



T.C.
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI

DERİN ÖĞRENME YÖNTEMLERİ KULLANARAK BEYİN
TÜMÖRÜ TEŞHİSİ VE SINIFLANDIRMASI

YÜKSEK LİSANS TEZİ

Abdullah SAKIN

Danışman: Prof. Dr. Mahmut HEKİM

TOKAT- 2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Mahmut HEKİM danışmanlığında hazırlamış olduğum “Derin Öğrenme Yöntemleri Kullanarak Beyin Tümörü Teşhisi ve Sınıflandırması” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

06/08/2024

Abdullah SAKIN

İmza

ÖNSÖZ

Gerek yüksek lisans tez çalışmamın gerçekleşmesinde gerek 2 yıllık yüksek lisans eğitim sürecinde gerekse elektrik-elektronik mühendisliği eğitimimde değerli bilgilerini bizlerle paylaşan, bizleri hiç kırmadan daima olumlu yönde motive eden, yine çalışmamda konu, kaynak ve yöntem açısından bana sürekli yardımda bulunarak yol gösteren saygıdeğer danışman hocam; Prof. Dr. Mahmut HEKİM 'e, çalışmam boyunca tez konumun tıpla ilgisi sebebiyle desteklerini esirgemeyen sevgili ablam Dr. Hatice Kübra SAKIN 'a sonsuz teşekkürlerimi sunarım.



ÖZET

DERİN ÖĞRENME YÖNTEMLERİ KULLANARAK BEYİN TÜMÖRÜ TEŞHİSİ ve SINIFLANDIRMASI

Sakin, Abdullah

Yüksek Lisans, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Tez Danışmanı: Prof. Dr. Mahmut Hekim

2024, xv+53 sayfa

Derin öğrenme bir veya daha fazla gizli katman içeren yapay sinir ağları (ANN) modelleri ve benzeri makine öğrenme algoritmalarını kapsayan çalışma alanıdır. Yani en az bir adet yapay sinir ağının kullanıldığı ve birçok algoritma ile, bilgisayarın eldeki verilerden yeni veriler elde etmesidir. Bu çalışmalarla derin öğrenme birçok alanda hayatı doğru yönetme ve yönlendirmede başarılar sağlanmaktadır. Tıp alanında kullanılan derin öğrenme ise özellikle beyin tümörünü hızlı ve doğru bir şekilde tespit ederek hem hastalara hem de doktorlara büyük destek vermektedir. Ancak mevcut çözümler ve teknolojik yöntemlerin yetersizliği, bazı alanlarda veri seti içeriklerinin azlığı, yeterli çeşitlilik olmaması ve ilgili görüntülerdeki gürültü oranlarının fazlalığı bu alanlardaki başarılı uygulamaların geliştirilmesini zorlaştırmaktadır. Bununla birlikte özellikle gelişmemiş ülkelerdeki doktor başına düşen hasta sayısı, doktorların zaman zaman stres, dikkat kaybı, yorgunluk vb. nedenlerle beyin tümörünün teşhisinde yanlış veya eksik değerlendirmeler yapması insan sağlığını kötü yönde etkilemektedir. Olumsuzlukları ortadan kaldırmak ve doktorlara destek vermek adına yapılan bu çalışmada, evrimsel sinir ağı (CNN) modelleri kullanılarak beyin tümörlerinin sınıflandırılmasına odaklanılmaktadır. Beyin tümörü görüntüleri Google Colab üzerinde derin öğrenme algoritmaları RESNET50, ALEXNET, YOLOV8 ve bu tezde önerilen CNN modeli kullanılarak sınıflandırılmaktadır. Google Colab üzerinde, 4 ayrı modelden RESNET50, ALEXNET ve bu çalışmada önerilen CNN modelinde sınıflandırma yöntemiyle, YOLOV8 modelinin çeşitlerinde ise nesne tespiti yöntemiyle en yüksek öğrenme oranına sahip model tespit edilerek karşılaştırmaları yapılmaktadır. Bu çalışmada veri seti olarak kullanılan manyetik rezonans (MR) görüntüleri 4 sınıftan oluşan toplamda 7023 görüntü içermektedir. Veri setinin içeriğinde yer alan görüntüler eğitim ve test olmak üzere 2

gruba ayrılmakta ve her bir grubun içeriği 4 sınıftan oluşmaktadır. Bu gruplar sırasıyla glioma tümör, meningioma tümör, no tümör ve pituitary tümördür. Veri seti halka açık Kaggle veri tabanından alınmıştır ancak MR görüntü boyutlarının farklı olmasından dolayı yeniden düzenlenerek her bir görüntünün boyutu 300x300 olarak normalize edilmiştir. Olumsuzlukları ortadan kaldırmak ve doktorlara destek vermek adına yapılan bu çalışmada, Google Colab üzerinde 4 derin öğrenme algoritması kullanılmakta ve tüm elde edilen sonuçlar içerisinde en yüksek doğruluk oranına sahip model elde edilmeye çalışılmaktadır. Literatürde aynı veri seti üzerinde farklı modeller kullanılmış ancak Google Colab üzerinde 4 farklı model kullanılarak karşılaştırma yapılmamıştır. Yapılan çalışma ile bu eksiklik giderilmeye çalışılmıştır. Bu araştırmada, derin öğrenme yöntemleri ile farklı modeller kullanarak yüksek doğruluk oranında beyin tümörü teşhisi ve sınıflandırılması amaçlanmıştır. Beyin tümörü teşhisi ve sınıflandırılmasında RESNET50, ALEXNET, önerilen CNN modeli ve YOLOV8 derin öğrenme algoritmalarından yararlanılmaktadır. Her bir modelde farklı başarı oranları elde edilmiştir. Farklı başarı oranlarının elde edilmesinde kullanılan veri setinin modele uygunluğu etkili olmuştur.

Anahtar Kelimeler: Beyin tümörü, Derin öğrenme, Sınıflandırma, Cnn, Alexnet, Resnet50, YOLOV8.

ABSTRACT

BRAIN TUMOR DIAGNOSIS AND CLASSIFICATION USING DEEP LEARNING METHODS

Sakin, Abdullah

Master's Thesis, Department of Electrical and Electronical Engineering

Thesis Advisor: Prof. Dr. Mahmut Hekim

2024, xiii+52 pages

Deep learning is a field of study that includes Artificial Neural Networks (ANN) and similar machine learning algorithms that contain one or more hidden layers. In other words, the computer obtains new data from the available data by using at least one artificial neural network and many algorithms. With these studies, deep learning achieves success in managing and directing life correctly in many areas. Deep learning used in the medical field provides great support to both patients and doctors by detecting brain tumors quickly and accurately. However, the inadequacy of existing solutions and technological methods, the scarcity of dataset content in some areas, the lack of sufficient diversity, and the high noise levels in the relevant images make it difficult to develop successful applications in these areas. Moreover, the number of patients per doctor, especially in underdeveloped countries, causes doctors to suffer from stress, loss of attention, fatigue, etc. from time to time. For these reasons, incorrect or incomplete evaluations in the diagnosis of brain tumors negatively affect human health. This study, conducted to eliminate the negativities and support doctors, focuses on the classification of brain tumors using convolutional neural networks (CNN) models. Brain tumor images are classified on Google Colab using deep learning algorithms RESNET50, ALEXNET, YOLOV8 and the CNN model proposed in this thesis. On Google Colab, 4 different models, RESNET50, ALEXNET and the CNN model proposed in this study, are determined by the classification method, and in the variants of the YOLOV8 model, the model with the highest learning rate is determined and compared by the object detection method. Magnetic Resonance (MR) images used as the dataset in this study contain a total of 7023 images, consisting of four classes. The images in the content of the data set are divided into two groups: training and testing, and the content of each group consists of

four classes. These groups are glioma tumor, meningioma tumor, no tumor, and pituitary tumor, respectively. The data set was taken from the public Kaggle database, but due to the different sizes of the MR image size it was rearranged and the size of each image was standardized to 300x300. In this study, which is carried out to eliminate the negativities and support doctors, four deep learning algorithms are used on Google Colab, and the model with the highest accuracy rate is tried to be obtained among all the results obtained. Different models have been used on the same data set in the literature, but no comparison has been made using four different models on Google Colab. This study attempted to eliminate this deficiency. In this research, it was aimed at diagnosing and classify brain tumors with high accuracy by using different models with deep learning methods. RESNET50, ALEXNET, our CNN model, and YOLOV8 are used in brain tumor diagnosis and classification. Different success rates were obtained in each model. The suitability of the data set used in the model was effective in obtaining different success rates.

Keywords: Brain tumor, Deep learning, Classification, Cnn, Alexnet, Resnet50, YOLOV8.

İÇİNDEKİLER

Sayfa

ETİK SÖZLEŞME	i
ÖNSÖZ	ii
ÖZET	iii
ABSTRACT	v
İÇİNDEKİLER	vii
TABLolar LİSTESİ	x
ŞEKİLLER LİSTESİ	xi
KISALTMALAR VE SİMGELER LİSTESİ	xiii
1. GİRİŞ	1
2. LİTERATÜR ÖZETLERİ/KURAMSAL TEMELLER/GENEL BİLGİLER	8
2.1 Derin öğrenme	9
2.2 CNN	10
2.3 Avantajları ve dezavantajları	11
2.3.1 Avantajları	11
2.3.2 Dezavantajları	11
2.4 Katmanlar	11
2.4.1 Evrişim	11

2.4.2 Dolgu	12
2.4.3 Havuzlama	13
2.4.4 Düzleştirme	14
2.4.5 Tam bağı katman (FCN)	15
2.5 Aktivasyon fonksiyonu.....	16
2.5.1 Doğrusal fonksiyon.....	17
2.5.2 Sigmoid fonksiyonu	17
2.5.3 Tanjant fonksiyonu.....	18
2.5.4 Doğrultulmuş Lineer Birim (Relu) fonksiyonu	18
2.5.5 Softmax fonksiyonu	19
2.6. Hata fonksiyonları tablosu.....	20
2.6.1 Ortalama hata fonksiyonu.....	20
2.6.2 Çapraz entropi fonksiyonu.....	21
2.7 Derin öğrenme modellerinde kullanılan hiper parametreler	21
2.7.1 Veri setinin boyutu	22
2.7.2 Mini batch boyutu	22
2.7.3 Öğrenme hızı.....	23
2.7.4 Eğitim tur sayısı.....	24
2.7.5 Optimizasyon algoritmaları	24

2.8 CNN mimarileri	26
2.8.1 LeNet-5.....	26
2.8.2 ALEXNET	27
2.8.3 VGGNet	27
2.8.4 GoogLeNet	28
2.8.5 RESNET.....	29
2.8.6 RESNET 50.....	31
2.8.7 YOLO.....	31
3. MATERYAL ve YÖNTEM.....	33
3.1 Veri seti.....	33
3.2 Uygulanan ve Geliştirilen Modeller.....	34
3.2.1 Tasarlanan CNN Modeli Üzerinde Yapılan Çalışmalar	35
3.2.2 YOLOV8 Üzerinde Yapılan Çalışmalar	38
3.2.3 ALEXNET Modeli ile Yapılan Çalışmalar	39
3.2.4 RESNET50 Modeli ile Yapılan Çalışmalar	40
3.3 Performans Değerlendirme Kriterleri	42
4. BULGULAR ve TARTIŞMA.....	43
5. SONUÇ	48
KAYNAKLAR	49

TABLÖLER LİSTESİ

<u>Tablo No</u>	<u>Sayfa</u>
Tablo 1. Aktivasyon Fonksiyonları ve Matematiksel İfadeleri	20
Tablo 2. Hata Fonksiyon Denklemleri	21
Tablo 3. Çapraz Entropi Fonksiyonu Denklemi	21
Tablo 4. Veri seti içeriği.....	34
Tablo 5: Model analiz sonuçları.....	37
Tablo 6: Tasarımı yapılan CNN modeli eğitim adımları.....	38
Tablo 7: YOLO modelleri başarı oranları	39
Tablo 8: ALEXNET modeli eğitim adımları.....	40
Tablo 9: RESNET50 modeli eğitim adımları	41
Tablo 10: Model öğrenme oranı karşılaştırmaları.....	41
Tablo 11: YOLOV8 performans karşılaştırma sonuçları	43
Tablo 12: ALEXNET-RESNET50-Tasarlanan CNN Modeli performans karşılaştırma sonuçları.....	46

