait verilerin, sonuç bilgisi olmadan eğitilip, giriş verilerinden elde edilen özelliklere göre verilerin kümelenmesi ile sonuç tahmininde bulunur. Kümeleme (Clustering), Birliktelik Kuralları (Association Rules) ve Temel Bileşen Analizi (Principal Component Analysis(PCA)) en çok kullanılan denetimsiz öğrenme algoritmalarıdır (Metlek ve Kayaalp, 2020).


Takviyeli Öğrenme, içerisinde doğru bilindiğinde ödül, yanlış bilindiğinde ceza olan bir veri setinin, geri bildirimlerle yapay zeka sisteminin öğrenme performansının artırıldığı öğrenmedir. Takviyeli öğrenme sisteminde çevresiyle etkileşime girilmesi suretiyle öğrenme gerçekleşir. Doğru tahmin edilirse ödüllendirilir, yanlış tahminde bulunursa cezalandırılır. Bu şekilde sistem, ödülünü en üst seviyeye çıkarıp, cezasını en az seviyeye indirerek öğrenmeye çalışır (Candan ve ark., 2018).

3.3.3. Derin Öğrenme

Derin Öğrenme, sinir ağlarını optimize eden işlenmemiş veri türleriyle çalışabilmesini sağlayan algoritma sınıfıdır. Derin öğrenme algoritmaları, çok katmanlı yapay sinir ağlarından oluşup, her bir katmanda algılayıcı yer almaktadır. Yapay Sinir Ağlarının(YSA) yapısında girdi, çıktı, aktivasyon fonksiyonu ve ağırlıktan oluşan bir dizi perceptron barındırır. Derin öğrenmenin son yıllarda popülerliğini arttırmasının nedenleri arasında bilgisayar donanımı ve GPU'ların geliştirilmesi yer almaktadır. Derin Öğrenme, resim tanıma ve sınıflandırma, yüz tanıma, konuşmayı anlama, sürüş otonom sistemleri gibi alanlarda kullanılmaktadır (Erdoğan, 2019).

Derin öğrenme mimarileri, denetimli ve denetimsiz olarak eğitilmektedir. Denetimli öğrenme, etiketlenmiş verilerle sınıflandırma ve regresyon problemlerinde hedeflenen tahmin ve hatayı en aza indiren ağırlıkların belirlendiği öğrenmedir (Kaya ve ark., 2023). Denetimsiz öğrenme ise etiketlenmiş veriler kullanılmamakta olup, kümeleme, özellik çıkarma, boyut azaltma gibi problemlerde kullanılmaktadır (Ravi ve ark., 2016).

Şekil 3.2, Derin Öğrenme ile Makine Öğrenmesi arasındaki ilişkiyi daha iyi özetlemektedir;



Şekil 3. 2 Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme Arasındaki İlişki (Kavuncu, 2018)


3.4. Evrişimsel Sinir Ağları(CNN)

Evrişimli sinir ağları (CNN), görüntü işlemede kullanılan ve girdi olarak görselleri alan görüntü tanımak için kullanılan derin öğrenme algoritmasıdır (Keiron ve Ryan, 2015). Farklı işlemlerde görsellerdeki özellikleri yakalayan bu algoritma farklı katmanlardan oluşmaktadır (Cengil ve Çınar, 2016).

CNN, özellikleri belirlemede kullanılan ve ilk katmanlardan olan evrişim katmanı, havuzlama (pooling) katmanı ve ağı sınıflandırma özelliğine sahip tam bağlantılı katman olmak üzere üç yapı taşından oluşur (Keiron ve Ryan, 2015). Mimari açıdan CNN, normalleştirme, ortaklama,

seyreltme gibi katmanlara sahip ileri beslemeli yapay sinir ağlarıdır (Yılmaz ve Kavzoğlu, 2021). Aynı filtreye sahip nöronlar, uzamsal yapıyı korumak için yalnızca görüntünün yerel yamalarına bağlanır ve modelin parametre sayısını azaltmak için ağırlıkları paylaşılır (Keiron ve Ryan, 2015).

CNN'in mimari açıdan genel görünümü Şekil 3.3'de gösterilmektedir.




Şekil 3. 3 CNN Mimarisi. (Gurkahraman ve Karakış, 2021)

CNN'lerin en önemli yanı, Yapay sinir Ağları'ndaki parametre sayılarının azaltılmasıdır. Bundan dolayı geliştiricileri klasik yapay sinir ağları ile mümkün olmayan karmaşık görevleri çözmekle birlikte daha büyük modellere uğraşmaya teşvik etmektedir. CNN'de girdi olarak sunulan veriler, katmanlar derinleştikçe daha soyut özellikler elde edilmektedir. Bu durum nesne tespiti açısından oldukça önemlidir (Lu ve ark., 2017).


3.4.1. Evrişim(Convolution) Katmanı

Doğrusal ve doğrusal olmayan işlemlerin kombinasyon yöntemini kullanarak girdi olarak verilen görüntülerden özellikler çıkarılmasını sağlar. Bu katman ile evrişim filtreleri kullanılarak, görüntüden özelliklerin belirlendiği yeni görüntüler elde edilir (Yamashita ve ark. 2018). Evrişim katmanı, kullanılan filtre sayısı ile aynı sayıda özellik haritası çıkarır. Mesela, giriş görüntüsüne dört farklı 5x5 boyutlarında evrişim filtresi uygulanırsa, bu görüntüden dört farklı özellik haritası elde edilmiş olur (Kim, 2017). Şekil 3.4'te, bu katmanın evrişim filtresi ile özellik haritasının nasıl çıkarıldığını göstermektedir;



Şekil 3. 4 Evrişim katmanı işlemi (*:Evrişim işlemi, φ:Aktivasyon Fonksiyonu) (Kim, 2017)

Evrişim katmanında yapılacak işlemler için görüntü matrisi ve evrişim filtresi olmak üzere iki parametre kullanılmaktadır. Evrişim filtresi, özellik haritasını çıkarmak için görüntü matrisi üzerinde sol üst köşeden itibaren belirli adımlarla kaydırılarak, görüntü matris değerleri ile evrişim filtre değerleri çarpılır ve çarpım değerleri toplanır. Elde edilen toplam, oluşturulan özellik haritasının matris değerleri olarak atanır. Bu işlem, kaydırma işlemi bitene kadar devam eder. Ortaya çıkan özellik haritası aktivasyon fonksiyonuyla işlenerek evrişim katmanı çıktısını meydana getirir (Kim, 2017). Evrişim işleminin adım adım nasıl yapıldığı Şekil 3.5'te gösterilmiştir;






Şekil 3. 5 Evrişim İşlemi Örneği (Kızrak ve Bolat, 2018)



3.4.2. Aktivasyon Fonksiyonları

Doğrusal olmayan ses, görüntü, video ve yazı gibi karmaşık verileri, sinir ağlarına tanıtmak için kullanılmaktadır. Aktivasyon fonksiyonu kullanılmadığı takdirde sinir ağlarının eğitiminde iyileştirme olanağı olmamaktadır (Hao ve ark. 2020). Aktivasyon fonksiyonu ile eğitim ve

öğrenme daha iyi olur ve daha iyi bir genelleştirme imkanı sunar (Singh ve ark., 2023). Sigmoid, Relu, Leaky Relu, Softmax ve Tanh tercih edilen aktivasyon fonksiyonlarıdır. Son katmanda yaygın olarak kullanılan softmax fonksiyonu, ikili sınıflandırma için kullanılan sigmoid fonksiyonlardan farklı olarak çoklu sınıflandırma problemleri için kullanılabilir. Relu, sinir ağlarında yaygın olarak kullanılan bir aktivasyon fonksiyonudur. Relu kullanımının en büyük avantajı, tüm nöronların aynı anda etkinleştirilmemesidir. Relu fonksiyonu sadece gizli katmanlarda kullanılmalı, dış katmanlarda kullanılmamalıdır (Sharma ve ark., 2020).