ŞEKİLLER LİSTESİ

<u>Şekil No</u>	<u>Sayfa</u>
Şekil 1. Glioma Tümör	5
Şekil 2. Menengioma Tümör	5
Şekil 3. Pituitary Tümör	6
Şekil 4. Bir CNN modelinin temel yapısı.....	10
Şekil 5. Evrişim İşlemi	12
Şekil 6. Dolgu İşlemi.....	13
Şekil 7. (a) Maksimum ortaklama, (b) Ortalama ortaklama	14
Şekil 8. Düzleştirme İşlemi.....	15
Şekil 9. FCN Yapısı	16
Şekil 10. Doğrusal Fonksiyon ve Türevi.....	17
Şekil 11. Sigmoid Fonksiyon ve Türevi.....	18
Şekil 12. Tanjant Fonksiyonu ve Türevi	18
Şekil 13. Relu Fonksiyonu ve Türevi.....	19
Şekil 14. Softmax Fonksiyonu ve Türevi	20
Şekil 15. Batch ve mini-batch hata değeri değişim grafiği.....	23
Şekil 16. Öğrenme Hızına Göre Hata değişim Grafiği	24
Şekil 17. LeNet mimari yapısı	26

Şekil 18. ALEXNET mimari yapısı	27
Şekil 19. VGGNet mimari yapısı.....	28
Şekil 20. GoogLeNet mimari yapısı.....	29
Şekil 21. 34 katmana sahip klasik derin sinir ağı ve RESNET model yapıları	30
Şekil 22. RESNET artık (residual) öğrenmenin yapı taşı.....	30
Şekil 23. RESNET50 bağlantı örneği.....	31
Şekil 24. YOLO ağ tasarımı	32
Şekil 25. Sınıflara ait tümör görüntü örnekleri	33
Şekil 26. Önerilen modelin uygulama adımları	36
Şekil 27. YOLOV8m-cls, YOLOV8n-cls, YOLOV8s-cls ROC eğrisi grafikleri	45
Şekil 28. RESNET50, ALEXNET, TASARLANAN CNN MODELİ ROC eğrisi grafikleri	47

KISALTMALAR VE SİMGELER LİSTESİ

Kısaltmalar	Açıklamalar
CNN:	Evrişimsel Sinir Ağları (Convolutional Neural Networks)
SGD:	Stokastik Gradyan İnişi (Stochastic Gradient Descent)
RELU:	Doğrultulmuş Lineer Birim (Rectified Linear Unit)
RMSPROP:	Karelerin Ortalamasının Karekökü Yayılımı (Square Root Of Mean Of Squares Spread)
MR:	Manyetik Rezonans (Magnetic Resonance)
CT:	Bilgisayarlı Tomografi (Computed Tomography)
MRI:	Manyetik Rezonans Görüntüleme (Magnetic Resonance Image)
ANN:	Yapay Sinir Ağları (Artificial Neural Networks)
FCN:	Tam Bağlı Katman (Fully Connected Layer)
ML:	Makine Öğrenmesi (Machine Learning)
UNFPA:	Dünya Nüfus Raporu (World Population Report)
CRF:	Şartlı Rastgele Alanlar (Conditional Random Fields)
MRF:	Rastgele Alanlar (Random Fields)
FCM:	Bulanık C-means (Fuzzy C-means)

1. GİRİŞ

Tüm kanserler hücrenin yaşam döngüsündeki bir problemten dolayı oluşur. Kas ve sinir hücreleri hariç vücudumuzdaki hücreler belli bir düzenle bölünme özelliğine sahiptir. Bölünme bazen onarım bazen yenileme bazen de çoğalma sebebiyle gerçekleşir. Bölünme hızı ilerleyen yaşla beraber değişir. Yaşamın ilk yıllarında daha hızlı iken sonraları zamanla azalır. Ama tüm hücreler ne zaman bölüneceğini bilir. Kanser ise, hücrelerin ne zaman bölüneceğini bilmediğinde ortaya çıkar. Fazla miktarda bölünen hücreler bir kitle yapısı halini alabilir. Hücreler bölünürken DNA adı verilen iplikçik yapısına göre hareket ederler. Kanserli hücrelerde meydana gelen bu sorunlar normalde kontrol edilerek düzeltilebilir. Düzeltilemezse hasarlı hücre öldürülür. Ama kanserli hücre meydana geldiyse bu olasılıklar gerçekleşmemiştir. Kontrolsüz şekilde çoğalma başlar. Bu kontrolsüz çoğalmanın sebebi, tümörleri engelleyici genlerin etkisinin azalması veya onkogen adı verilen kontrolsüz şekilde protein kodlayan genlerin etkisinin artmasıdır. Kanserli hücrelerin çoğalma hızı ise normal hücrelerin hızından fazladır. Meydana gelen bu kanserli hücreler çoğalarak tümörleri oluşturur. Kanserlerde erken teşhis hastalığın gidişatı için çok önemlidir. Bu yüzden belirtiler dikkate alınmalıdır. Ciddi dereceli ağrılar, ciltteki bazı değişiklikler, normalin dışındaki halsizlik hissi veya ateş belirtiler arasında olabilir. Tümörlerin oluşum süreci hücrelerin kontrolsüz büyümesi ve bölünmesi ile başlar. Normalde hücreler yaşlanır ve ölürken yeni hücreler oluşur. Ancak bazı durumlarda bu dengeli süreç bozulur ve anormal hücrelerin birikmesine neden olur. İşte tümörler de bu anormal hücre kümelerinden oluşur. İnsan vücudunda tümörler iyi huylu (benign) ve kötü huylu (malign) olarak iki farklı kategoride değerlendirilir. İyi huylu tümörler çevreye özellikle damarlara yayılımı ve lokal invazyonu olmayan, farklılaşması olan ve büyüme hızı yavaş olan tümörlerdir. Bir tümörün köken aldığı hücreye görünüm ve işlev olarak benzemesine farklılaşma denir. Farklılaşmanın hiç olmamasına yani hücrenin veya dokunun kendine has özelliklerini kaybetmesine ise anaplazi denir. Kötü huylu tümörlerde ise çevreye özellikle damarlara yayılım daha sık olup büyüme hızı ise oldukça değişkendir. Bölünme sık ve atipiktir. Lokal invazyon (yayılım) sıklığıdır. İyi huylu ve kötü huylu tümörleri ayıran en önemli kriter metastazdır. Sağ kalımı artıran en önemli faktör metastazın olmamasıdır. Tümörün toplumdaki hastalık dağılımı ve görülme sıklıkları farklılık gösterir. Erkeklerde en sık

izlenen kötü huylu tümörler prostat, akciğer, kalın bağırsak kanserleridir. Kadınlarda en sık görülen kötü huylu tümörler meme, akciğer, kalın bağırsak tümörleridir. Kadın ve erkekte en çok ölüme neden olan akciğer kanseridir. Tümörler oluşurken çevre ve genetiğin birlikte etkisi olur. Bazı tümörlerde genetiğin etkisi daha fazladır. Bu tümörler ailesel olduğu için yaşamın daha erken zamanlarında ve genellikle çoklu odaklarda görülür. Hastalığın gidişatı da daha kötüdür. Örneğin çocuklarda görülen bir çeşit göz tümörü olan retinoblastoma kalıtsal özelliği en yüksek olan tümör olup ailesel geçiş özelliği %40 oranındadır. Çevresel risk faktörleri arasında ise alkol, sigara, obezite, mesleki kanser etkenler, radyasyon, bazı virüsler, kronik hastalıklar yer alır. Alkol, dudak hariç ağız içi kanserleri, yemek borusu kanseri, karaciğer kanseri, pankreas kanseri riskini artırır. Sigara, ağız içi kanserleri, yutak, ses teli, yemek borusu, pankreas, mesane, akciğer ve böbrek kanseri riskini artırır. Sigara ve alkolün birlikteliği kanser oluşumu riskini daha da artırır. Yemek yeme alışkanlıkları; prostat, meme ve kalın bağırsak kanserlerinin gelişimini etkilemektedir. Obezite genelde tüm kanserlerin riskini artırır. Beyin tümörü ise kontrolsüz çoğalan hücre grubudur ve çoğunlukla tesadüfidir. Beyin tümörleri insan sağlığını ve yaşantısını kalitesizleştirdiği gibi önemli derecede etkili ve ölümcül olabilirler. Her beyin tümörü kötü huylu değildir. Bu nedenle beyin tümörlerinin doğru teşhis edilmesi tedavi için en önemli adımdır. Beyin tümörlerinin yanlış teşhisi durumunda ise uygulanabilecek tedavi yöntemleri de hatalı olacağından insan sağlığı, sonuçtan olumsuz etkilenir. Beyin tümörleri vücutta kitle oluşturur ve dolayısıyla kurallara uymadan sınırsız çoğalabilirler. Bu tümörler beyin, beyincik, beynin çevresindeki diğer hücreler, ona yakın dokular, sinir hücreleri ya da beyin zarında ortaya çıkabilir. Bu tümörler, beynin içinde oluşabildiği gibi, beynin çevresindeki dokulardan da kaynaklanabilir ve kafatasının içine doğru büyüyebilirler. Kafatası içine yerleşen tümörler, beyne yaptığı basınçla birlikte bulantı, kusma ve şiddetli baş ağrısı belirtileri gösterebilir. (Özdoğan, 2020; Beyazyıldız, 2020).

Dünyada yapılan istatistiki araştırma verilerine göre yeryüzünde 19.3 milyon kanser hastası olduğu tespit edilmiştir. Bu veriler 2040 yılına ötelenerek bir tespit yapıldığında ise hasta sayısı 28.4 milyon kişiye çıkmaktadır. Kanser araştırmaları ile beyin tümörü özelinde yapılan çalışmalarda her yaşta bu tümörün olabileceği ortaya konmuştur. Aynı

zamanda insan yaşlandıkça bu oran da artmaktadır. Birleşmiş Milletler tarafından 2022 yılında yapılan açıklamaya göre dünya nüfusu 8 milyarı aşmıştır. Yine Birleşmiş Milletlere göre, 1950-2010 arasında ortalama yaşam süresi 46'dan 68 yıla çıkarken 2020'de bu oran 73.2'ye yükselmiştir. İşte bu araştırma sonuçları bize yaşlanma ile birlikte beyin tümörü hastalıklarının da hızla artacağını göstermektedir (Dünya nüfus raporu [UNFPA], 2022).

Beyin tümörleri insan sağlığını ve yaşantısını kalitesizleştirdiği gibi önemli derecede etkili ve ölümcül olabilir.

Beyin tümörleri iyi huylu ya da kötü huylu olabilir.

1. Beyin tümörü riskini artıran faktörler

- Kafa bölgesine yapılan ısınlama
- İmmün-supresyon (Vücudun antijene karşı göstereceği yanıtın önlenmesi)
- Bazı kalıtsal hastalıklar
- NF1: vücudun birçok sistemini etkileyebilen genetik bir hastalık
- VHL: birçok organda neoplazi gelişimi ile seyreden kalıtsal bir hastalık
- Tuberoskleroz: Beyinde, deride ve bazı başka dokularda tümöral lezyonlar ve nöbetlerle seyreden genetik bir hastalık
- İleri yaş
- Radyasyon tedavisi ya da radyasyona maruz kalmak
- Hormon tedavisi almak
- Diğer organlardaki kanserli dokunun beyne sıçraması, metastaz yapması.
- Menengioma (Beynin etrafını saran, onu koruyan, dura adı verilen zardan kaynaklanan ve beyinde en çok rastlanan tümörlerden birisidir.) Kadınlar da daha sık görülür.
- Aile öyküsü

2. Beyin Tümörü Belirtileri

- En sık bulgu baş ağrısıdır

- Görme bozuklukları (görme kaybı, bulanık görme, çift görme ve epilepsi nöbetleri)
- Kişiliğin değişmesi
- Bulantı ve kusma

3. Beyin tümörleri tanısı

- Bilgisayarlı tomografi (CT)
- Manyetik rezonans (MR)
- Biyopsi


4. Beyin tümörlerinin genel tedavisi

- Cerrahi tedavi
- Radyoterapi (ışın tedavisi)
- Kemoterapi (ilaç tedavisi)

Derin öğrenme çalışmasına konu olan ve sıkça rastlanan tümörler şunlardır:

1. Glioma tümörler


Glioma tümör, genellikle beyinde veya omurilikte oluşan bir tümör çeşididir ancak omurilikte de oluşabilir. Astrositomlar, ependimomlar ve oligodendrogliomalar dahil olmak üzere türleri bulunmaktadır. Glioma tümör glial hücreler kontrolden çıktığında oluşur. Normalde bu hücreler sinirleri destekler ve merkezi sinir sistemimizin çalışmasına yardımcı olur. Gliomalar çocukları veya yetişkinleri etkileyebilir. Bazıları çok hızlı büyür. Gliomaları olan çoğu kişi, cerrahi, radyasyon tedavisi ve kemoterapi gibi tedavilerin bir kombinasyonuna ihtiyaç duyar. Gliomlar genellikle kötü huyludur. Bazıları çok yavaş büyüyebilir. Bunlar birincil beyin tümörleridir, yani beyin dokusunda ortaya çıkarlar. Gliomlar genellikle beyin veya omurganın dışına yayılmazlar. Beynin diğer bölgelerine doğru büyür (Anonim, 2021). Şekil 1’de glioma tümör örneği görülmektedir.