Evrişimli Sinir Ağları'nda (ESA) en çok kullanılan aktivasyon fonksiyonları ve bu fonksiyonların matematiksel ifadesi Tablo 1'de gösterilmiştir;


Fonksiyon Grafiği	Matematiksel İfadesi
Sigmoid Fonksiyonu	
	$\text{sigmoid}(x) = \frac{e^x}{1 + e^x}$
Relu Fonksiyonu	
	$R(x) = \begin{cases} x & \text{if } x \geq 0 \\ 0 & \text{otherwise} \end{cases}$
Leaky Relu Fonksiyonu	
	$R(x) = \begin{cases} x & \text{if } x \geq 0 \\ \infty x & \text{otherwise} \end{cases}$
Softmax Fonksiyonu	

	$Y_i = \frac{e^{z_i}}{\sum_{i=0}^m e^{z_i}}$
Tanh Fonksiyonu	
	$\tan h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Tablo 1 Bazı Aktivasyon Fonksiyonların Grafiği ve Matematiksel İfadeleri (Yamashita ve ark.(2018), Bedi ve ark.(2022), Ahmadova ve ark.(2023))

3.4.3. Havuzlama (Pooling) Katmanı

Evrişimli sinir ağları mimarisinde evrişim ve aktivasyon fonksiyonlarından sonra gelen katmandır. Bu katmanın işlevi evrişim katmanından sonra girdi görüntüsündeki belirli bir alanın piksellerinin ortalamasını(ortalama havuzlama) ya da en büyük değerini(maksimum havuzlama) alarak görüntünün boyutlarını azaltmaktır. Bu katman kullanılmadığı takdirde hesaplama işlemleri maliyetli olacaktır. Bu katmanda piksel kaybı oluşsa da hesaplama işlemi azalacağı için sistemin ezberlemesi engellenmiş olur (Bayram, 2020). Hem Ortalama Havuzlama hem de Maksimum Havuzlama'nın nasıl hesaplandığı Şekil 3.6'da uygulamalı olarak gösterilmektedir;




Şekil 3. 6 Havuzlama Katmanı Örneği (Arı ve Hanbay, 2019)

3.4.4. Tam Bağlı (Fully Connected) Katman

Bu katman, CNN modellerinde daha çok son katmanlarda kullanılmaktadır. Bu katmanda bulunan nöronlar, önceki katmanların nöronlarına doğrudan bağlıdır. Bu bağlantı ile evrişim ve havuzlama katmanlarından geçen görüntü verilerinin matris değerleri tek boyutlu matris haline getirildikten sonra çıkış katmanına yönlendirilir. Sonuçta, bir görüntü verisinin, evrişim ve havuzlama katmanlarından ve bu katmanların farklı filtrelerinden çıkarılan öznetelikler üzerinde sınıflandırma işlemi uygulanmış olur (Baykal, 2019).

Evrişim ve Havuzlama katmanında aktivasyon fonksiyonu olarak ReLU kullanılırken, tam bağlantılı katmanda, 0 ile 1 arasında değer üreterek sınıflandırma işlemini uygulayan ve en çok kullanılan aktivasyon fonksiyonu olan Softmax kullanılır (Yamashita ve ark., 2018). Şekil 3,7’de 4 sınıflı çıkışa sahip CNN modelinin tam bağlı katman yapısı gösterilmektedir;




Şekil 3. 7 Tam Bağlantılı Katmanın Yapısı (Stanford.edu)

3.4.5. Seyreltme(Dropout) Katmanı

Seyreltme(Dropout) katmanı, CNN modellerinde daha çok tam bağlı katmanlardan sonra kullanılmaktadır. Bu modeller için eğitimde kullanılan veri setindeki veriler az miktarda olduğunda, model veriyi ezberlemekte ve başarı oranının düşmesine sebep olmaktadır. Bu durumu engellemek için dropout katmanı kullanılması gerekir. Seyreltme(dropout) katmanı, rastgele ya da belirlenen sınır değerine göre bazı düğüm ağırlıklarının sıfır olarak ayarlanması prensibine göre çalışmaktadır. Böylece, ağırlık değişimlerinden nöronların çok az etkilenmesi, uyumlu modellerin ortaya çıkmasına ve performansının artmasına neden olmaktadır (Türkoğlu ve ark., 2020).

Basit yapıli sinir ağında tüm nöronların kullanıldığı, dropout kullanılan ağda ise bazı nöronların kullanılmadığı Şekil 3.8’de gösterilmektedir;



Şekil 3. 8 (a) Basit Sinir Ağı Yapısı (b) Dropout katmanlı Ağ Yapısı (Türkoğlu ve ark., 2020)


3.5. CNN’de Kullanılan Hiperparametreler

3.5.1. Öğrenme Oranı(Learning Rate)

Öğrenme oranı, derin öğrenme mimarilerinde bulunan her bir düğüme ait ağırlıklar güncellendiğinde ortaya çıkan tahmini hata oranına bağlı olarak mimarinin ne kadar değiştirileceğini kontrol eden parametredir. Öğrenme oranı değeri çok küçük olduğunda eğitim süreci çok uzun sürerken, büyük değer olduğunda ise tutarsız bir eğitim süreci ile sonlanabilir (Akman, 2022).

YSA’da tavsiye edilen öğrenme oranı 0,000001 ile 0,1 arasında olmalıdır. Öğrenme oranı 0,1 ya da 0,01 girildikten sonra belli bir epoch (tekrar) sayısından sonra öğrenme oranının kademeli olarak düşürülmesi tavsiye edilmektedir (Akman, 2022).

Şekil 3.9, öğrenme oranı ile kayıp(loss) değerlerinin değişimini göstermektedir (Akman, 2022);



Şekil 3. 9 Öğrenme Oranına Göre Kayıp Değişim Grafiği (Akman, 2022)

3.5.2. Kayıp Fonksiyonu (Loss Function)

ESA mimarisi ile veri seti üzerinde uygulanan eğitim ve test işlemleri sonucunda, ulaşılması istenen sonuçla elde edilen sonuç arasındaki hata oranı, o modelin kayıp değeridir. Tahmini yüksek verebilecek bir model kurulmuşsa hedeflenen sonuç ile tahmin edilen sonuç arasındaki fark çok az olur ve kayıp değeri 0'a yakın olacaktır. Ancak fark çok olursa tahminler gerçek değerlerden oldukça sapmış olacaktır (Akman, 2022).

3.5.3. Tur (Epoch) Sayısı

ESA modeli için eğitim ve test aşamalarından önce belirlenen hiperparametredir. Epoch (Devir) sayısı küçük değer almışsa, model tam anlamıyla öğrenemez. Bu hiperparametre çok büyük değer almışsa, model aşırı öğrenmiş olur ve overfitting durumu ortaya çıkar. Bu durum modelin iyi sonuç elde edemediği sonucunu doğurur. Bu olumsuzlukları önlemek için modelin eğitim aşamasında kayıp değerlerini takip ederek en optimum epoch değerini belirlemek ya da keras kütüphanesinde yer alan 'earlystopping' özelliğini kullanarak, tahmin edilen sonucun hedeflenen seviyeye geldiği anda modelin eğitim ve test aşamasını durdurmak gerekir (Akman, 2022).

3.5.4. Optimizasyon algoritmaları

ESA modelinin eğitim ve test aşamalarında ortaya çıkan kayıpları azaltmak, modelde bulunan düğümlerin ağırlıklarını ve öğrenme oranlarını değiştirmek için kullanılan hiperparametrelerdir. Böylece elde edilecek tahmini sonuçların optimum sonuca yaklaştırılmasını sağlarlar. Gradyan İniş(Gradient Descent, Yığın Gradyan İniş(Batch Gradient Descent), Stokastik Gradyan İniş (Stochastic Gradient Descent), Küçük Yığın Gradyan İniş(Mini Batch Gradient Descent), Momentum, AdaGrad, AdaDelta, RMSProp ve ADAM(Adaptive Moment Estimation), optimizasyon algoritmalarından bazılarıdır (Dağlı, 2021);

- **Gradyan İniş:** ESA modellerinde en yaygın kullanılan algoritmadır. Sınıflandırma ve Regresyon problemleri için uygulanır. ESA'da geri yayılım(back propogation) bir gradyan iniş algoritmasıdır. Uygulanması ve hesaplanması kolaydır ancak yerel minimumda sıkışma oluşturmaması en büyük dezavantajıdır.

- **Yığın Gradyan İniş:** Eğitim için kullanılan veri setinin tümünü modelde uyguladıktan sonra parametreleri güncellemektedir. Esa'da kullanımı çok nadirdir.
- **Stokastik Gradyan İniş:** Her bir eğitim aşamasından sonra parametreleri günceller. Bununla birlikte parametrelerde yüksek varyans ve global minimum oluşur.
- **Küçük Yığın Gradyan İniş:** Stokastik Gradyan ile Yığın Gradyan'ın avantajlı yönlerini uygulayarak parametrelerin güncellemesini yapar. Yakınsama konusunda başarılı olamadığından kullanılmaz.
- **Momentum:** Stokastik Gradyan İniş'in yüksek varyans durumunu gidermek için keşfedilmiştir. Tek farkı momentum değerinin eklenmesi olup, modelin performansı açısından optimum değer girilmelidir.
- **AdaGrad:** Birçok optimizasyon algoritmaları, öğrenme hızını değiştirememektedir. Bu durum AdaGrad ile çözülmüştür. Bu algoritma, hesaplama konusunda sorun yaşamakta ve öğrenme hızının eğitim aşamalarında düşürülmesi ile eğitim durmaktadır.
- **AdaDelta:** AdaGrad algoritmasının öğrenme hızı sorununu çözen algoritmadır.
- **RMSProp:** Dikey yönde ortaya çıkan salınımları sınırlar. Bundan dolayı, öğrenme oranını arttırarak algoritmanın daha çabuk yakınsaması sağlanabilir. Bu algoritma, Momentum'a benzemektedir.
- **Adaptive Moment Estimation(ADAM):** Bu algoritmanın yaklaşımı, öğrenme hızını düşürmek ve temkinli olarak ilerlemektir (Dağlı, 2021).