Şekil 1. Glioma Tümör (Anonim,2021)

2. Menengioma tümörler


Şekil 2’de görünen menengioma tümörler sert ve sınırlı, iyileşme şansı olan ve beyin etrafını saran, onu koruyan dura adı verilen zardan kaynaklanan tümörlerdir. Beyinde en çok rastlanan tümör çeşididir. Genellikle beyin tümörlerinin %15-20 kadarını oluşturdıkları bilinir (Peker,2024).



Şekil 2. Menengioma Tümör (Anonim,2021)

3. Pituitary tümörler (Hipofiz tümörü)

Hipofiz tümörleri, hipofiz bezinde gelişen alışılmadık tümörlerdir. Bu bez, bezelye büyüklüğünde bir organdır. Beynin tabanında, burnun arkasında yer alır. Bu tümörlerden bazıları, hipofiz bezinin önemli vücut fonksiyonlarını kontrol eden belirli hormonları çok fazla üretmesine neden olurken bazıları da hipofiz bezinin bu hormonları çok az üretmesine neden olabilir. Çoğu iyi huylu olup kanser değildir. Bu kanserli olmayan tümörlerin bir diğer adı da hipofiz adenomlarıdır. Çoğu adenom hipofiz bezinde veya etrafındaki dokuda kalır ve yavaş büyür. Genellikle vücudun diğer bölgelerine yayılmazlar (Anonim, 2024).



Şekil 3. Pituitary Tümör (Anonim,2021)

Tümöre yönelik tedaviler, tümörün kötü huylu, iyi huylu ve konumu dahil olmak üzere birçok faktöre bağlıdır. Kanserli olmayan tümörlerin birçoğu için tedaviye ihtiyaç duyulmamaktadır. Ancak bazı iyi huylu tümörler için aynı şeyi söyleyemeyiz çünkü büyümeye devam edebilirler. Örneğin, iyi huylu beyin tümörleri sağlıklı hücreye baskı yaparak görmeyi veya konuşmayı etkileyebilir. Derin öğrenme temelli bu çalışmanın amacı, insan için ölümcül olan beyin tümörlerinin ve çeşitlerinin tespitini yüksek doğruluk oranıyla gerçekleştirmektir. Aynı zamanda insan hayatını kurtarmaya

kendilerini adayan hekimlerimize bir nebze de olsa yardımcı olabilmektir (Anonim, 2024).

Bu tezde, ölümcül sonuçlara sebep olacak bu hastalığın tespitinin sadece insan algısına bırakılmaması, gelişen teknoloji ile birlikte insana ait zayıflıklardan uzak makine öğrenmesi (ML) yardımıyla hekimlerimize destek sağlanması amaçlanmaktadır.



2. LİTERATÜR ÖZETLERİ/KURAMSAL TEMELLER/GENEL BİLGİLER

Beyin tümörü tanısı görüntüleme yöntemleri, hastaların tıbbi öyküsü ve nörolojik muayene sonucunda konulmaktadır. Patolojik incelemeler sonucunda ise beyin tümörü kesin olarak teşhis edilmektedir. Derin öğrenme yöntemleriyle beyin tümörünün kısa sürede doğru bir şekilde teşhis edilebilmesi hastalığa yönelik tedavi şeklinin hızlıca seçilerek uygulanabilmesi ve elde edilen verilerin yönetiminin kolaylaştırılabilmesi söz konusudur. Bilişim sektörünün tıp alanında faydalanılabilir hale getirilmesi ile gerek maliyet gerekse zaman açısından oldukça fazla tasarruf edilebilir. Literatürde beyin tümörü teşhisine odaklanan birçok çalışma bulunmaktadır. Tez çalışmasına konu olan yöntemlerle ilgili literatür çalışmaları aşağıda sunulmuştur.

Rehman ve arkadaşları yaptığı çalışmada, transfer öğrenimi kullanarak beyin tümörü sınıflandırmasında sahip olunan doğruluk oranını artırmayı amaçlamıştır. Çeşitli mimarileri denedikten sonra en iyi sonucu VGG16 mimarisinde elde etmişlerdir (Rehman ve ark., 2020).

Sajjad ve arkadaşları yaptığı araştırmada kısıtlı veri sayısının evrimsel sinir ağları (CNN) için bir problem olduğunu belirterek, veri çeşitlendirmenin etkisi üzerine çalışmıştır. VGG19 mimarisini kullanarak veri sayısının çeşitlendirme olmadan ve çeşitlendirme ile doğruluk oranı üzerindeki etkisini incelemiştir (Sajjad ve ark., 2019).

Li ve arkadaşları tarafından yapılan çalışmada beyin tümörü segmentasyonu için tam otomatik bir algoritma geliştirmek amacıyla Markov, Rasgele Alanlar (MRF) ve ayrık gösterimi birleştirmişlerdir. Tümör segmentasyonu çoklu sınıflandırma problemi olarak ele alınmıştır (Li ve ark., 2016).

Kaur tarafından yapılan bu çalışmada manyetik rezonans görüntüleme (MRI) görüntülerinde tümör çıkarımı için Otsu, K-means, bulanık C-means (FCM) ve eşikleme olmak üzere dört farklı yöntem kullanılmıştır. Tamamen otomatik tümör çıkarımı yapan yöntem literatürde diğer mevcut yöntemlerle karşılaştırılmış ve daha az zaman alan, daha verimli ve daha doğru bir yaklaşım sunduğu gösterilmiştir (Kaur, 2016).

Kamnitsas ve arkadaşları tarafından yapılan çalışmada, DeepMedic'e dayalı 3D CNN mimarisinden oluşan otomatik beyin tümör segmentasyon yöntemi kullanılmıştır. Mevcut

yöntemden yola çıkılarak iki paralel bağlantı katmanı eklenip ortaya çıkan gelişmeler sunulmuştur (Kamnitsas ve ark., 2016).

Kamnitsas ve arkadaşları tarafından yapılan bir diğer çalışmada, beyin tümörlerinin segmentasyonu için çift yollu ve derin katmanlı bir 3D CNN mimarisi sunulmuştur. Önerilen çift yollu mimari ile küresel ve yerel bağlamsal bilgiler birleştirilmiştir. Sonrasında ise yanlış pozitifleri gidermek için 3D tam bağlı koşullu rasgele şartlı rastgele alanlar (CRF) uygulanmıştır (Kamnitsas ve ark., 2017).

Pereira ve arkadaşları tarafından yapılan çalışmada, CNN ile hiyerarşik beyin tümörü segmentasyonu yaklaşımı önerilmiştir. Bu yaklaşım ile sadece tümörün bir bütün olarak tespit edilmesinin değil aynı zamanda nekroz ve ödem gibi bölgelerin de daha iyi tanımlandığı belirtilmiştir. Kullanılan performans metrikleri ile hiyerarşik yaklaşımın tümörün tüm bölümleri için istatistiksel olarak anlamlı segmentasyonlar yaptığı ortaya konulmuştur (Pereira ve ark., 2017).

Arunkumar ve arkadaşları tarafından yapılan bu çalışmada yapay sinir ağı (ANN) kullanılarak beyin tümörleri için tam otomatik model tabanlı bir segmentasyon ve sınıflandırma yaklaşımı literatüre kazandırılmıştır. MRI görüntülerinde, ilgi alanlarının saptanması için kullanılan bu yöntem manuel segmentasyon ile karşılaştırılmış ve 200 MRI görüntüsü üzerinde yapılan bu deneysel çalışmalarda doku özelliklerinin ayrıştırılmasında elle ilgi alanlarının saptanmasına karşı daha iyi performans sağladığı belirtilmiştir (Arunkumar ve ark., 2020).

2.1 Derin öğrenme


Derin öğrenme modelleri, doğru ve aynı zamanda tutarlı çıktılar geliştirmek için metinler, resimler, sesler ve başka verilerdeki anlaşılması daha zor modelleri öğrenebilir. Görüntüleri tanımak veya bir ses dosyasını text formatına dönüştürmek gibi insan zekâsı gerektiren uygulamaları sürekli hale getirmek için derin öğrenme yöntemleri tercih edilebilir (Anonim,2023).

Derin öğrenme algoritmaları, insan beyninden alıntı yapılarak tasarlanan sinir ağlarıdır. Bir insan beyni, veriyi öğrenmek ve bu öğrendiği bilgiyi kullanmak için beraber çalışan

binlerce hatta milyonlarca birbirine bağılı nöron barındırır. Aynı şekilde, derin öğrenme veya ANN, bilgisayar içinde hep beraber aynı anda işlem yapan birden fazla yapay nöron katmanından oluşur. Derin öğrenme hayatımızın birçok alanında bizlere eşlik eden bir ML yöntemidir. Bunlara örnek olarak yüz ve ses tanımlama sistemleri, araçlarda sanki insan kullanıyormuş gibi otopilot görevini üstlenmesi, alarm sistemleri, sağlık sektöründe birçok araştırmada, görüntü ve işaret iyileştirilmesi, siber saldırılara ilişkin tehdit analizlerini gösterebiliriz (Anonim,2021).

2.2 CNN

Derin öğrenme içerisinde birçok mimari bulundurulur. Bunlardan birisi ve günümüzde en yaygın kullanım alanına sahip olan ise CNN'dir. Bu mimarideki işleyiş şu şekildedir, ilk olarak giriş verisi olarak bir görüntü alır. Daha sonra giriş katmanındaki görüntüdeki bazı kısımlara ağırlıklar atar. Ancak atanan bu ağırlıklar görüntüyü daha iyi algılaması için sabit kalmaz değişebilir. Ayrıca bu sistem tıpkı insanların şekilleri birbirinden ayırt ettiği gibi görüntüleri sınıflandırma özelliğine sahiptir. CNN'in temel yapı taşları ortaklama, evrişim ve tamamen bağılı katmandır. Aşağıdaki şekilde CNN'nin yapısı mevcuttur (Dağılı, 2021).



Şekil 4. Bir CNN modelinin temel yapısı (Dağılı, 2021)

2.3 Avantajları ve dezavantajları

ANN birçok avantajı ve dezavantajı bulunmaktadır. Bunlar aşağıda sıralanmıştır.

2.3.1 Avantajları

- ANN'nin en önemli avantajlarından biri önceki yapılan çalışmadan öğrendiklerini hafızasında tutuyor olabilmesidir. Böylece yeni bir girdi sunulduğunda hemen tepki gösterebilir.
- Herhangi bir matematiksel modellemeye ihtiyaç duymazlar.
- Geleneksel bilgisayar sistemleri ile kıyaslandığında ANN hata toleransları daha yüksektir.
- ANN yapı olarak doğrusal bir yapıya değil karmaşık bir yapıya sahiptir. Dolayısıyla doğrusal teknikler ile karşılaştırıldığında karmaşık problemleri çözme yeteneği daha fazladır.

2.3.2 Dezavantajları


- Her zaman hata yapma payı vardır. Bu yeterli veri kümesi olmamasından ya da uygun fonksiyonun bulunmamasındandır.
- ANN eğitimleri uzun sürmektedir.
- Uygulamadaki çok küçük bir değişiklik bile bize zamansal anlamda çok fazla süre olarak dönebilmektedir (Tolon ve Tosunoğlu, 2008).

2.4 Katmanlar

2.4.1 Evrişim


Bu katman CNN'nin temellerini oluşturan ve sinir ağındaki yük dağılımının yapıldığı katmandır. CNN' de birden fazla evrişim katmanı bulunabilir. Bu sayı arttığında yapı daha fazla nitelik kazanır ve öğrenme kapasitesi daha fazla artar. İlgili katmanda birçok özellik belirlenir. Bunlardan bazıları renkler, kenarlar vb. dir. Evrişim katmanında iki matris arasında bir çarpım gerçekleşiyor diyebiliriz. Bu çarpım evrişim filtresiyle filtrenin görüntü üzerinde kapladığı alanın çarpımıdır. Sonuç değeri de bize çıktıyı vermektedir. Bu işlem giriş görüntüsünün tamamında uygulanır ve elde edilen görüntü bize sonuç çıktısını verir. Elde bulunan filtreyi giriş görüntüsü üzerinde farklı şekilde kullanabiliriz.