3.5.5. Yığın(Batch Size) Boyutu


YSA'da bir epoch(tekrar) için eğitim veri setinden alınan örneklerin sayısını ifade eder. Bir modele yığın; Batch mod (Toplu Yığın Mod), Mini Batch Mod ve Stochastic Mod olmak üzere 3 farklı durumda verilebilir (Akman, 2022).

Toplu Yığın mod'da tüm verilerin modele yığın bir şekilde sunulmasıdır. Küçük Yığın mod, verilerin parça parça sunulması, Stochastic mod ise verilerin modele birer birer verilmesidir. Derin Öğrenme için kullanılan veriler çok büyük olduğundan, verileri, küçük yığın mod ile bölerek modele sunmak, bellek maliyetlerini azaltmakta ve modelin performansını yükseltmektedir (Akman, 2022).

Derin öğrenme modelleri için 1,2,4,8 ve 16 gibi küçük yığın mod ile Batch boyutu girilirse sonuç, daha çok gürültülü olmakta, 32,64,128 ve 256 gibi değerler girildiğinde, modelin veri sayısı, türü, tekrar (epoch) değeri ile yapılacak işleme (sınıflandırma, regresyon v.s.) bakılarak en iyi sonuç alındığı belirtilmektedir. 512, 1024 ve 2048 gibi büyük Batch değerleri girildiğinde, hesaplama konusunda daha maliyetli olmakta ve performansı düşürmesine neden olmaktadır (Akman, 2022).

3.6. Transfer Öğrenme

Bir öğrenme sürecinden elde edilen bilgilerin, becerilerin ve stratejilerin, yeni ve benzer bir bağlamda kullanılabilmesi sürecidir. Bundan dolayı, transfer öğrenme, insanların öğrenme stratejisine benzetilmektedir (Fan ve ark., 2021). İnsanlar, bir sorunun çözümüne en hızlı ve en uygun yoldan ulaşmak isterler. Çözüme ulaştıklarında elde ettikleri tecrübe, benzer sorunların çözümünde etkili olmaktadır. İnsanların elde ettiği bu öğrenme modelinde olduğu gibi, transfer öğrenme, geçmişte ortaya çıkan problemlerin çözümünde elde edilen kalıpların, yeni karşılaşılan benzer problemlerin çözümünde, sonuca daha hızlı ulaşmak amacıyla kullanıldığı bir yöntemdir (Fırıldak ve Talu, 2019). Derin öğrenme modellerinin eğitimi için kullanılan veri setinin az olması, modelin eğitimini zorlaştırdığı gibi, aşırı uyum (overfitting) sorunlarını da beraberinde getirmektedir. Transfer öğrenme modellerinde, önceki eğitim süreçlerinden elde edilen bilgi kalıpları sayesinde, az ölçekli veri seti üzerinde aşırı uyum sorunu olmadan eğitim daha etkili olmaktadır (Wang ve ark., 2020). Daha önceden eğitilmiş bir transfer öğrenme modeli, büyük ve karmaşık verileri öğrenmek için, modelde en çok işlem gören katmanlar ya da son katman pasifleştirilerek kullanılmaktadır (Rajeswari ve Nair, 2021). Transfer öğrenmeyi daha iyi özetleyen çalışma prensibi, Şekil 3.10'da gösterilmiştir (Fırıldak ve Talu, 2019);



Şekil 3. 10 Transfer Öğrenme Modellerinin Çalışma Prensibi

Çalışmamızda değerlendirilmek üzere bazı transfer öğrenme modellerini kullandık. Bu modeller ve en önemli özellikleri aşağıda belirtilmiştir.

3.6.1. VGG16

Transfer öğrenme modelleri içinde basit bir ağ yapısına sahip olup, AlexNet tarafından geliştirilmiş ve iyileştirilmiştir. Bu ağ, adından anlaşılacağı üzere 16 katmandan oluşmaktadır. Son katman hariç diğer katmanlar ReLU aktivasyon fonksiyonu kullanılırken, son katmanda Softmax kullanılmaktadır. Parametre sayısının fazla olmasından ötürü işlenmesi zordur (Güngen, 2020).

3.6.2. ResNet50

Diğer ağlardan farklı yapıya sahip bu ağ, önce ResNet (Residual Neural Network) adıyla ortaya çıkmıştır. Bu ağın giriş kısmı, diğer ağlardaki gibi olup, peşpeşe katmanlar arasında atlama bağlantısı eklenmiştir. Böylece ağın karmaşıklığı azaltılmıştır. ResNet 1000 katmandan oluşup, 20-30 katmanlı bloklar halinde çalışmaktadır (Ji ve ark. 2019).

3.6.3. DenseNet121

Yapay sinir ağlarında oluşturulan modeller uyumlu çalışsa da zamanla yeni sorunlar ortaya çıkarabilir. Ağların katman sayısının artması, önce sorunsuz davransa da belirli zaman sonra katmanlar arası açıldığından bilginin transferi zorlaşmaktadır. Bu sorunu, özniteliklerin tekrar kullanımı ile bilgi akışı sağlanarak çözülmektedir. DenseNet, katmanlar arasında L tipi bağlantısını oluşturur. Bu modele göre, her katman, bir sonraki katmana tüm öznitelikleri girdi olarak verilmektedir. DenseNet'in bilgi akışının geliştirilmiş olması, eğitimin kolaylaşmasını sağlamaktadır. DenseNet'te bulunan farklı katmanlardaki özniteliklerin birleştirilmesi, bu modelin basit ve verimli olmasını mümkün kılmaktadır (Güngen, 2020).

3.6.4. InceptionV3

InceptionV3 modeli, InceptionV1'in güncellenmiş versiyonudur (Mujahid ve ark., 2022). Bu model, 48 katmandan oluşan bir CNN'dir. GoogleNet eklentisi olarak geliştirilmiş olup, sınıflandırma, algılama ve resim tanımlamayı kolaylaştırır (Pillai ve ark., 2023). InceptionV3 modeli, düşük konfigürasyonlu bilgisayarda eğitilmiş bir CNN mimarisidir. Eğitim süreci zor olup, birkaç gün sürebilir. Bu durum, yeni veriler için son katmanını değiştirmeyen transfer öğrenme metodu ile giderilmektedir (Mujahid ve ark., 2022). Ayrıca bu model derin sinir ağların daha geniş olmasını sağlarken, parametre sayılarının yüksek olmasını engeller (Pillai ve ark., 2023).

3.7. Çalışmada Kullanılan Yazılımlar ve Kütüphaneleri

3.7.1. Python

Python, 90'lı yılların başında geliştirilen, açık kaynak kodlu, nesne tabanlı, veri analizi ve yazılım geliştirmede adından söz ettirmiş üstü düzel bir programlama dilidir. Python, kolay anlaşılır, söz dizimi kolay, sade bir programlama dili olmasının yanında Windows, Mac ve Linux tabanlarında çalışmaktadır (Kördemir, 2021).

Derin öğrenme alanında son yıllarda önemli mesafe katedilmiştir. Literatürde yapılan çalışmalara baktığımızda farklı sektörlerde derin öğrenme mimarilerinin kullanıldığı görülmüştür. Özellikle görüntü sınıflandırma alanında daha çok araştırma ve geliştirme çalışmaları yapıldığı görülmektedir. Python, derin öğrenme ve makine öğrenmesi alanında en çok kullanılan programlama dillerinden biridir. Bu tez çalışmasında Python programlama dili kullanılmıştır (Doğanay, 2022).

3.7.2. Numpy

Numpy(Numerical Python), adından anlaşılacağı üzere bilimsel hesaplamalar yapmak üzere kullanılan python kütüphanelerinden biridir. Modellerde bulunan katmanlar tarafından işlenen verilerden elde edilen çok boyutlu matrisler üzerinde hesaplamalar yapılmasını sağlayan araçları bulunduran kütüphanedir (Kördemir, 2021).

3.7.3. Scikit-Plot

Derin Öğrenme ve Makine Öğrenmesi modellerinin eğitim ve test sonuçlarını görsel açıdan görüntülemek için kullanılan ve “matplotlib” tabanlı bir kütüphanedir. Geliştirilen ağ modellerinin, “Confusion Matrix”, “ROC” eğrileri gibi performans değerlerini görüntülemek için kullanılır (Kördemir, 2021).

3.7.4. Tensorflow

Sayısal hesaplama konusunda yüksek performans gösteren, derin öğrenme ve makine öğrenmesi alanlarında kullanılan, CPU, GPU, mobil ve web platformlarında çalışabilen, birçok uygulama programlama arabirimini barındıran açık kaynak kodlu Python kütüphanesidir (Kördemir, 2021).

3.7.5. Keras

Derin öğrenme ve makine öğrenmesi kütüphanesi Tensorflow üzerine entegre edilmiş, Python dilinde yazılmış derin öğrenme arabirimidir (Kördemir, 2021).