Bu kullanımdan kasıt filtrenin giriş görüntüsü üzerindeki adım değeridir. Adım değeri ne kadar büyük olursa elde edilen çıktı o kadar küçülür. Adım değeri ne kadar küçükse de elde edilen çıktı boyutu o oranda artacaktır (Mayank, 2020).



2.4.2 Dolgu


Evrişim katmanında bir girdi görüntüsüne filtre uygulayarak sonuç çıktısı aldığımızı belirtmiştik. Ancak filtreyi doğru şekilde işlemezsek sonuç çıktısı yanıltıcı olabilir. Burada devreye dolgu girmektedir. Evrişim işlemini yapmadan önce girdi görüntüsünün 4 kenarını kaplayacak şekilde sıfırlar eklenir. Bunun nedeni şudur örneğin girdi görüntüsü 6×6 şeklinde olsun ve buna uygulanacak filtre boyutu da 4×4 olsun. Sonuç çıktısı giriş görüntüsü ile aynı boyutta olması beklenemez. Durum böyle olunca da bilgi kaybı olması kaçınılmaz olur. Bu durumu önlemek için dolgu işlemi yapılması zorunludur. Aşağıda anlatılan işlemin görseli mevcuttur (Dağlı, 2021).



Şekil 6. Dolgu İşlemi (Dağlı, 2021).

2.4.3 Havuzlama


Havuzlama katmanı CNN’de bulunan katmanlardan bir diğeridir. Havuzlama katmanı bu mimaride yer alan önemli katmanlardan biridir. Daha önce de belirttiğimiz gibi veri setinde yer alan görüntüler bazen boyut olarak çok büyük ve yoğun olabilmekte bu da sonuç çıktısının verimli olmasının önüne geçebilmektedir. Burada havuzlama katmanı devreye girmektedir. Havuzlama katmanındaki asıl yapılmak istenen bu büyük görüntüleri sadeleştirmektir. Peki bu işlemi nasıl gerçekleştireceğiz? Temel olarak 2 yöntem bulunmaktadır. Bunlar ortaklama havuzlama ve maksimum havuzlamadır. Ortaklama havuzlama yönteminde filtrenin içeriğinde yer alan değerlerin ortalamasını kullanır. Maksimum havuzlama ise maksimum değeri göz önünde bulundurur. Bu iki yöntem arasında en çok tercih edilen ise maksimum havuzlama yöntemidir. Veri kümesinin içeriğinde bulunan görüntülerin gürültü miktarı bazen fazla olabilmektedir. Bu da sonuç çıktısını etkileyerek verimli bir sonuç almanın önüne geçmektedir. Maksimum havuzlama yöntemi kullanıldığında bu gürültü oranları da düşmektedir. Maksimum havuzlama yönteminde görüntünün eni ve boyu azaltarak verideki asıl ve diğer parametrelere oranla daha önemli özellikler ortaya çıkarılmaya çalışılır (Dağlı, 2021; Doğan, 2020).



Şekil 7. (a) Maksimum ortaklama, (b) Ortalama ortaklama (Dağlı, 2021)

2.4.4 Düzleştirme


Düzleştirme katmanı tamamen bağlı katmana geçmeden önceki son adımdır. Bu katman evrişimsel katmandan veya havuzlama katmanından geçen verileri kullanır. Daha sonra ise bu değerler sinir ağına girdi olarak kullanılır. Buradaki asıl amaç isminden de anlaşılacağı üzere veriyi düzleştirmektir. Örneğin 2×2 'lik bir vektörü 1×4 'lük bir vektöre dönüştürebilir. Aşağıdaki görselde bu işlem anlatılmıştır (Dağlı, 2021; Doğan, 2020; Akdağlı, 2021).



Şekil 8. Düzleştirme İşlemi (Dağlı, 2021)

2.4.5 Tam bağı katman (FCN)

FCN için öğrenme işleminin tam olarak gerçekleştiği katman diyebiliriz. Bu katmana gelinceye kadar görüntü ilk olarak evrişim katmanından daha sonra ise havuzlama ve düzleştirme aşamalarında geçmiştir. Bu katman birçok düğüm noktası ve nöronları içeren bir yapay sinir ağı merkezidir. Bu katmanda ağırlık hesaplamaları en verimli ve doğru sonucu elde etmek için sürekli değişeceğinden yoğun bir işlem içerecektir. Bundan dolayı da işlem yoğunluğu açısından fazla yük taşımaya meyillidir. Ancak yüzde yüz doğruluk oranı ile hangi görüntünün hangi sınıfa ait olduğu tespit edilememektedir. Dolayısıyla da belirli bir hata yapma payı her zaman olacaktır. Buna CNN’de hata fonksiyonu adı verilir (Dağlı, 2021; Doğan, 2020; Sayracı, 2021).



Şekil 9. FCN Yapısı (Koç, 2022)


2.5 Aktivasyon fonksiyonu

ANN aktivasyon fonksiyonunun görevi karar verici olmasıdır. Yani toplam ağırlığı hesaplayarak sinir ağındaki bir nöronun aktif olup olmayacağını belirler. Bizler her zaman bir yapay sinir ağıının derin, karmaşık yapıda ve öğrenme kapasitesinin yüksek olmasını isteriz. Eğer sinir ağıımız böyle bir yapıda değilse ilkel kalacaktır. Bununla birlikte istediğimiz yüksek oranda verimli ve doğru sonuçlar elde edilemeyecektir. Aktivasyon fonksiyonları aslında tam da bu noktada devreye girmektedir ve yapay sinir ağını doğrusal olmaktan çıkararak karmaşık problemlerin çözümüne hazırlar ve öğrenme kapasitesini artırır. Bir yapay sinir ağını basitçe anlatacak olursak girdiler x olarak ağırlıklar w olarak adlandırılır ve bir de çıktı değeri vardır bu çıktı değerine $f(x)$ aktivasyon fonksiyonu uygulanır ve bir sonraki katmanın girişine aktarılır. Birçok aktivasyon fonksiyonu bulunmaktadır. Bu aktivasyon fonksiyonları ile ilgili bilgiler

aşağıda yer almaktadır. Softmax fonksiyonu beyin tümörü teşhisi ve sınıflandırmasında kullanılan modellerde aktivasyon fonksiyonu olarak belirlenmiştir. (Kızrak, 2019)

2.5.1 Doğrusal fonksiyon

Daha önce de belirttiğimiz gibi her zaman yapay sinir ağımızın karmaşık, derin ve öğrenme kapasitesinin yüksek olmasını isteriz. ANN geri yayılım ile öğrenmeyi gerçekleştirir. Maalesef doğrusal fonksiyonlar kullanarak bunu sağlayamıyoruz. Bunun nedeni ise doğrusal fonksiyonların türevinin her zaman sabit bir sayı olmasından kaynaklıdır. Ortaya çıkan sonuçta sürekli olarak sabit bir sayı olacak ve bir sonraki katman girdisine sabit sayı aktarılacaktır. Dolayısıyla sadece bir girdi ve çıktı olacak ara katmanların burada hiçbir işlevi kalmayacaktır. Aşağıdaki şekilde bir doğrusal fonksiyon ve türevi gösterilmiştir (Kızrak, 2019).




Şekil 10. Doğrusal Fonksiyon ve Türevi (Kızrak, 2019)

2.5.2 Sigmoid fonksiyonu

Çevremize baktığımızda aslında çoğu olay doğrusal değildir. Bundan kaynaklı problemlerin çözümleri için türevlenebilir bir fonksiyona ihtiyaç duyarız. Bu fonksiyonlardan biri de sigmoid fonksiyonudur. Doğrusal fonksiyon türevlenebilir olmadığından bir sonraki katmana sürekli sabit sayı aktırılıyor bundan dolayı da öğrenmeyi gerçekleştiremiyordu. Sigmoid fonksiyonu türevlenebilir olduğu için öğrenmeyi gerçekleştirebilir.

Sigmoid fonksiyonunun olumsuz tarafına değinecek olursak öğrenmeyi verimli bir şekilde gerçekleştirememesidir (Kızrak, 2019).


✓ Doğrusal Fonksiyonun değer aralığı $(-\infty, +\infty)$ (Kızrak, 2019).



Şekil 11. Sigmoid Fonksiyon ve Türevi (Kızrak, 2019)

2.5.3 Tanjant fonksiyonu

Sigmoid Fonksiyonuna çok benzer yapıdadır. Sigmoid fonksiyonun türevlenebilir değer aralığının sonucu her zaman pozitiftir ancak tanjant fonksiyonunda negatif değer de alabilmektedir. Bu yönüyle öğrenme olanağının daha da yüksek olduğunu ve sigmoid fonksiyonuna göre daha üstün olduğunu gösterir (Kızrak, 2019; Asmaa, 2021).




Şekil 12. Tanjant Fonksiyonu ve Türevi (Asmaa, 2021)

2.5.4 Doğrultulmuş Lineer Birim (Relu) fonksiyonu

Relu fonksiyonu diğer fonksiyonlarla karşılaştırıldığında iyi bir öğrenme yeteneğine sahip olup iyi bir sınıflandırıcıdır. Sigmoid ile hiperbolik fonksiyon karşılaştırıldığında


daha az sayıda nöron kullanır ve işlem yükünü azaltır bu da daha dengeli ve aynı zamanda verimli olmasını sağlar. Relu fonksiyonu negatif değer almaz. Bu aslında hem avantaj hem de dezavantajdır. Negatif değer almaması hızı artırır ancak bu bölgede öğrenme gerçekleştiremez (Kızrak, 2019; Asmaa, 2021).



Şekil 13. Relu Fonksiyonu ve Türevi (Asmaa, 2021).

2.5.5 Softmax fonksiyonu

Tıpkı sigmoid fonksiyonunda olduğu gibi softmax fonksiyonu da sınıflandırma problemleri için ideal bir fonksiyondur. Eğer veri setinizde birden fazla sınıf varsa softmax fonksiyonu kullanmak bir avantaj olacaktır. Genellikle çıktı yani en son katman olarak kullanılır (Kızrak, 2019; Asmaa, 2021).



Şekil 14. Softmax Fonksiyonu ve Türevi (Asmaa, 2021)

AKTİVASYON FONKSİYONU	DENKLEM	ARALIK
Doğrusal Fonksiyon	$f(x) = x$	$(-\infty, \infty)$
Basamak Fonksiyonu	$f(x) = \{0 \text{ için } x < 0$ $f(x) = \{1 \text{ için } x \geq 0$	$\{0,1\}$
Sigmoid Fonksiyonu	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0,1)$
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{e^{-x} - e^x}{e^{-x} + e^x}$	$(-1,1)$
Relu	$f(x) = \{0 \text{ için } x < 0$ $f(x) = \{x \text{ için } x \geq 0$	$[0, \infty]$
Leaky (Sızıntı) Relu	$f(x) = \{0.01 \text{ için } x < 0$ $f(x) = \{x \text{ için } x \geq 0$	$(-\infty, \infty)$
Swish Fonksiyonu	$f(x) = 2\sigma(\beta x) = \{\beta = 0 \text{ için } f(x) = x\}$ $f(x) = 2\sigma(\beta x) = \{\beta \rightarrow \infty \text{ için } f(x)$ $= 2\max(0, x)\}$	$(-\infty, \infty)$

Tablo 1. Aktivasyon Fonksiyonları ve Matematiksel İfadeleri (Kızrak, 2019)

2.6. Hata fonksiyonları tablosu

2.6.1 Ortalama hata fonksiyonu

Ortalama hata değerinin genel hatları ile tanımını yapacak olursak çıktı değeri ile olması istenen değer arasındaki farktır. Bu doğan farka göre ağırlıkları güncelleyerek istenen hedefe ulaşılmaya çalışılmaktadır. Ortalama hata fonksiyonun birçok çeşidi bulunmakla beraber bazıları; ortalama hata, ortalama kare hata, ortalama mutlak hata, kök ortalama mutlak hatadır. Hata fonksiyonların denklemleri aşağıda belirtilmiştir (Altunbaş, 2021).

Ortalama Hata Denklemi	$ME = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)$
Ortalama Kare Hata Denklemi	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2$
Ortalama Mutlak Hata Denklemi	$MAE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)$
Kök Ortalama Mutlak Hata Denklemi	$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y'_i)^2}{n}}$

Tablo 2. Hata Fonksiyon Denklemleri (Power, ve Chemmgat, 2019)

2.6.2 Çapraz entropi fonksiyonu

Ortalama hata fonksiyonlarından farkı tahminde bulunmasıdır. Çıkış değeri ile olması istenen değer arasında olasılık hesaplaması yapar. 0 ile 1 arasında bir değer almaktadır. 0 bize istenen olayın gerçekleşme olasılığının hiç olmadığını 1 ise kesinlikle olacağını Belirtir (Çetinkaya, 2021).