4. BULGULAR

4.1. Veri Seti

Çalışmada kaggle sitesinde (Beyin tümörleri veriseti, 2024) bulunan veri setinde Meningioma, Glioma, Pituitary ve Normal olmak üzere hastalıklı ve sağlıklı 4 farklı sınıftan oluşan veri setini kullandık. Bu veri setinde eğitimde kullanılmak üzere 1339 Meningioma hastalıklı MRI görüntüsü, 1321 Glioma hastalıklı MRI görüntüsü, 1457 Pituitary hastalıklı MRI görüntüsü ve 1595 Normal sağlıklı MRI görüntüsü bulunmaktadır. Doğrulama verilerini eğitim veri setinden belirli bir oranda alınarak oluşturulurken, test eğitim setinde 306 Meningioma hastalıklı MRI görüntüsü, 300 Glioma hastalıklı MRI görüntüsü, 300 Pituitary hastalıklı MRI görüntüsü ve 405 Normal sağlıklı MRI görüntüsü bulunmaktadır.

4.2. Değerlendirme Metrikleri

Bu bölümde, derin öğrenme ve makine öğrenmesi alanında oluşturulan modellerin değerlendirilmesi için gerekli olan performans metriklerine göz atacağız. Modelimizin doğruluğunu detaylı bir şekilde değerlendirmek için, bu kriterlerin ne anlama geldiğini bilmemiz gerekmektedir. Bu durum, performans değerlendirmesi bakımından anlaşılmasını gerektiren bir süreç olduğu kadar modelin analiz sonuçlarını yorumlamak için kritik öneme sahiptir.

Karışıklık Matrisi

Oluşturulan CNN modelinin performansını belirlemede kullanılan bir tablodur. Sınıflandırma algoritmasının yapmış olduğu doğru ve yanlış tahminleri tablo halinde gösterir. Bu tabloda satır alanında gerçek değerleri, sütun alanında ise tahmin değerleri gösterir. Confusion Matrix(Karışıklık Matrisi)'teki bu hücreler ile f1-score, precision(kesinlik), recall(hassasiyet) ve diğer performans metriklerini hesaplamak açısından kullanılacak değerleri barındırır. Bu matrisler, ikili sınıflandırma işlemlerinde kullanıldığı gibi çoklu sınıflandırma da kullanılabilir. Tablo 2'de görüldüğü gibi karışıklık matrisi, dört parametreden oluşmaktadır (Abokhnana, 2023);

		Var olan Durum	
		Pozitif Durumlar	Negatif Durumlar
Tahmin	Pozitif	TP	FP
	Negatif	FN	TN

Tablo 2 Confusion Matrix Parametreleri

Accuracy(Doğruluk)

Sınıflandırma işlemlerinde oluşturulan modelin verdiği doğru tahminlerin toplam tahminlere oranıdır. Aşağıdaki matematiksel formüle bakıldığında anlaşılacağı üzere doğruluk, doğru tahmin sayısının toplam tahmin sayısına bölünmesi ile bulunur.

$$Doğruluk = \frac{TP + TN}{TP + FP + FN + TN}$$

Precision(Kesinlik)

Sınıflandırıcı modelin verdiği tahmini bilgilerin uygunluk durumunu belirleyen performans metriğidir. Precision(Kesinlik), pozitif tahmini girilen verilerden kaçının gerçek pozitif olduğunu gösterir. Aşağıda belirtilen matematiksel formüle bakıldığında, kesinlik, pozitif tahminlerin tüm tahminlere oranı olarak ifade edilmektedir;

$$Kesinlik = \frac{TP}{TP + FP}$$

Recall(Hassasiyet)

Sınıflandırıcı modelin başarılı olarak elde ettiği parametrelerin oranını belirleyen bir performans metriğidir. Hassasiyet(Recall) metriğinin matematiksel formülü aşağıdaki gibi ifade edilmektedir;

$$Hassasiyet = \frac{TP}{TP + FN}$$

f1-Score

Doğruluk(Accuracy) ve Hassasiyet(Recall) metriklerinin harmonik ortalaması f1-score değerini verir. f1-score, Hassasiyet ve Doğruluk değerlerini dengede tutar. f1-score metriğinin matematiksel ifadesi aşağıdaki gibidir;

$$f1 - Score = 2x \frac{Kesinlik \times Hassasiyet}{Kesinlik + Hassasiyet}$$

4.3. Önerilen Model


Geçmişteki benzer araştırma faaliyetleri ve özellikle tıbbi görüntülerde kullanılan yapay zekanın görüntü işleme alanında kullanılmasına ilişkin yaygın yöntemler göz önüne alındığında, önerilen yöntemimizde, daha önceden bilinen hazır mimarilerden farklı olarak kullanacağımız evrişim, havuzlama ve tam bağlı katman sayısını en az optimum seviyede kullanarak en iyi sonucu elde etme ve MRI görüntülerinden hangi beyin tümörü türüne ait olduğunu tespit etmek amaçlanmıştır.

Önerilen modelimizde bilinen mimarilerden farklı olarak 6 Convolutional (Evrişim) Katmanlı bir CNN modeli oluşturduk. Son katmanda ise veri setimizde 4 sınıf bulunduğundan 4 nöronlu bir çıkış katmanı oluşturduk. Bu modelimizin hiperparametre değerleri Tablo 3’de gösterilmiştir;

Layer	Filter Size	Kernel Size
Conv. Layer	16	3x3
Conv. Layer	32	3x3
Conv. Layer	64	3x3
Conv. Layer	128	3x3
Conv. Layer	256	3x3
Conv. Layer	512	3x3
Dense Layer	128	-


Tablo 3 Önerilen Modelin Hiperparametre Değerleri

Yukarıdaki tablodan anlaşılacağı gibi önerilen modelimizin CNN mimarisinde, filtre sayıları sırasıyla 16, 32, 64, 128, 256, 512 olan 6 konvolüsyon katmanından ve filtre sayısı 128 olan Dense katmanından oluşmaktadır. Modelimizin CNN mimari yapısı Şekil 4.1’de gösterilmiştir;



Şekil 4. 1 Önerilen Modelin CNN Mimarisi

Çalışmada, Pycharm Community Edition dili kullanılarak, i7 3.0 GHz işlemci, 16 GB RAM ve nVidia Geforce GTX1060 ekran kartına sahip sistemde eğitimler gerçekleştirilmiştir. Önerilen modelimiz, 6 Convolution katmanlı, veri setinin “Training” eğitim klasöründen %95 eğitim ve % 5 validation olmak üzere ayrıştırılmasıyla elde edilen bir modeldir. Veri setimizde bulunan görüntülerin 224x224x3 boyutuna getirilerek, önerilen model ile birlikte hiperparametreleri değiştirilerek oluşturulan farklı modeller tarafından eğitilmiş ve test edilmiştir. Eğitim sonunda elde edilen en yüksek doğruluk oranına sahip modelimizin her bir sınıf için ortaya çıkan Confusion Matrix değerleri Şekil 4.2’de gösterilmiştir;




Şekil 4. 2 Önerilen Modelin Confusion Matrix Tablosu

Bu tablodan önerilen modelimize ait kesinlik (precision), hassasiyet (recall) ve f1-score değerleri Tablo 4’te gösterilmiştir;

Model	Precision	Recall	F1-Score
Önerilen Model	0,99472	0,99421	0,99442

Tablo 4 Önerilen Modelin Değerleri

Önerilen modelin eğitim ve doğrulama aşamasında ortaya çıkan doğruluk ve kayıp grafiği Şekil 4.3’de gösterilmiştir;



Şekil 4. 3 Önerilen Modelin Doğruluk ve Kayıp Tablosu


4.4. En Yüksek Performanslı CNN Mimarilerinin Karşılaştırılması

Çalışmada oluşturulan farklı mimarilerden katman sayıları farklı olup, en yüksek performansı veren modellerin detaylı karşılaştırılması Tablo 5’de gösterilmiştir;


Model	Kernel_1	Kernel_2	Kernel_3	Kernel_4	Kernel_5	Kernel_6	Kernel_7	Dense	Batch_Size	Optimization	L_Rate	Epoch	Accuracy	Precision	f1-Score
4 Katmanlı ESA	3	3	3	3				64	16	*	10^{-3}	100	98,70	98,70	98,65
5 Katmanlı ESA	3	3	3	3	3			64	16	*	10^{-3}	100	99,39	99,36	99,36
6 Katmanlı ESA	3	3	3	3	3	3		128	32	**	10^{-3}	200	99,47	99,46	99,44
7 Katmanlı ESA	3	5	3	5	3	5	3	128	16	**	10^{-2}	100	99,24	99,21	99,19

Tablo 5 Farklı katmanlara sahip en iyi modellere ait performans metrikleri


Farklı katmanlarda en yüksek performansı gösteren bu mimarilerin doğruluk ve kayıp değerlerini gösteren grafik Şekil 4.4’de gösterilmiştir;



(a)




(b)




(c)

Şekil 4. 4 (a) 4 Conv. (b) 5 Conv. (c) 7 Conv. Katmanlı ESA Modellerin Doğruluk ve Kayıp Grafiği

Modeller, eğitim veri setinde eğitildikten sonra, test veri seti ile test edilip Confusion Matrix (Karışıklık Matrisi) kullanarak, doğruluk, hassasiyet ve f1-skor gibi performans metriklerini hesaplarız. Modellere ait karışıklık matrisleri, Şekil 4.5'te verilmiştir.