Çapraz Entropi	$H(p, r) = - \sum_{i=1} p(x_i) * \log (r(x_i))$
----------------	---

Tablo 3. Çapraz Entropi Fonksiyonu Denklemi (Köroğlu, 2012)

2.7 Derin öğrenme modellerinde kullanılan hiper parametreler


Hiper parametreler kullanılan sinir ağına göre ve ağı yöneten kişinin amacına göre değişen aynı zaman da var olan veri setine göre güncellenebilen değişken yapılardır. Bu yapılar eğer sabit olsalardı en doğru sonuca gitmemiz mümkün olmazdı. En uygun hiper parametre seçimi ağı tasarlayan kişinin deneme sayısına, eğer daha önceden sonuç çıktısı aldıysa bundan çıkarım yapmasına göre değişkenlik gösterecektir. En çok kullanılan hiper parametrelerden bazıları aşağıda belirtilmiştir (Radhakrishnan, 2017).

2.7.1 Veri setinin boyutu

Derin öğrenmede eğitim sırasında kullanılan veri seti, eğitimin olumlu sonuçlanması ve öğrenme oranının yüksek olması açısından büyük önem taşımaktadır. Veri seti probleme göre görsel ya da metin şeklinde değişkenlik gösterebilir ancak veri setinin çeşidi ne olursa olsun içerdiği veri sayısının fazla olması önemlidir. Çünkü veri sayısının fazlalığı öğrenme oranını olumlu yönde etkileyecektir. Eğer bizim amacımız hız ise ve modelin bir an önce öğrenmesini istiyorsak veri setinin büyüklüğünü sınırlamamız gerekebilir. Verilerin sayısı arttıkça başarı oranı artacaktır ancak bir yerden sonra artık bu durağan bir hal alacak ve minimum seviyede artış gösterecektir. Bu noktayı denemeler sonucunda tespit edebilir ve bu noktadan sonra veri setini sınırlandırabiliriz. Verilerin sayısı kadar çeşidi de önemlidir. Eğer veri seti çok çeşitli veriler içeriyorsa bu öğrenme oranını artıracaktır. Eğer görsel olarak bir veri seti seçtiysek ve görseller birbiri ile benzerse gürültü oranı artacak ve öğrenme oranını olumsuz yönde etkileyecektir (Çarkacı, 2018).

2.7.2 Mini batch boyutu

Derin öğrenme de modeli eğitirken veri setinin boyutunun öneminden bahsetmiştik. Veri setindeki sayı ve çeşit ne kadar fazla olursa başarı oranı da aynı oranda yükselecektir. Ancak bu kadar fazla veri içeren veri setin de öğrenme işlemi de bir hayli yavaş gerçekleşecektir çünkü iyileştirme için parametreler de her değişim yaptığımız da geri salınım yaparak mecburen ağırlık güncellenmesi yapılması gerekmektedir. Mini-batch işte burada devreye girmektedir. Mini-batch amacı büyük veri içeriğini parçalayarak birden fazla gruba ayırmak ve eğitimin bu şekilde devam etmesini sağlamaktır. Bu şekilde zamandan tasarruf etmek amaçlanmaktadır. Tabii ki bu araştırmacının amacına göre değişiklik gösterebilir. Zamandan tasarruf etmek istenirse mini-batch için girilen değer artırabilir ya da zaman bizim için öncelikli değilse girilen değer küçük tutabilir. Mini-batch bizlere zamandan tasarruf imkânı tanımaktadır ancak aynı zamanda da kayıpları artırmaktadır. Mini-batch için girilecek optimum değer aralığı 64-512 arasında ve 2'nin katı değerler olacak şekilde belirlenebilir. Böylelikle hem kayıplar fazla yaşanmayacak hem de eğitim çok uzun süremeyecektir. Aşağıdaki görselde hata değişim grafikleri yer almaktadır (Andrew, 2018).



Şekil 15. Batch ve mini-batch hata değeri değişim grafiği (Andrew, 2018)

2.7.3 Öğrenme hızı

Öğrenme hızı diğer hiper parametreler gibi başarı oranını önemli ölçüde etkilemektedir. Araştırmacı uygun bir veri seti seçimi sonrası istenilen başarı oranını yakalamak için öğrenme hızında değişiklikler yapmak zorundadır. Yapılan bu değişiklikler aynı zaman da ağırlıklarda dalgalanmalara neden olacaktır. Buradaki amaç hatayı en az seviyeye çekerek öğrenme oranını artırmaktır. Öğrenme hızı için belirlenen seviye eğer çok yüksek ise eğitim tur sayısı azalacak ancak hata oranı maksimuma çıkacaktır. Öğrenme hızının düşük seviyeye çekilmesi ise yüksek öğrenme hızına kıyasla hata oranını düşürecek ve eğitim tur sayısını artıracak dolayısıyla da zamanı artıracaktır. Tasarlanan modele ve veri setine göre en uygun öğrenme hızı, hatayı en düşük seviyeye kadar az devir sayısı ile yakınsamaktadır. Aşağıda hata değişim grafiği yer almaktadır (Brownlee, 2019).



Şekil 16. Öğrenme Hızına Göre Hata değişim Grafiği (Brownlee, 2019)

2.7.4 Eğitim tur sayısı

Derin öğrenme de eğitim sırasında verilerin hepsi aynı anda eğitilemez. Dolayısıyla belirli sayıda eğitim gerçekleşir. Eğitim gerçekleştikçe geriye doğru yayılım başlar ve ağırlıklar en optimum seviyeye güncellenir. Böylelikle yüksek başarı oranı ve en az hata ile eğitimi tamamlamak amaçlanır. Eğitim sıklığı ne kadar artarsa öğrenme oranı da artacaktır ancak belirli bir yerden sonra artık artmayacak ve seyrinde ilerleyecektir (Zulkifli, 2018).

2.7.5 Optimizasyon algoritmaları

Başarı oranını en yüksek seviyeye taşıyarak kayıpları minimuma indirmeyi amaçlayan algoritmalarlardır. Birçok optimizasyon algoritması bulunmaktadır. Bu algoritmalar aşağıda belirtilmiştir. Bu tezde beyin tümörü teşhisi ve sınıflandırmasında kullanılan modellerde birçok algoritma denenmiş ancak en yüksek başarı SGD optimizasyon algoritmasında elde edilmiştir. Bundan dolayı kullanılan modellerde optimizasyon algoritması olarak SGD tercih edilmiştir.

- Gradyan iniş: Optimizasyon algoritmaların içerisinde en fazla tercih edilenidir. Eğer veri setin de farklı sınıflarda veri varsa bu algoritma tercih edilebilir. ANN geriye salınım yapması aslında bir gradyan iniş örneğidir. Uygulaması pratiktir.


- Yığın gradyan iniş: Gradyan inişten farkı tüm veri setini incelemesidir. Bu işlemi gerçekleştirdikten sonra parametrelerde değişiklikler yapar dolayısıyla zaman konusunda istediğimiz verimi alamayız. Çok tercih edilen bir algoritma değildir.
- Stokastik gradyan iniş (SGD): SGD her eğitim başlangıcında veri havuzundaki tüm örnekler için parametre güncellemesi yapar. Dolayısıyla süre açısından optimum değildir ve sürekli güncellemeler dalgalanmalara neden olmaktadır.
- Momentum: SGD her eğitim başlangıcında parametre güncellemesi yaptığını yukarıda belirtmiştik. Momentum algoritması bunun önüne geçmek için türetilmiştir. Modelin yüksek başarı oranı yakalamasını istiyorsak momentum parametresini en iyi şekilde belirlemeliyiz.
- Adagrad: Daha önce de belirttiğimiz gibi öğrenme hızının sabit olması, bizim eğitim sırasında istemeyeceğimiz bir fonksiyondur. Adagrad SGD ve Momentum yöntemlerindeki sabit öğrenme katsayısı problemini ortadan kaldırmak için önerilmiştir ancak hesaplama açısından diğer algoritmalara göre dezavantajlı konumdadır.
- Adadelta: Bu algortmada öğrenme hızı sabit değil ancak bir süre sonra eğitimler ilerledikçe öğrenme oranında azalma gözlenmektedir. Adadelta yönteminde Adagrad ve RMSProp yöntemlerinden farklı olarak öğrenme katsayısı seçme zorunluluğu yoktur. Her iki yöntemde, sabit öğrenme problemini çözmeye odaklanan Adagrad versiyonlarıdır. Öğrenme katsayısı yerine, geçerli ağırlıklar ile güncellenen ağırlıklar arasındaki farkı ifade eden delta değerlerinin karelerinin momentumlu toplamaları kullanılmaktadır.
- Karelerin ortalamasının karekökü yayılımı (RMSprop): Bu algoritmanın amacı öğrenme hızını diğer algoritmalara göre daha yüksek tutmaktır. Her parametre için ayrı ayrı öğrenme hızları otomatik olarak belirlenir.
- Adam: Bu algortmada öğrenme hızı belirli bir seviyede tutulmaktadır. Momentum ve RMSprop algoritmaların iyi yönlerini birleştirerek daha optimum bir algoritma elde edilmiştir (Dağlı ve Eroğul, 2020).

2.8 CNN mimarileri

Geçmişten günümüze literatüre katkı sağlamak amacıyla birçok çalışma yapılmış ve yapılan bu çalışmalarda farklı mimariler tercih edilmiştir. Bu mimarilerden bazıları aşağıda yer almaktadır. Bu tezde kullanılan mimariler Alexnet, Resnet50, YOLO ve önerilen CNN modelidir.

2.8.1 LeNet-5

CNN’de birçok model bulunmaktadır. Bunlardan ilk başarılı sayılan model ise Lecun ve arkadaşlarının yaptığı çalışmadır. Yapılan çalışma bir sınıflandırma olup posta kodlarının ve rakamların okunması vb. alanlarda istenilen sonucu vermiştir (LeCun ve ark., 1998). Aşağıdaki LeNet mimari yapısını kısaca özetleyecek olursak; boyutlandırma olarak 32*32*1 seçilmiştir. Kullanılan katmanlar; 2 adet evrişim katmanı, iki adet ortalama havuzlama katmanı, iki tamamen bağlı katman ve sınıflandırma katmanı olarak da softmax katmanıdır (Xu ve ark., 2019).




Şekil 17. LeNet mimari yapısı (LeCun ve ark., 1998)

2.8.2 ALEXNET

Krizhevsky ve ark. 2012 yılında geliştirdikleri ALEXNET modeli ile derin öğrenmenin tekrardan insanlar tarafından ilgi duyulan bir alan haline gelmesini sağlayan ilk çalışmadır. LeNet ile kıyaslandığında daha derin bir modeldir. Ayrıca ALEXNET, ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını kazanarak büyük bir başarı yakalamıştır (Krizhevsky ve ark., 2012).

Aşağıdaki görselde bulunan ALEXNET mimarisini kısaca özetleyecek olursak; beş adet evrişimsel katman, üç adet maksimum havuzlama katmanı, üç adet FCN ve sınıflandırma için de softmax katmanından oluşmaktadır. Her bir evrişim ve FCN katmanından sonra Relu aktivasyon fonksiyonu kullanılmıştır (Rehman ve ark., 2020).




Şekil 18. ALEXNET mimari yapısı (Krizhevsky ve ark., 2012)

2.8.3 VGGNet

Simonyan ve ark. tarafından geliştirilen model 2014 yılında yapılan ILSVRC yarışmasında başarılı olmuştur. VGGNet LeNet-5 ve ALEXNET ile kıyaslandığında daha fazla katman içermektedir. Daha derin olduğundan sınıflandırma başarı oranı daha


yüksektir. Aşağıdaki görsel de VGGNet mimarisi yer almaktadır (Simonyan ve Zisserman, 2014).



Şekil 19. VGGNet mimari yapısı (Simonyan ve Zisserman, 2014)

2.8.4 GoogLeNet


GoogLeNet, Szegedy ve ark. tarafından geliştirilen bir modeldir. 2014 yılı ILSVRC yarışmasını kazanmıştır. Aşağıdaki görselde GoogLeNet mimarisi yer almaktadır. Toplamda 22 tane katmana sahiptir ve diğer modellere oranla parametre sayısını azdır (Szegedy ve ark., 2015).




Şekil 20. GoogLeNet mimari yapısı (Szegedy ve ark., 2015).

2.8.5 RESNET

Microsoft ekibi (He vd. 2016) tarafından sunulan bir modeldir. Modelin 18, 34, 50, 101 ve 152 ağırlık katmanlı türleri vardır. 2015 yılı ILSVRC’de ve COCO yarışmalarında birinci olmuştur. Aşağıdaki görselde RESNET mimarisi yer almaktadır. Atlama bağlantılarının buradaki görevi başka bir ağ katmanına veri akışı sağlayarak onu beslemektir (He ve ark., 2016).




Şekil 21. 34 katmana sahip klasik derin sinir ağı ve RESNET model yapıları (He ve ark., 2016)



Şekil 22. RESNET artık (residual) öğrenmenin yapı taşı (He ve ark., 2016)

2.8.6 RESNET 50


VggNet, ALEXNET gibi geleneksel ardışık ağ mimarisinden farklı bir yapıya sahiptir. RESNET50 mikro mimari modülü yapısı ile diğer mimarilerden ayrışır. Bazı katmanlar arasındaki değişim göz ardı edilerek alt katmana geçiş işlemi yapılması tercih edilebilir. RESNET mimarisinde bu duruma izin verilerek başarı oranı daha üst seviyelere çıkarılmıştır. RESNET50 mimarisinde 177 katmandan oluşan bir ağ yer almaktadır. Bu katmansal yapıya ek olarak katmanlar arası bağlantıların nasıl olacağı hakkında bilgi mevcuttur. Giriş katmanı $224 \times 224 \times 3$ boyutundadır. Şekil 12’de RESNET mimarisinde kullanılan bağlantı örneği görülmektedir (He ve ark., 2016).



Şekil 23. RESNET50 bağlantı örneği (He ve ark., 2016)

2.8.7 YOLO

YOLO nesne tespiti yapan birçok uygulamadan sadece bir tanesidir. CNN tabanlı bir algoritmadır. YOLO algoritması nesne tespitini yaparken oldukça hızlı bir biçimde analiz yapmaktadır. Kullanılan donanım ve modüllerde bunda etkili olmaktadır. YOLO nesne tespiti yaparken girdi olarak verilen görüntüleri $X \times X$ lik matrislere böler ve nesne olup olmadığını eğer nesne varsa merkez noktasının kendi alanında olup olmadığını kontrol eder. Eğer nesne kendi alanında ise nesnenin sınıfını, yüksekliğini ve genişliğini tespit eder (Anonim, 2021). Aşağıdaki şekilde YOLO ağ tasarımı gösterilmektedir. Toplam 24 evrişimsel katmana, dört maksimum havuzlama katmanına ve iki tamamen bağlı katmana sahiptir.



Şekil 24. YOLO ağ tasarımı (Keite, 2022)


Derin öğrenme algoritması olan YOLO kullanılarak sınıflandırma yapılmaktadır. YOLOV8 modelinin birden fazla çeşidi bulunmaktadır. Bu çalışmada farklı çeşitteki modellerden YOLOV8m-cls, YOLOV8n-cls, YOLOV8s-cls aynı veri seti uygulanmıştır. Aynı zamanda Google Colab üzerinde alınan başarı oranları kıyaslanarak en yüksek başarı oranına sahip model tespit edilmesi amaçlanmaktadır.

3. MATERYAL ve YÖNTEM

Çalışmanın bu bölümünde geliştirilen modellerin uygulama adımları ve model başarı oranları üzerinden durulmaktadır. Karşılaştırmalar yapılarak ve en yüksek başarı oranına sahip modelin tespiti amaçlanmaktadır.

3.1 Veri seti

Bu çalışma da kullanılan veri setinin içeriğinde toplam 7023 görüntü bulunmaktadır. Veri setinde bulunan MR görüntüleri eğitim ve test olmak üzere iki sınıftan oluşmaktadır. Her bir sınıfın alt kategorisi de 4 ayrı sınıftan oluşmaktadır. Bu sınıflar glioma tümör, meningioma tümör, no tümör ve pitutary tümördür (Anonim, 2021).



Şekil 25. Sınıflara ait tümör görüntü örnekleri (Anonim, 2021)

Aşağıdaki tabloda hangi sınıfta kaç adet MR görüntüsünün olduğu gösterilmektedir.

Veri Seti İçeriği		
	Test	Train
Glioma Tümör	300	1321
Meningioma Tümör	306	1339
No Tümör	405	1595
Pitutary Tümör	300	1457

Tablo 4. Veri seti içeriği (Anonim, 2021)

Bu çalışmada kullanılan bilgisayar, microsoft windows 10 pro işletim sistemine sahip, üzerinde 2.6GHz işlemci, 27.4 GB bellek ve 565 GB disk kapasitesi barındıran bir yapıdadır.


3.2 Uygulanan ve Geliştirilen Modeller

Bu bölümde Google Colab üzerinde 4 farklı CNN modeline derin öğrenme uygulanmış, modeller geliştirilmiştir. Bu modeller daha önce de belirtildiği üzere ALEXNET, RESNET50, YOLOV8m-cl, YOLOV8n-cl, YOLOV8s-cl ve bu çalışmada önerilen CNN modelidir. Belirtilmiş olan modellerden ALEXNET ve RESNET50 daha önceden birçok kere denenmiş yüksek başarılar elde edilmiş güvenilir modellerdendir. YOLO ise son zamanlarda popüler hale gelmiş birçok yönden bize kolaylık sağlayan CNN tabanlı algoritmalarından biridir. Bunlara ilave olarak daha önceden geliştirilen bazı modellerden örnekler alarak ve birçok deneme sonucunda optimize hale getirilen bu çalışmada önerilen CNN modeli de eklenmiştir. Tüm geliştirilen modellerin uygulama adımları elde edilen başarı oranları bu bölümde karşılaştırmalı olarak belirtilmiştir. Farklı modeller geliştirilerek veri setine en uygun olan ve en yüksek başarı oranı elde edilen CNN modelinin bulunması amaçlanmaktadır. Geliştirilen modellerde katman sayısı çeşidi ve hiper parametrelerde değişiklikler yapılarak en optimum model geliştirilmiştir. Aşağıda geliştirilen modeller belirtilmiştir.

3.2.1 Tasarlanan CNN Modeli Üzerinde Yapılan Çalışmalar

Google Colab üzerinde yapılan çalışmalardan birisi olan önerilen CNN modeli ile yapılan derin öğrenme veri seti içeriğinde bulunan ve 4 ayrı grupta yer alan beyin tümörlerini sınıflandırmak için kullanılmıştır. Öncelikle veri setinin alındığı Kaggle platformundaki MR görüntülerinin boyutları birbirinden farklı olmasından dolayı bu görüntülerin hepsi 300x300 şeklinde eşitlendi. Veri setinin içeriğindeki MR görüntülerinden net olmayanlar tespit edilerek bunlar ayrıştırıldı. Geliştirilen modelin girişine uygun olarak 300x300x3 şeklinde boyutlandırıldı. Giriş katmanında farklı boyutlarda görüntü işlenmiştir. Bu çalışmada boyutu düşürdükçe daha yüksek başarı oranları elde edildiği görülmektedir. Bu modele en uygun boyutun 300*300*3 olduğu tespit edilmiştir. Giriş katmanından sonraki katmanlarda filtrelemeler yapılmaktadır. 2 adet convolution layer kullanılmıştır. İlkinde 32 adet filtre [5,5] boyutunda, diğerinde ise 16 adet filtre [3,3] boyutunda kullanılmıştır. Filtre boyutu küçültülerek daha detaylı bir görüntü elde edilmesi amaçlanmaktadır. Giriş katmanında yer alan görüntüler uygun filtrelemeler yapılarak havuzlama katmanına hazır hale getirilmektedir. Havuzlama katmanındaki asıl yapılmak istenen bu büyük görüntüleri sadeleştirmektir. Ortaklama havuzlama yöntemine göre daha fazla tercih edildiği ve daha iyi sonuç verdiği için maksimum havuzlama yöntemi tercih edilmiştir. FCN ise uygun ağırlıklar belirlenerek öğrenme işlemi gerçekleştirilmektedir. Derin öğrenme yöntemleri kullanılarak sınıflandırma yapılmak istendiğinden aktivasyon fonksiyonu olarak softmax fonksiyonunu tercih edilmektedir. Son katmanımız olan classoutput katmanında ise sınıflara MR görüntüleri dağıtılarak çıktı elde edilir. Elde edilen sonuçlarda hiper parametler de büyük rol oynamaktadır. Bu çalışmada kullanılan hiper parametreler doğrulama sıklığı (validation frequency), döngü sayısı (max epochs), öğrenme oranı ve mini batchdir. En yüksek başarı oranını elde etmek için kullanılan hiper parametrelere farklı değerler verilerek birçok deneme yapılmıştır ve optimum değerler belirlenmiştir. Bu parametrelere verilen değerler doğrulama sıklığı (validation frequency) 50, döngü sayısı (max epochs) 20, öğrenme oranı 0.01 ve mini batch boyutu 64'dür. Bu çalışmada döngü sayısının değeri 20 alınmaktadır ve bu şekilde zamandan tasarruf etmek amaçlanmaktadır. Döngü sayısı artıkcça öğrenmenin daha verimli olduğu bilinmektedir. Ancak adım sayısını fazla artırmakta modeli aşırı öğrenmeye götüreceği için en uygun değer 20 olarak belirlenmiştir. Burada başarı ölçütü görüntünün doğru sınıfta yer

almasıdır. Buna göre farklı optimizasyon algoritmalarının başarı ölçütleri kıyaslanarak en başarılı olan optimizasyon algoritmasının hangisi olduğunun tespiti yapılmaktadır. Aşağıdaki şekilde önerilen modelin uygulama adımları ve modelin analiz sonuçları gösterilmektedir.



Şekil 26. Önerilen modelin uygulama adımları

Analiz Sonucu		
	İsim	Aktivasyon
1	Giriş Katmanı 300x300x3 rastgele sıfır bir normalleştirmeli görüntüler	300x300x3
2	Evrişim Katmanı 32 adet 5x5 filtre	300x300x32
3	Evrişim Katmanı 16 adet 3x3 filtre	300x300x16
4	Maksimum Havuzlama	300x300x16
5	Tam Bağlı Katman	1x1x4
6	Softmax Aktivasyon Katmanı	1x1x4
7	Çıkış Katmanı	-

Tablo 5: Model analiz sonuçları

Eğitim sonucunda model başarı oranları aşağıdaki tabloda belirtilmiştir. Eğitim adım sayısı 20 olarak belirlenmiştir.

	Tasarımı Yapılan CNN Modeli Başarı Oranları	
	Traning Başarı Oranı	Testing Başarı Oranı
0.ADİM	%0.7130	%0.8507
1.ADİM	%0.9323	%0.8709
2.ADİM	%0.9795	%0.9218
3.ADİM	%0.9956	%0.9170
4.ADİM	%0.9995	%0.9295
5.ADİM	1	%0.9309
6.ADİM	1	%0.9330
7.ADİM	1	%0.9330

8.ADİM	1	%0.9323
9.ADİM	1	%0.9330
10.ADİM	1	%0.9323
11.ADİM	1	%0.9323
12.ADİM	1	%0.9309
13.ADİM	1	%0.9316
14.ADİM	1	%0.9302
15.ADİM	1	%0.9295
16.ADİM	1	%0.9295
17.ADİM	1	%0.9295
18.ADİM	1	%0.9295
19.ADİM	1	%0.9295

Tablo 6: Tasarımı yapılan CNN modeli eğitim adımları

3.2.2 YOLOV8 Üzerinde Yapılan Çalışmalar

Bu çalışmada YOLOV8 modeli kullanılarak nesne tespiti yapılmaktadır ve bu modellerin başarı oranları kıyaslanarak en yüksek başarı oranına sahip modelin tespit edilmesi amaçlanmaktadır. YOLOV8'in 3 farklı çeşidi olan YOLOV8m-cls, YOLOV8n-cls, YOLOV8s-cls yukarıda yer alan model üzerinde uygulanarak 3 model için de katmanlarda ve değerlerde herhangi bir değişiklik yapılmamıştır. Görüntü boyutu ise 300*300*3 alınmıştır. Hiper parametre değerleri momentum 0.937, öğrenme oranı 0.01, max epochs (döngü sayısı) 20, mini batch boyutu ise 64 alındı. Bu uygulamaların sonucunda 3 farklı başarı oranı elde edilmiştir. 20 adım sonunda model eğitim sonuçları aşağıdaki tabloda yer almaktadır.

Model Başarı Oranları	
YOLOV8m-cls	% 0.996
YOLOV8n-cls	% 0.995
YOLOV8s-cls	% 0.992

Tablo 7: YOLO modelleri başarı oranları

3.2.3 ALEXNET Modeli ile Yapılan Çalışmalar

Google Colab üzerinde yapılan çalışmalardan bir diğeri ALEXNET modeli ile yapılan sınıflandırma çalışmasıdır. Bu model daha önceden birçok çalışmada kullanıldığı için güvenilir bir model olmakla beraber aynı zamanda başarısı ispatlanmıştır. Optimizasyon algoritması olarak SGD kullanılmıştır. Model ağırlıklarında herhangi bir değişiklik yapılmamıştır. Eğitim adım sayısı 20 olarak belirlenmiştir. Adım sayısı daha az iken başarı oranının düştüğü gözlemlenmiştir. Adım sayısını artırıldığında modelde aşırı öğrenmenin gerçekleştiği saptanmıştır.