(b)



(c)

Şekil 4. 5 (a) 4 Conv. (b) 5 Conv. (c) 7 Conv. Katmanlı Modellerin Confusion Matrix Tablosu

Tespit ettiğimiz farklı katmanlara sahip en iyi performansı gösteren modellerimizin eğitilebilir parametre sayılarını gösteren grafik aşağıda gösterilmiştir;



Şekil 4. 6 Modelimiz ve Transfer Öğrenme Modellerinin Toplam Parametre Sayıları

4.5. Çalışmadaki CNN Mimarilerinin Karşılaştırılması

Aşağıdaki tabloda beyin MRI görüntüleri ile hastalıkların tespiti için elde edilen veri seti, convolution katmanı ve dense katmanı sayıları, batch size boyutu, optimization yöntemi, kernel size boyutu değerleri değiştirilerek oluşturulan farklı CNN modelleri ile eğitilerek en iyi modelimizi bulmaya çalıştık. Elde edilen doğruluk, hassasiyet ve f1-score değerleri Tablo 6'da özet halinde sunulmaktadır;

Con_1	Kernel_size	Con_2	Kernel_size	Con_3	Kernel_size	Con_4	Kernel_size	Con_5	Kernel_size	Con_6	Kernel_size	Con_7	Kernel_size	Dense	Batch_size	Optimization	Epoch	Accuracy(%)	Precision(%)	F1-Score(%)
16	3	32	3	64	3	128	3							64	16	*	100	98.70	98.70	98.65
16	3	32	3	64	3	128	5							64	32	**	100	87.80	90.48	86.13
16	3	32	3	64	3	128	5							128	32	**	100	98.47	98.41	98.40
16	3	32	3	64	3	128	3	256	3					64	16	*	100	99.39	99.36	99.36
16	3	32	3	64	3	128	3	256	3					128	16	**	100	98.63	98.57	98.55
16	3	32	3	64	3	128	3	256	3					128	16	**	100	98.25	98.21	98.14
16	3	32	3	64	3	128	3	256	3					128-64	16	**	100	97.10	97.08	96.89
16	3	32	3	64	3	128	3	256	3					64	16	**	100	97.48	97.49	97.37
16	3	32	3	64	3	128	3	256	3					64	16	**	150	96.87	96.89	96.63
16	3	32	3	64	3	128	3	256	3					64	32	**	150	99.39	99.34	99.35
16	3	32	3	64	3	128	3	256	3					64	64	**	100	98.86	98.85	98.81
16	3	32	3	64	3	128	3	256	3	256	3			64	16	*	100	97.64	97.60	97.45
16	3	32	3	64	3	128	3	256	3	256	3			64	16	**	100	97.79	97.74	97.62
32	3	64	3	128	3	256	3							64	16	*	100	97.33	97.37	97.18
32	3	64	3	128	3	256	3	512	3					64	16	*	100	98.02	97.97	97.87
64	3	128	3	256	3	512	3							64	16	*	100	93.52	93.73	93.20
16	3	32	3	64	3	128	3	256	3	512	3			64	16	**	100	98.86	98.83	98.79
16	3	32	3	64	3	128	3	256	3	512	3			128	32	**	100	99.31	99.30	99.28
16	5	32	3	64	3	128	3	256	3	512	3			128	32	**	100	98.32	98.31	98.20
16	5	32	5	64	5	128	5	256	5	512	5			128	32	**	100	97.25	97.32	97.06
16	3	32	3	64	3	128	3	256	3	512	5			128	32	**	100	99.16	99.18	99.13

16	3	32	3	64	3	128	3	256	3	512	5			128	32	**	130	99.01	98.99	98.97
16	3	32	3	64	3	128	3	256	3	512	5			128	32	**	150	99.01	99.03	98.98
16	3	32	3	64	3	128	3	256	3	512	5			128	32	**	180	99.39	99.42	99.38
16	3	32	3	64	3	128	3	256	3	512	5			128	32	**	200	98.47	98.46	98.38
16	3	32	3	64	3	128	3	256	5	512	5			128	32	**	100	97.56	97.54	97.37
16	5	32	3	64	3	128	3	256	3	512	3			128	32	**	150	83.07	87.92	80.00
16	3	32	5	64	5	128	3	256	3	512	5			128	32	**	100	98.86	98.80	98.79
16	3	32	5	64	5	128	3	256	3	512	5			128	16	**	100	99.24	99.22	99.19
16	3	32	5	64	5	128	3	256	3	512	5			128	16	**	100	99.39	99.38	99.36
16	3	32	5	64	5	128	3	256	3	512	5			128	16	**	100	98.78	98.72	98.71
16	3	32	5	64	5	128	3	256	3	512	5			128	16	*	100	98.70	98.66	98.61
16	3	32	5	64	5	128	3	256	3	512	5			128	16	**	125	99.39	99.38	99.36
16	3	32	3	64	3	128	3	256	3	512	3			128	32	*	100	97.71	97.72	97.59
16	3	32	3	64	3	128	3	256	3	512	3			128	32	**	100	99.24	99.26	99.21
16	3	32	3	64	3	128	3	256	3	512	3			256	32	**	100	98.63	98.58	98.55
16	3	32	3	64	3	128	3	256	3	512	3			256	16	**	100	94.51	95.08	94.07
16	3	32	3	64	3	128	3	256	3	512	3			512	32	*	100	95.19	95.35	94.87
16	3	32	3	64	3	128	3	256	3	512	3			128	32	**	100	99.24	99.26	99.21
16	3	32	3	64	3	128	3	256	3	512	3			128	32	**	130	99.39	99.38	99.36
16	3	32	3	64	3	128	3	256	3	512	3			128	32	**	150	99.31	99.32	99.28
16	3	32	3	64	3	128	3	256	3	512	3			128	32	**	170	97.86	97.84	97.71
16	3	32	3	64	3	128	3	256	3	512	3			128	32	**	200	99.47	99.46	99.44
16	5	32	3	64	3	128	3	256	3	512	3			128	32	**	100	98.32	98.31	98.20
16	5	32	3	64	3	128	3	256	3	512	3			128	32	**	150	83.07	98.92	80.00
16	5	32	3	64	3	128	3	256	3	512	3			128	32	**	100	98.32	98.31	98.20
16	5	32	3	64	3	128	3	256	3	512	3			128	32	**	150	83.07	98.92	80.00
16	3	32	5	64	3	128	5	256	3	512	5	1024	3	128	16	**	100	99.24	99.21	99.19
16	3	32	3	64	3	128	3	256	3	512	3	1024	3	512	32	**	100	87.26	90.65	86.21
16	3	32	3	64	3	128	3	256	3	512	3	1024	3	256	16	*	100	98.63	98.54	98.54

Tablo 6 Oluşturulan farklı CNN modelleri ve elde edilen sonuçlar(*:ADAM, **:SGD)

4.6. Önerilen Modelin Transfer Öğrenme Modelleri ile Karşılaştırılması

Modelimiz, VGG16, DenseNet121, InceptionV3 ve Resnet50 gibi yaygın olarak kullanılan transfer öğrenme modelleri ile, epoch, batch_size ve optimization değerleri aynı olmak koşuluyla veri setimiz üzerinde eğitilmiştir. Bu eğitim sonunda elde edilen sonuçlar, Tablo 7’de gösterilmiştir;

Model	Opt.	Batch-Size	Epoch	Accuracy(%)	Total Param
InceptionV3	SGD	32	200	92.98	22 milyon
DenseNet121	SGD	32	200	95.72	7.2 milyon
VGG16	SGD	32	200	96.87	14.8 milyon
ResNet-50	SGD	32	200	97.02	23.9 milyon
Önerilen Model	SGD	32	200	99.47	2.2 milyon

Tablo 7 Modelimizin Transfer Öğrenme Modelleriyle Karşılaştırılması

Tablo 7’deki değerlere baktığımızda modelimiz, en az parametre sayısı ile, diğer transfer öğrenme modelleri arasında en yüksek doğruluk değerini aldığı görülmüştür.

4.7. Önerilen Modelin Literatürdeki Çalışmalarla Karşılaştırılması

Önerilen modelimizin, daha önce yapılan çalışmalardan elde edilen accuracy, precision ve f1-score değerleri ile karşılaştırıldığı Tablo 8’de listelenmiştir;

Yazar	Önerilen Model	Performans Ölçütleri		
		Accuracy	Precision	F1-Score
Kaplan ve ark.	n LBPd=1 özellik çıkarma ve KNN	0,9556	0,956	0,956
Ghassemi ve ark.	Rastgele Bölünme ve GAN metodu	0,956	0,9529	0,9510
Sowrirajan ve ark.	Hibrit VGG16-NADE	0,9601	0,9572	0,9568
Sultan ve ark.		0,9613	0,9342	0,9475
Kibriya ve ark.	13 Katmanlı CNN mimarisi	0,972	0,97	0,9709
Haq ve ark.	GoogleNet Değişken mimarisi	0,973	0,9374	0,9548
Deepak ve ark.	KNN özellikli CNN	0,98	0,97	0,9749
Asiri ve ark.	BW-VGG19	0,98	0,9843	0,9821
Yerukalareddy ve ark.	GAN özellikli CNN	0,9857	0,9875	0,9865
Rehman ve ark.	İnce Ayarlı VGG16	0,9869		

Önerilen Model	6 Conv. Katmanlı CNN	0,9947	0,99462	0,99442
-----------------------	-----------------------------	---------------	----------------	----------------

Tablo 8 Önerilen Modelin Literatür'deki Çalışmalarla Karşılaştırılması

5. TARTIŞMA ve SONUÇ

5.1. Tartışma

Bu çalışma, beyin MRI görüntülerini kullanarak beyin MRI türlerinin (Meningioma, Glioma, Pituitary) otomatik tespiti için 6 Evrişim katmanlı yeni CNN modeli geliştirilmiştir. 3 farklı hastalıklı ve 1 normal olmak üzere toplam 4 sınıftan oluşan, kaggle veri tabanında bulunan veri seti kullanılmıştır. Önerilen modelimiz, literatürde yapılmış olan çalışmalardan elde edilen sonuçlara göre en iyi performansı göstermiştir.

Tablo 6’de farklı hiperparametre değerleriyle oluşturulan CNN modellerine baktığımızda SGD optimizasyon algoritmasının ADAM algoritmasından daha iyi performans gösterdiği ve kernel değerinin ilk evrişim katmanında yüksek girilmesi, performansını olumsuz yönde etkilediği ancak diğer katmanlarda kernel değerinin yüksek girildiği durumlarda performansında iyileşme görüldüğü gözlenmiştir. Dense katmanında optimum değer 128 olduğu görülmüş ve daha düşük değerlerde ADAM optimizasyon algoritmasının daha iyi sonuç verdiği belirlenmiştir. Bazı modellerde doğruluk değerleri, girilen epoch sayılarının artmasıyla düşme eğiliminde olmuşsa da tekrar yükselme eğilimine geçtiği görülmüştür.

Önerilen modelin doğruluk grafiğine baktığımızda “train” ve “validation” eğrilerinin belirli tur (epoch) değerlerinde birbirine yaklaştığı ve optimum değerler elde edildiği, belirli tur (epoch) değerlerinde ise “train” ve “validation” değerleri arasındaki farkın açıldığı ama aşırı öğrenmenin olmadığı gözlenmiştir. Modelin kayıp değeri grafiğinde bazı tur değerlerinde artmış olmasına rağmen geneline bakıldığında hem doğruluk hem de kayıp değerleri “train” ve “validation” için birbirine yakın değerlerde hareket etmiştir.

Tablo 8’de önerilen modelimizin önceki çalışmalarla karşılaştırıldığında, Kaplan ve ark. ile Deepak ve ark., veri seti üzerinde derin öğrenme modelini uygulamadan önce özellik çıkarma işlemleri uygulanmış, Ghassemi ve ark. yapmış olduğu çalışmada ise ön eğitimden geçirildikten sonra sınıflandırma modeli üzerinde tekrar eğitilmiştir. Diğer çalışmaların önerilen modelimizden daha çok katman kullanılmış ve modelimiz, önceki çalışmalardan daha yüksek doğruluk elde etmiştir.

Gelecekte, modelin performansını belirleyen diğer hiperparametre seçimi tekniklerini, farklı CNN modellerini kullanarak ve veri setindeki verilerin sayısı artırılarak daha iyi sonuçlar almak için yeni teknikler üzerinde geliştirilip test edilebilir.

5.2. Sonuç

Bilgisayar tabanlı sistemler ile MRI görüntülerdeki beyin tümörü türlerini erken teşhis etmek ve o türe ait tedavi yöntemini vakit kaybetmeden başlatmak hayati önem taşımaktadır. Bilgisayar destekli tıbbi görüntülerinden hastalık tespiti için CNN modelleri oldukça yaygın olarak kullanılmakta ve geliştirilmektedir. Çalışmamıza konu olan beyin tümörü türlerinin tespiti için literatür'e bakıldığında, GoogleNet, GAN, VGG19 ve VGG16 gibi eğitilebilir parametre sayıları yüksek olan modeller üzerinde eğitilmiş ve yüksek performans elde edilmiştir. Bizim bu çalışmamızdaki amacımız, en az eğitilebilir parametre sayısına sahip yeni bir model ile yüksek doğruluk ve en az hata oranını yakalamaktır.

Çalışmamızın amacına uygun olacak şekilde Tablo 6'da görüldüğü gibi 50 farklı model geliştirilmiş. Geliştirilen bu modeller içerisinde %99.47 doğruluk(Accuracy) değerine ulaşarak en az katman sayısı ve en az hiperparametre ile en yüksek doğruluğu elde etmiş bulunuyoruz.

6. KAYNAKÇA

- Abd-Ellah, M. K., Awad, A. I., Khalaf, A. A., Hamed, H. F. (2019), A review on brain tumor diagnosis from MRI images: Practical implications, key achievements, and lessons learned. *Magnetic resonance imaging*, Vol. 61, p: 300-318
- Abokhnana S. A. A. (2023), Tumor Detection in Spinal Cords Using Sigmoid Based CNN Algorithm, Altınbaş University Institute of Graduate Studies Information Technology, Yüksek Lisans Tezi
- Afshar P., Mohammadi A., Plataniotis K. N. (2018), Brain Tumor Type Classification Via Capsule Networks, Concordia.Institute for Information System Engineering, Concordia University, Montreal, QC, Canada, Department of Electrical and Computer Engineering University of Toronto , Toronto,ON, Canada
- Ahmadova, A., Huseynov, I., & Ibrahimov, Y. (2023), Improving Pneumonia Diagnosis with RadImageNet: A Deep Transfer Learning Approach. *Authorea Preprints*.
- Akman M. (2022), Derin Öğrenme Tabanlı Beyin Tümörü Segmentasyonu, Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi

- Apra C., Peyre M., Kalamarides M. (2018), Current Treatment Options For Meningioma, Expert Review of Neurotherapeutics, HAL Open Science, 18 (3), pp.241-249. ff10.1080/14737175.2018.1429920
- Arı, A., & Hanbay, D. (2019), Tumor detection in MR images of regional convolutional neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(3), 1395-1408.
- ARLI Ş. K. (2013), Beyin Kanseri Tedavisinin Fonksiyonel Değerlendirilmesi Ölçeğinin Türk Toplumunda Geçerlik ve Güvenirlik Çalışması, Doktora Tezi, Marmara Üniversitesi Sağlık Bilimleri Enstitüsü
- Asiri A. A., Aamir M., Shaf A., Ali T., Zeeshan M., Irfan M., Alshamrani K. A., Alshamrani H. A., Alqahtani F. F. ve Alshehri A. H. D. (2022), Block-Wise Neural Network for Brain Tumor Identification in Magnetic Resonance Images, *Computers, Materials & Continua*, Tech Science Press, vol. 73, no.3, pp. 5735-5753, doi: 10.32604/cmc.2022.03174
- Aşlıyan R. (2022), Otsu ve Rocchio Metodlarıyla Beyin Tümörü Tespiti, Araştırma Makalesi, *Avrupa Bilim ve Teknoloji Dergisi*, (43):69-74, doi: 10.31590/ejosat.1200979
- Ayadi W., Elhamzi W., Charfi I, Atri M. (2021), Deep CNN for Brain Tumor Classification, *Neural Processing Letters*, Springer, 53:671-700, doi: <https://doi.org/10.1007/s11063-020-10398-2>
- Bali M. (2020), Renal Hücre Karsinomunda Aday Tümör Baskılayıcı Bnc1, Scube3, Sfrp1 ve Pcdh8 Genlerinin Epigenetik Analizi, Yüksek Lisans Tezi, Bezmialem Vakıf Üniversitesi Sağlık Bilimleri Enstitüsü
- Barnholtz-Sloan J. S., Ostrom Q. T., Cote D. (2018), Epidemiology of Brain Tumors, *Neurologic Clinics*, Vol. 36, Issue 3, P:395-419
- Baykara O. (2016), Kanser Tedavisinde Güncel Yaklaşımlar, *Balıkesir Sağlık Bilimleri Dergisi*, Cilt:5, Sayı:3, doi: <http://dx.doi.org/10.5505/bsbd.2016.93823>
- Baykal Y. (2019), Derin Öğrenme İle Manyetik Rezonans Görüntülerde Temporomandibular Eklem Disk Deplasmanlarının Diagnozu, *Karadeniz Teknik Üniversitesi, Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi*, 74, Trabzon.