	ALEXNET Başarı Oranları	
	Traning Başarı Oranı	Testing Başarı Oranı
0.ADİM	% 0.6371	%0.8459
1.ADİM	%0.8036	%0.8902
2.ADİM	% 0.8351	%0.8757
3.ADİM	% 0.8463	%0.8673
4.ADİM	% 0.8665	%0.9237
5.ADİM	% 0.8695	%0.9397
6.ADİM	% 0.8824	%0.9382
7.ADİM	% 0.9145	%0.9603
8.ADİM	% 0.9259	%0.9649

9.ADİM	% 0.9288	%0.9603
10.ADİM	% 0.9300	%0.9649
11.ADİM	% 0.9372	%0.9672
12.ADİM	% 0.9356	%0.9680
13.ADİM	% 0.9339	%0.9718
14.ADİM	% 0.9388	%0.9733
15.ADİM	% 0.9430	%0.9703
16.ADİM	% 0.9391	%0.9725
17.ADİM	% 0.9410	%0.9718
18.ADİM	% 0.9405	%0.9725
19.ADİM	% 0.9363	%0.9725

Tablo 8: ALEXNET modeli eğitim adımları

3.2.4 RESNET50 Modeli ile Yapılan Çalışmalar

Google Colab üzerinde yapılan çalışmalardan sonuncusu RESNET50 modeli ile yapılan sınıflandırma çalışmasıdır. Optimizasyon algoritması olarak SGD kullanılmıştır. Model ağırlıklarında herhangi bir değişiklik yapılmamıştır. Eğitim adım sayısı 20 olarak belirlenmiştir. Eğitim sonucunda model başarı oranları aşağıda belirtilmiştir. Adım sayısı artırıldığında modelde aşırı öğrenmenin gerçekleştiği saptanmıştır.

	RESNET50 Başarı Oranları	
	Traning Başarı Oranı	Testing Başarı Oranı
0.ADİM	% 0.7195	% 0.9001
1.ADİM	% 0.8226	% 0.9367
2.ADİM	% 0.8678	% 0.8970
3.ADİM	% 0.8910	% 0.9489
4.ADİM	% 0.9051	% 0.9703
5.ADİM	% 0.9114	% 0.9703

6.ADİM	% 0.9281	% 0.9680
7.ADİM	% 0.9471	% 0.9840
8.ADİM	% 0.9574	% 0.9840
9.ADİM	% 0.9538	% 0.9893
10.ADİM	% 0.9641	% 0.9855
11.ADİM	% 0.9639	% 0.9893
12.ADİM	% 0.9620	% 0.9878
13.ADİM	% 0.9649	% 0.9893
14.ADİM	% 0.9702	% 0.9886
15.ADİM	% 0.9642	% 0.9886
16.ADİM	% 0.9689	% 0.9863
17.ADİM	% 0.9674	% 0.9886
18.ADİM	% 0.9684	% 0.9908
19.ADİM	% 0.9665	% 0.9870

Tablo 9: RESNET50 modeli eğitim adımları

Google Colab üzerinde yapılan çalışmaların başarı oranları tablolarda belirtilmektedir. Belirlenen modeller 4 farklı sınıftan oluşan toplamda 7023 adet MR görüntüsü üzerinde uygulanmış olup, aşağıdaki tabloya oranları işlenerek karşılaştırması yapılmıştır.

Model Öğrenme Oranı Karşılaştırmaları	
YOLOV8m-cls	% 0.996
YOLOV8n-cls	% 0.995
YOLOV8s-cls	% 0.992
RESNET50	%0.9908
ALEXNET	%0.9733
Tasarımı Yapılan CNN Modeli	%0.9295

Tablo 10: Model öğrenme oranı karşılaştırmaları

3.3 Performans Değerlendirme Kriterleri

Sınıflandırma modellerinde sınıflandırıcı başarısının ölçülmesi sınıflandırıcının etiketlediği sınıf değerleri ile gerçek sınıf değeri arasındaki ilişkilere göre belirlenir. Gerçek sınıf değeri pozitif olan bir veriyi pozitif olarak etiketlemeye doğru pozitif (DP), negatif olarak etiketlemeye yanlış negatif (YN) gerçek sınıf değeri negatif olan bir veriyi negatif olarak etiketlemeye doğru negatif (DN), pozitif olarak etiketlemeye de yanlış pozitif (YP) denmektedir. Buna göre karmaşıklık matrisindeki DP, DN, YP, YN değerleri kullanılarak performans değerlendirme kriterleri hesaplanmaktadır. Bilimsel çalışmalarda performans değerlendirme kriterleri olarak Doğruluk (Doğ), Duyarlılık (Duy), Özgüllük (Özg), Keskinlik (Kes) ve F1 skoru gibi ölçütler yaygın olarak kullanılmaktadır. (Bulut, 2017).

Performans değerlendirme kriterlerine ait bağıntılar Denklem 1-5’da verilmiştir (Bulut, 2017; Siuly ve ark., 2020).

1	$\text{Doğ} = \frac{TP+TN}{TP+TN+FP+FN} * 100$
2	$\text{Duy} = \frac{TP}{TP+FN} * 100$
3	$\text{Özg} = \frac{TP}{TN+FP} * 100$
4	$\text{Kes} = \frac{TP}{TP+FP} * 100$
5	$\text{F1 Skor} = \frac{DUY * KES}{DUY + KES} * 100$

Yapılan bu çalışmada, önceki yapılan çalışmalarda olduğu gibi derin öğrenme yöntemleri kullanılarak daha verimli ve doğruluk oranı yüksek bir yöntem geliştirme amaçlanmıştır. Literatürde aynı veri seti üzerinde farklı modeller kullanılmış ancak Google Colab üzerinde 4 farklı model kullanılarak karşılaştırma yapılmamıştır. Yapılan çalışma ile bu eksiklik giderilmeye çalışılmıştır.

4. BULGULAR ve TARTIŞMA

Bu tez çalışmasında derin öğrenme yöntemleri kullanılarak Google Colab üzerinde beyin tümörü teşhisi ve sınıflandırması üzerine uygulamalar yapılmaktadır. Bu çalışmada kullanılan bilgisayar, Microsoft Windows 10 Pro işletim sistemine sahip, üzerinde 2.6GHz işlemci, 27.4 GB bellek ve 565 GB disk kapasitesi barındıran bir yapıdadır.

Veri setinde ise toplam 7023 görüntü bulunmaktadır. Bunları tehlike açısından sınıflandıracak olursak; 1621 adet hafif, 1645 adet orta, 2000 adet tümör olmayan ve 1757 adet ağır beyin tümörü içeren görüntü bulunmaktadır. (Anonim, 2021)

Yapılan bu çalışmada ALEXNET, RESNET50 ve önerilen CNN modeli mimarilerinde sınıflandırma, YOLO mimarisin de ise nesne tespiti ile derin öğrenme yöntemleri uygulanarak beyin tümörü teşhisi ve sınıflandırılması amaçlanmaktadır. Geliştirilen modellerin her birinde farklı öğrenme oranları elde edilmiştir. Bu farkların oluşmasında kullanılan optimizasyon algoritmaları, hiper parametreler, eklenen ve çıkarılan katmanlar, filtre adetleri, filtre boyutları vb. etkili olmuştur.

YOLOV8 Performans Karşılaştırma Sonuçları			
	YOLOV8m-cls	YOLOV8n-cls	YOLOV8s-cls
DOĞRULUK	%0.4607	%0.4584	%0.4577
DUYARLILIK	%0.4983	%0.4959	%0.4950
ÖZGÜNLÜK	%0.4962	%0.4959	%0.4945
KESKİNLİK	%0.4959	%0.4951	%0.4935
F1 KOR	%0.4971	%0.4995	%0.4942


Tablo 11: YOLOV8 performans karşılaştırma sonuçları

YOLOV8m, YOLOV8s ve YOLOV8n modellerin derinlikleri karşılaştırıldığında en derin modelin YOLOV8m-cls olduğu görülmüştür. Dolayısıyla da en yüksek başarı oranını da YOLOV8m-cls’de vermiştir. YOLO modellerinin başarı metrik çıktıları CNN model çıktıları ile karşılaştırdığımızda bir hayli düşük olduğu gözlemlenmiştir.


Model eğitimleri sonucunda elde edilen başarı oranları başarı metrik çıktılarına yansımamaktadır.

Aşağıda oluşturulan YOLO modellerinde ROC eğrisi çıktıları verilmiştir. En iyi sınıflandırma ölçütü YOLOV8m-cls modeline aittir. Daha sonra sırasıyla YOLOV8n-cls ve YOLOV8s-cls modeli gelmektedir.






YOLOV8m-cls Modeli ROC eğrisi grafiği



YOLOV8n-cls Modeli ROC eğrisi grafiği



YOLOV8s-cls Modeli ROC Eğrisi Grafiği


Şekil 27. YOLOV8m-cls, YOLOV8n-cls, YOLOV8s-cls ROC eğrisi grafikleri

ALEXNET-RESNET50-Tasarlanan CNN Modeli Performans Karşılaştırma Sonuçları			
	ALEXNET	RESNET50	Tasarlanan CNN Modeli
DOĞRULUK	%0.9733	%0.9908	%0.9295
DUYARLILIK	%0.9733	%0.9908	%0.9295
ÖZGÜNLÜK	%0.9732	%0.9908	%0.9037
KESKİNLİK	%0.9732	%0.9908	%0.9290
F1 KOR	%0.9733	%0.9908	%0.9286


Tablo 12: ALEXNET-RESNET50-Tasarlanan CNN Modeli performans karşılaştırma sonuçları

Yukarıdaki tabloda ALEXNET-RESNET50 ve Tasarlanan CNN Modelleri başarı metrik çıktıları yer almaktadır. Her bir model eşit adım sayısında eğitilmiştir. Bu modeller arasında en derin olan model RESNET50 modelidir. ALEXNET modeli derin öğrenmede ilk başarı yakalanan modellerden biri olarak sayılır. Dolayısıyla geleneksel bir yapısı vardır. Aynı zamanda da katman sayısı azdır. RESNET50 modeli ile geleneksel yapıdan çıkılmış ve derin öğrenmeye farklı bir bakış açısı getirilmiştir. Tablodaki modeller arasında en fazla katman sayısına sahip olan model RESNET50 modelidir. Tabloyu incelediğimizde en yüksek başarı metrik çıktılarının RESNET50 modelinde olduğunu görebiliriz.


Başarı metriklerinden bir diğeri ise ROC eğrisidir. ROC eğrisi x ve y ekseninden oluşan bir olasılık eğrisidir. X eksen (False Positive), Y eksen ise (True Positive) olarak isimlendirilir. ROC eğrisinin altında kalan alan ne kadar fazla ise veri setinde olan sınıfları ayırt etme ve doğru bir şekilde sınıflandırma ölçütü artmaktadır. Aşağıda oluşturulan CNN modellerindeki ROC eğrisi çıktıları verilmiştir. En iyi sınıflandırma ölçütü RESNET50 modeline aittir. Daha sonra sırasıyla ALEXNET ve tasarlanan CNN modeli gelmektedir.



RESNET50 ROC Eğrisi Grafiği



ALEXNET ROC Eğrisi Grafiği



TASARLANAN CNN MODELİ ROC Eğrisi

Şekil 28. RESNET50, ALEXNET, TASARLANAN CNN MODELİ ROC eğrisi grafikleri

5. SONUÇ

Derin öğrenme, herhangi bir insan müdahalesine gerek kalmadan, algoritma ve büyük veri kullanılarak çıktılar oluşturup cevaplar veren makine öğrenme tekniğidir. Derin öğrenme algoritmaları, verileri belirli bir mantıksal yapı ile sürekli olarak analiz ederek insanların yapacağı gibi benzer sonuçlar çıkarmaya çalışır. Bunu başarmak için, derin öğrenme, sinir ağları adı verilen çok katmanlı bir algoritma yapısı kullanmaktadır. Derin öğrenme yöntemleri ile farklı modeller ve algoritmalar kullanarak yüksek doğruluk oranında beyin tümörü teşhisi ve sınıflandırılması yaparak hem teknolojik yetersizliklerin önüne geçmek hem de doktorların beyin tümörü teşhisi sırasında dikkat kaybından doğabilecek hataları minimuma indirmeyi amaçlanmıştır.

Derin öğrenme bir veya daha fazla gizli katman içeren ANN ve benzeri makine öğrenme algoritmalarını kapsayan çalışma alanıdır. Yani en az bir adet yapay sinir ağının kullanıldığı ve birçok algoritma ile, bilgisayarın eldeki verilerden yeni veriler elde etmesidir.

Literatürde aynı veri seti üzerinde farklı modeller kullanılmış ancak Google Colab üzerinde 4 farklı model kullanılarak karşılaştırma yapılmamıştır. Bu çalışmada ise, yapılan Google Colab uygulamasıyla farklı olarak 4 ayrı model kullanılmış ve bu modeller içerisinde en yüksek doğruluk oranına sahip model elde edilmeye çalışılmıştır. Sonuç olarak yüksek sayıda olan ve farklı sınıflar içeren veriyi çok kısa bir sürede yüksek başarı oranı ile hangi sınıfa ait olduğu ortaya çıkarılmıştır.

Bu çalışmanın asıl amacı doktorların zaman zaman stres, dikkat kaybı, yorgunluk vb. nedenlerle beyin tümörünün teşhisinde yanlış veya eksik tespit yapılarak ölüme kadar gidebilecek bir sonucun önüne geçmektir. Yapılan bu çalışma ile bu eksiklik kısmen giderilmiş ve ileride yapılacak olan çalışmalara bir ufuk açılmıştır.

KAYNAKLAR

- Beyazyıldız, E., 2020. Neoplazi. Temel Patoloji, Uğur Ofset Yayınları, Samsun, 88-90.
- Özdoğan M., 2020. Kanser Nedir Neden ve Nasıl Oluşur. Antalya. <https://www.drozdogan.com/kanser-nedir-neden-ve-nasil-olusur-ozetle-tum-surec/> (06.09.2023).
- UNFPA., 2022. 2022 Dünya Nüfus Raporu. America.
- Anonim, 2021. Glioma Nedir. Cleveland, <https://my.clevelandclinic.org/health/diseases/21969-glioma> (28.07.2024).
- Anonim, 2021. Beyin Tümörü MRI Veri Kümesi. Kaggle, <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset> (10.02.2023).
- Peker,Selçuk.,2024. Meningiom. İstanbul, <https://www.selcukpeker.com/tedavi-unitele ri/meningiom/#:~:text=Beynin%20etraf%C4%B1n%C4%B1%20saran%2C%20 onu%20koruyan,15%2D20%20kadar%C4%B1n%C4%B1%20olu%C5%9Ftur d uklar%C4%B1%20bilinir> (01.07.2024).
- Anonim, 2024. Pituitary tumors. USE, <https://www.mayoclinic.org/diseases-conditions /pituitary-tumors/symptoms-causes/syc-20350548> (04.07.2024).
- Anonim, 2024. Tümör Nedir. Cleveland, <https://my.clevelandclinic.org/health/diseases /21881-tumo> (28.07.2024).
- Rehman, A., Naz, S., Razzak, M. I., Akram, F., & Imran, M. (2020). A deep learning-based framework for automatic brain tumors classification using transfer learning. *Circuits, Systems, and Signal Processing*, 39(2), 757-775.
- Sajjad, M., Khan, S., Muhammad, K., Wu, W., Ullah, A., & Baik, S. W. (2019). Multi-grade brain tumor classification using deep (CNN-Convolutional Neural Networks) with extensive data augmentation. *Journal of computational science*, 30, 174-182.
- Li, Y., Jia, F., and Qin, J., 2016. Brain tumor segmentation from multimodal magnetic resonance images via sparse representation. *Artificial intelligence in medicine*, 73, 1-13.
- Kaur, A., 2016. An automatic brain tumor extraction system using different segmentation methods. In 2016 Second International Conference on Computational Intelligence & Communication Technology (CICT) (pp. 187-191). IEEE, Ghaziabad, India
- Kamnitsas, K., Ferrante, E., Parisot, S., Ledig, C., Nori, A. V., Criminisi, A., and Glocker, B. (2016, October). DeepMedic for brain tumor segmentation. In *International workshop on Brainlesion: Glioma, multiple sclerosis, stroke and traumatic brain injuries* (pp. 138-149). Springer, Cham, Quebec City, QC, Canada.
- Kamnitsas, K., Ledig, C., Newcombe, V.F.J., Simpson, J.P., Kane, A.D., Menon, D.K. Glocker, B. (2017). Efficient multi-scale 3D (CNN-Convolutional Neural Networks) with fully connected CRF for accurate brain lesion segmentation. *Med Image Anal*, 36, 61-78.

- Pereira, S., Oliveira, A., Alves, V., and Silva, C. A. (2017, February). On hierarchical brain tumor segmentation in MRI using fully convolutional neural networks: a preliminary study. In 2017 IEEE 5th Portuguese meeting on bioengineering (ENBENG) (pp. 1-4). IEEE, Coimbra, Portugal.
- Arunkumar, N., Mohammed, M. A., Mostafa, S. A., Ibrahim, D. A., Rodrigues, J. J., and de Albuquerque, V. H. C. (2020). Fully automatic model-based segmentation and classification approach for MRI brain tumor using artificial neural networks. *Concurrency and Computation: Practice and Experience*, 32(1), 1-9.
- Anonim, 2023. Derin Öğrenme Nedir. <https://aws.amazon.com/tr/what-is/deep-learning/> (12.04.2023).
- Anonim, 2021 Derin Öğrenme (Deep Learning) Nedir. İstanbul, https://www.beyaz.net/tr/yazilim/makaleler/derin_ogrenme_deep_learning_nedir.html (16.04.2023).
- Dağlı, K., 2021. Derin öğrenme modelleri kullanılarak beyin tümörlerinin sınıflandırılması. (Yüksek Lisans Tezi), TOBB Ekonomi ve Teknoloji Üniversitesi. Biyomedikal Mühendisliği Ana Bilim Dalı, Ankara.
- Tolon, M., Tosunoğlu, N., 2008. Tüketici Tatmini Verilerinin Analizi ANN ve Regrasyon Analizi Karşılaştırması. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(2), 247-259.
- Mayank M., 2020. Convolutional Neural Networks. Hollanda, <https://towardsdatascience.com/convolutional-neural-networks-explained-9cc5188c4939> (20.04.2023).
- Dağlı, K., 2021. Derin öğrenme modelleri kullanılarak beyin tümörlerinin sınıflandırılması. (Yüksek Lisans Tezi), TOBB Ekonomi ve Teknoloji Üniversitesi. Biyomedikal Mühendisliği Ana Bilim Dalı, Ankara.
- Doğan Ö., 2020. (CNN-Convolutional Neural Networks) Nedir. Türkiye, <https://teknoloji.org/cnn-convolutional-neural-networks-nedir/> (05.08.2023).
- Akdağlı E., 2021. Convolutional Neural Network. Türkiye, [https://ece-akdagli.Medium.com/evri%C5%9Fimsel-sinir-a%C4%9Flar%C4%B1-convolutional-neural-networka6c9d8e666c4#:~:text=3.Flattening%20Layer%20\(D%C3%BCzle%C5%9Ftirme%20Katman%C4%B1,sinir%20a%C4%9F%C4%B1na%20girdi%20olarak%20kullan%C4%B1%C4%B1r](https://ece-akdagli.Medium.com/evri%C5%9Fimsel-sinir-a%C4%9Flar%C4%B1-convolutional-neural-networka6c9d8e666c4#:~:text=3.Flattening%20Layer%20(D%C3%BCzle%C5%9Ftirme%20Katman%C4%B1,sinir%20a%C4%9F%C4%B1na%20girdi%20olarak%20kullan%C4%B1%C4%B1r) (13.8.2023).
- Sayracı, B., 2021. Derin Öğrenme ve Evrişimsel Sinir Ağları. İzmir, <https://medium.com/deep-learning-from-deepest/deri%CC%87n-%C3%B6%C4%9Frenme-ve-evri%CC%87%C5%9Fi%CC%87msel-si%CC%87ni%CC%87r-a%C4%9Flari-446dc8a8d2f> (01.05.2023).
- Koç E., 2022. Evrişimsel Sinir Ağlarına Giriş. Türkiye, <https://www.miuul.com/not-defteri/evrisimli-sinir-aglarina-giris> [04.09.2023).

- Kızrak, A., 2019. Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması. İstanbul, <https://ayyucekizrak.medium.com/derin-%C3%B6%C4%9Frenme-%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9Ft%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd> (10.05.2023).
- Asmaa M., 2021. ANN’de Aktivasyon Fonksiyonları. İtalya, https://dltr.asmaamir.com/0,-nn-kavramlari/4-aktivasyon_fonksiyonlari (13.05.2023).
- Altuntaş, F., 2021. Mr Görüntülerinin Akıllı Yöntemler ile Sınıflandırılması Kümelenmesi ve Bölütlenmesi. (Y. Lisans Tezi), Kocaeli Üniversitesi. Bilgisayar Mühendisliği Anabilim Dalı, Kocaeli.
- Power, OS., Chemmangat, K., 2019. Dynamic time warping for reducing the effect of force variation on myoelectric control of hanf prostheses. Journal of Electromyography and Kinesiology, 48, 152-160.
- Çetinkaya, O., 2021. Çapraz Entropiye (Cross Entropy) Kısa Bir Bakış, <https://medium.com/@okanckaya/%C3%A7apraz-entropiye-cross-entropy-k%C4%B1sa-bir-bak%C4%B1%C5%9F-866ca840155c> (21.05.2023).
- Köroğlu, B., 2012. Cascaded Cross Entropy-Based Search Result Diversification. (Y. Lisans Tezi), Bilkent Üniversitesi, Bilgisayar Mühendisliği Ana Bilim Dalı, Ankara.
- Radhakrishnan, P., 2017. How to tune the Hyperparameters in a Deep Neural Network, <https://towardsdatascience.com/what-are-hyperparameters-and-how-to-tune-the-hyperparameters-in-a-deep-neural-network-d0604917584a> (23.05.2023).
- Çarkacı, N., 2018. Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper parametreler, <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarında-en-sik-kullanılan-hiper-parametreler-ece8e9125c4> (23.05.2023).
- Andrew, Ng., 2018. Understanding mini-batch gradient descent, <https://www.Coursera.org/lecture/deep-neural-network/understanding-mini-batch-gradient-descent-1BXu8> (23.05.2023).
- Brownlee, J., 2019. Understand the Impact of Learning Rate on Neural Network Performance, <https://machinelearningmastery.com/understand-the-dynamics-of-learning-rate-on-deep-learning-neural-networks> (21.05.2023).
- Zulkifli, H., 2018. Understanding Learning Rates and How It Improves Performance in Deep Learning. Malezya, <https://towardsdatascience.com/understanding-learning-rates-and-how-it-improves-performance-in-deep-learning-d0d4059c1c10> (22.05.2023).
- Dağlı, K., ve Eroğul, O., 2020. Derin öğrenme modelleri kullanılarak beyin tümörlerinin sınıflandırılması. Tıp Teknolojileri Kongresi, İzmir.
- LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. 1998. Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11): 2278-2324.
- Xu, S., Liu, C., Zong, Y., Chen, S., Lu, Y., Yang, L., Liu, Y. 2019. An early diagnosis of oral cancer based on three-dimensional convolutional neural networks. IEEE Access, 7: 158603-158611.

- Krizhevsky, A., Sutskever, I., Hinton, G. E. 2012. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25: 1097-1105.
- Rehman, A., Naz, S., Razzak, M. I., Akram, F., Imran, M. 2020. A deep learning-based framework for automatic brain tumors classification using transfer learning. *Circuits, Systems, and Signal Processing*, 39(2): 757-775.
- Simonyan, K., Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. 2015. Going deeper with convolutions. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- He, K., Zhang, X., Ren, S., Sun, J. 2016. Deep residual learning for image recognition. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Anonim, 2021. Yolo Nedir. Ankara, <https://www.odakarge.com/yolo-nedir.html> (01.01.2024).
- Keite, Z., 2022. Yolo Object Detection Explained, YOLO Object Detection Explained: A Beginner's Guide DataCamp (12.02.2024).
- Anonim, 2021. Beyin Tümörü MRI Veri Kümesi. Kaggle, <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset> (10.02.2023)
- Bulut F., 2017. Örnek Tabanlı Sınıflandırıcı Topluluklarıyla Yeni Bir Klinik Karar Destek Sistemi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, (33), 65–76.
- Siuly, S., Alçin, Ö F., Kabir, E., Şengür, A., Wang, H., Zhang, Y., Whittaker, F., 2020. A New Framework for Automatic Detection of Patients with Mild Cognitive Impairment Using Resting-State EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, (28), 1966–1976.