- Bayram, F. (2020), Derin öğrenme tabanlı otomatik plaka tanıma. *Politeknik Dergisi*, 23(4), 955-960.
- Bedi, P. P. S., Aggarwal, H., Narula, S., & Jain, S. (2022), Increasing the Versatility of Leaky ReLU Using a Nonlinear Function. In *Advanced Machine Intelligence and Signal Processing* (pp. 433-442). Singapore: Springer Nature Singapore.
- Beyin tümörleri veriseti, 2024, <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>, son erişim tarihi:08/08/2024
- Bush N. A. O., Chang S. M., Berger M. S. (2017), Current and Future Strategies for Treatment of Glioma, *Neurosurg Rev*, 40:1-14, doi: 10.1007/s10143-016-0709-8
- Candan, F., Emir, S., Doğan, M., & Kumbasar, T. (2018). Takviyeli Q-Öğrenme Yöntemiyle Labirent Problemi Çözümü Labyrinth Problem Solution with Reinforcement Q-Learning Method. *TOK2018 Otomatik Kontrol Ulusal Toplantısı, Kayseri*.
- Cengil E., Çınar A. (2016), A New Approach For Image Classification: Convolutional Neural Network, *European Journal of Technic, INESEG*, Vol 6, Num 2, pp. 96-103
- Choudhary, R., & Gianey, H. K. (2017). Comprehensive review on supervised machine learning algorithms. In *2017 International Conference on Machine Learning and Data Science (MLDS)* (pp. 37-43). IEEE.
- Çetin-Kaya, Y., & Kaya, M. (2024). A Novel Ensemble Framework for Multi-Classification of Brain Tumors Using Magnetic Resonance Imaging. *Diagnostics*, 14(4), 383.
- Çürükoğlu, N. (2019). Automated Demand/Suggestion Systems. In *2019 4th International Conference on Computer Science and Engineering (UBMK)* (pp. 762-766). IEEE.
- Dağlı K. (2021), Derin Öğrenme Modelleri Kullanılarak Beyin Tümörlerinin Sınıflandırılması, TOBB Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi
- Dandıl E.(2015), MR Görüntüleri ve MR Spektroskopi Verileri ile Yapay Öğrenme Tabanlı Beyin Tümörü Tespit Yöntemi ve Uygulaması, Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü
- Deepak S., Ameer P. M. (2019), Brain tumor classification using deep CNN features via transfer learning, *Computers in Biology and Medicine*, ELSEVIER

- Doğanay T. (2022), Beyin Tümör Tespiti İçin Derin Öğrenme Temelli Bilgisayar Destekli Tanı Sistemi, Gazi Üniversitesi Bilişim Enstitüsü, Yüksek Lisans Tezi
- Erdoğan, P. (2019), Deep Learning Performance on Medical Image, Data and Signals. *Sakarya University Journal of Computer and Information Sciences*, 2(1), 28-40.
- Fan, J., Lee, J. H., Lee, Y. (2021), Application of Transfer Learning for Image Classification on Dataset with Not Mutually Exclusive Classes. 2021 36th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC), Jeju, Korea (South).
- Fathi A-R., Roelcke U. (2013), Meningioma, Neuro-Oncology (Le Abrey, Section Editor) *Curr Neurol Neurosci Rep* 13:337, Doi:10.1007/s11910-013-0337-4
- Fırıldak, K., Talu, M. F. (2019), Evrimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. *Anatolian Journal of Computer Science*, 4(2), 88-95.
- Gab Allah A. M., Sarhan A. M., Elshennawy N. M. (2021), Classification of brain MRI tumor images based on deep learning PGGAN Augmentation, *Diagnostics*, 11(12), 2343
- Ghassemi N., Shoeibi A., Rouhani M. (2020), Deep neural network with generative adversarial networks pre-training for brain tumor classification based on MR images, *Biomedical Signal Processing and Control*, Elsevier, doi: <https://doi.org/10.1016/j.bspc.2019.101678>
- Gurkahraman, K., Karakış R. (2021), Veri çoğaltma kullanılarak derin öğrenme ile beyin tümörlerinin sınıflandırılması, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 997-1012
- Güngen C. (2020), Beyin Tümörlerinin Derin Öğrenme ile Manyetik Rezonans Görüntülerinden Sınıflandırılması, *Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*
- Hao W., Yizhou W., Yaqin L., Zhili S. (2020), The Role of Activation Function in CNN. *Proceedings, 2020 2nd International Conference on Information Technology and Computer Application, ITCA 2020*, 429-432, doi: <https://doi.org/10.1109/ITCA52113.2020.00096>

- Haq E. U., Jianjun H., Li K., Haq H. U., Zhang T. (2021), An MRI-based deep learning approach for efficient classification of brain tumors, *Journal of Ambient Intelligence and Humanized Computing*, Springer, doi: <https://doi.org/10.1007/s12652-021-03535-9>
- Hashemzahi R., Mahdavi S. J. S., Kheirabadi M., Kamel S. R. (2020), Detection of brain tumors from MRI images base on deep learning using hybrid model CNN and NADE, *Biocybernetics And Biomedical Engineering*, Elsevier, pp. 1225-1232, doi: <https://doi.org/10.1016/j.bbe.2020.06.001>
- Ismael M. R., Ikhlas A-Q. (2018), Brain Tumor Classification via Statistical Features and Back-Propagation Neural Network, 2018 IEEE Uluslararası Elektro/Bilgi Teknolojisi Konferansı
- İlçe A., Totur B., Özbayır T. (2010), Beyin Tümörlü Hastaların Uluslararası NANDA Hemşirelik Tanılarına Göre Değerlendirilmesi: Bakım Önerileri, *Journal of Neurological Sciences [Turkish]* 27:(2) 23:178-184
- Ji, Q., Huang, J., He, W., & Sun, Y. (2019), Optimized deep convolutional neural networks for identification of macular diseases from optical coherence tomography images. *Algorithms*, 12(3), 51.
- Kaplan K., Kaya Y., Kuncan M., Ertunç H. M. (2020), Brain tumor classification using modified local binary patterns (LBP) feature extraction methods, *Medical Hypotheses*, Elsevier, doi: <https://doi.org/10.1016/j.mehy.2020.109696>
- Kavuncu, S. K. (2018), Makine öğrenmesi ve derin öğrenme: Nesne tanıma uygulaması, Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen bilimleri Enstitüsü
- Kaya, M., & Çetin-Kaya, Y. (2024), A novel ensemble learning framework based on a genetic algorithm for the classification of pneumonia. *Engineering Applications of Artificial Intelligence*, 133, 108494.
- Kaya, M., & Çetin-Kaya, Y. (2024), A Novel Deep Learning Architecture Optimization for Multiclass Classification of Alzheimer's Disease Level. *IEEE Access*.
- Kaya, M. (2023), Bayesian Optimization-based CNN Framework for Automated Detection of Brain Tumors. *Balkan Journal of Electrical and Computer Engineering*, 11(4), 395-404.

- Kaya, M., Ulutürk, S., Kaya, Y. Ç., Altıntaş, O., & Turan, B. (2023), Optimization of Several Deep CNN Models for Waste Classification. *Sakarya University Journal of Computer and Information Sciences*, 6(2), 91-104.
- Kaya Z., Sözmen Ş., Usta C., Elbaşı E. (2023), Kanser Teşhisinde Otomatik Karar Verme, Çankaya Üniversitesi Bilgisayar Mühendisliği, TÜBİTAK
- Keleş A. (2018), Derin Öğrenme ve Sağlık Alanındaki Uygulamaları, Araştırma Makalesi, *Information Technologies & Applied Sciences, Turkish Studies*, Vol:13/21 P:113-127, doi: <http://dx.doi.org/10.7827/TurkishStudies.14189>
- Khalil, M. M., Tremoleda, J. L., Bayomy, T. B., & Gsell, W. (2011), Molecular SPECT imaging: an overview. *International journal of molecular imaging*, 2011(1), 796025.
- Kızrak, M. A., & Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.
- Kibriya H., Masood M., Nawaz M., Nazir T. (2022), Multiclass classification of brain tumors using a novel CNN architecture, *Multimedia Tools and Applications*, SPRINGER, 81:29847-29863, doi: <https://doi.org/10.1007/s11042-022-12977-y>
- Kim, P. (2017). Matlab deep learning. *With machine learning, neural networks and artificial intelligence*, 130(21), 151.
- Kördemir M., (2021), Beyin Tümörlerinin MR Görüntüleri Üzerinden Derin Öğrenme Yöntemiyle Tespiti ve Sınıflandırılması, Yüksek Lisans Tezi, Akdeniz Üniversitesi Fen Bilimleri Enstitüsü
- Lameka, K., Farwell, M. D., & Ichise, M. (2016), Positron emission tomography. *Handbook of clinical neurology*, 135, 209-227.
- Liu, J., Li, M., Wang, J., Wu, F., Liu, T., & Pan, Y. (2014). A survey of MRI-based brain tumor segmentation methods. *Tsinghua science and technology*, 19(6), 578-595.
- Lu Y., Yi S., Zeng N., Liu Y., Zhang Y. (2017), Identification of rice diseases using deep convolutional neural networks, *Neurocomputing*, Vol. 267, pp. 378-384, Elsevier,
- Metlek, S., & Kayaalp, K. (2020). Otistik Spektrum Bozukluğunun Makine Öğrenme Algoritmaları ile Tespiti. *Journal of Intelligent Systems: Theory and Applications*, 3(2), 60-68.

- Modrek A. S., Bayin N. S., Placantonakis D. G. (2014), Brain Stem Cells as The Cell of Origin in Glioma, *World J Stem Cells*. Jan 26, 2014; 6(1): 43-52 doi: [10.4252/wjsc.v6.i1.43](https://doi.org/10.4252/wjsc.v6.i1.43)
- Mora J. (2012), What is a Pediatric Tumor?, *Clinical Oncology In Adolescents And Young Adults*, Vol.:2, Page:7-15, doi: 10.2147/COAYA.S29791
- Muhammad S. D., Kobti Z. (2023), An Ensemble Deep Learning Approach for Enhanced Classification of Pituitary Tumors. In 2023 IEEE Symposium Series on Computational Intelligence p: 427-432, IEEE
- Mujahid, M., Rustam, F., Álvarez, R., Luis Vidal Mazón, J., Díez, I. D. L. T., & Ashraf, I. (2022), Pneumonia classification from X-ray images with inception-V3 and convolutional neural network. *Diagnostics*, 12(5), 1280.
- Muratdağı G., Aşıcı N., Oturak G., Kibar F. A., Keskin M., Berberoğlu U., Ekerbiçer H. Ç., Aydın A. (2019), Evaluation of Cancer News in The Media, *Araştırma Makalesi, Sakarya Tıp Dergisi* 2019 9(4):619-625, doi:10.31832/smj.562475
- O'Shea K., Nash R. (2015), An Introduction to Convolutional Neural Networks, arXiv: 1511.08458v2
- Pannu, A. (2015). Artificial intelligence and its application in different areas. *Artificial Intelligence*, 4(10), 79-84.
- Pashaei A., Sajedi H., Jazayeri N. (2018), Brain Tumor Classification via Convolutional Neural Network and Extreme Learning Machines, *ICCKE2018*, Ferdowsi University of Mashhad, pp. 314-319
- Pavlopoulou A., Spandidos A. D., Michalopoulos I. (2015), Human Cancer Databases (Review), *Oncology Reports* 33:3-18 doi: 10.3892/or.2014.3579
- Pınar M. (2022), Derin Öğrenme Yöntemleri Kullanılarak Beyin Tümörü Tiplerinin ve Sınırlarının Tahminlenmesi, Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü
- Pillai, R., Sharma, A., Sharma, N., & Gupta, R. (2023), Brain tumor classification using VGG 16, ResNet50, and inception V3 transfer learning models. In 2023 2nd International Conference for Innovation in Technology (INOCON) (pp. 1-5). IEEE.

- Polat, Ö., Güngen, C. (2021), Classification of brain tumors from MR images using deep transfer learning. *The Journal of Supercomputing*: 1-17.
- Rajeswari, S. S., Nair, M. (2021), A Transfer Learning Approach for Predicting Alzheimer's Disease. 2021 4th Biennial International Conference on Nascent Technologies in Engineering (ICNTE), NaviMumbai, India.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2016), Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4-21.
- Rehman, A., Naz, S., Razzak, M. I., Akram, F. ve Imran, M. (2020), A deep learningbased framework for automatic brain tumors classification using transfer learning. *Circuits, Systems, and Signal Processing*, 39(2), 757–775. doi:10.1007/S00034-019-01246-3/TABLES/8
- Ritt, P., Vija, H., Hornegger, J., & Kuwert, T. (2011), Absolute quantification in SPECT. *European journal of nuclear medicine and molecular imaging*, 38, 69-77
- Salçın K. (2019), A Method For Brain Tumor Classification From MRI Images Using Deep Learning And Image Enhancement Techniques, Yüksek Lisans Tezi, Institute Of Natural And Applied Sciences, Çukurova University
- Saranya, C., Priya, J. G., Jayalakshmi, P., Pavithra, E. H. (2021), Brain tumor identification using deep learning. *Materials Today: Proceedings*.
- Sharma S., Sharma S., Athaiya A. (2020), Activation Functions in Neural Networks, *International Journal of Engineering Applied Sciences and Technology*, Vol 4 Issue 12, Pages:310-316
- Singh B., Patel S., Vijavargiya A. ve Kumar R. (2023), Analyzing The Impact of Activation Functions on The Performance of The Data-Driven Gait Model. *Results in Engineering*, 18 (101029)
- Singh, V. (2024), Advancements and Applications of MR Spectroscopy in Neuroimaging: A Comprehensive Review.
- Sowrirajan S. R., Balasubramanian S., Raj R. S. P. (2023), MRI Brain Tumor Classification Using a Hybrid VGG16-NADE Model, *Article-Engineering, Technology and Techniques, BABT*, Vol. 66, doi: <https://doi.org/10.1590/1678-4324-2023220071>

- Sultan H. H., Salem N. M., Al-Atabany W. (2019), Multi-classification of brain tumor images using deep neural network, IEEE Access, 7, 69215–69225. doi:10.1109/ACCESS.2019.2919122
- Swati Z. N. K., Zhao Q., Kabir M., Ali F., Ahmed S., Lu J. (2019), Brain Tumor Classification for MR Images Using Transfer Learning and Fine-Tuning, Computerized Medical Imaging and Graphics, ELSEVIER
- Tanash A. (2020), Developing A Deep Learning Approach For Detecting Brain Cancer From Mri Images, Yüksek Lisans Tezi, Bahçeşehir Üniversitesi
- Türkoğlu, M., Hanbay, K., Sivrikaya, I. S., & Hanbay, D. (2020), Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334-345.
- Valverde, J. M., Imani, V., Abdollahzadeh, A., De Feo, R., Prakash, M., Ciszek, R., & Tohka, J. (2021). Transfer learning in magnetic resonance brain imaging: A systematic review. *Journal of imaging*, 7(4), 66.
- Wang P., Chung A. C. S., (2022), Relax and focus on brain tumor segmentation, Medical Image Analysis, 75, Article Number 102259.
- Wang, W., Liang, D., Chen, Q., Iwamoto, Y., Han, X.-H., Zhang, Q., Chen, Y.-W. (2020), Medical image classification using deep learning. In: Y.-W. Chen & L. C. Jain (Eds.). Deep Learning in Healthcare ed., Vol. 171. Springer. pp. 33-51.
- Wiemels J., Wrensch M., Claus E. B. (2010), Epidemiology and Etiology of Meningioma, Invited Review, J Neurooncol 99:307-314, Doi: 10.1007/s11060-010-0386-3
- Wrensch, M., Bondy, M. L., Wiencke, J., & Yost, M. (1993). Environmental risk factors for primary malignant brain tumors: A review. *Journal of Neuro-Oncology* 17:47-64, <https://link.springer.com/article/10.1007/BF01054274>.
- Xu, J., & Tsui, B. M. (2013). Quantifying the importance of the statistical assumption in statistical x-ray CT image reconstruction. *IEEE transactions on medical imaging*, 33(1), 61-73.
- Yamashita R., Nishio, M., Do, R. K. G., Togashi, K. (2018), Convolutional Neural Networks: an Overview And Application in Radiology. *Insights Into Imaging*, 9(4): 611-629

- Yazdan, S. A., Ahmad, R., Iqbal, N., Rizwan, A., Khan, A. N., & Kim, D. H. (2022), An efficient multi-scale convolutional neural network based multi-class brain MRI classification for SaMD. *Tomography*, 8(4), 1905-1927.
- Yazol M., Öner A. Y. (2016), Beyin Gliomlarında Manyetik Rezonans Görüntüleme, Gazi Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı, Türk Radyoloji Derneği, 2016;4, doi: 10.5152/trs.2016.332
- Yerukalareddy D. R., Pavlovskiy E. (2021), Brain Tumor Classification Based On MR Images Using Gan As A Pre-trained Model, IEEE Ural-Siberian Conference On Computational Technologies in Cognitive Science, Genomics And Biomedicine (CSGB), P:380-384, doi: 10.1109/CSGB53040.2021.9496036
- Yılmaz E. Ö., Kavzoğlu T. (2021), Derin Öğrenmenin Temel Prensipleri ve Uzaktan Algılama Alanındaki Uygulamaları, Harita Dergisi, Vol 166, pp. 25-43
- Zhang, J., Traylor, K. S., & Mountz, J. M. (2020), PET and SPECT imaging of brain tumors. In *Seminars in Ultrasound, CT and MRI*, Vol. 41, No. 6, pp. 530-540, WB Saunders
- <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks>