

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



BEYİN TÜMÖRÜNÜN VERİMLİ SINIFLANDIRILMASI İÇİN
MAKİNE ÖĞRENME YÖNTEMLERİ ARAŞTIRMASI

YÜKSEK LİSANS TEZİ

Alaa ALNEMER

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

ŞUBAT, 2023

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



BEYİN TÜMÖRÜNÜN VERİMLİ SINIFLANDIRILMASI İÇİN
MAKİNE ÖĞRENME YÖNTEMLERİ ARAŞTIRMASI

YÜKSEK LİSANS TEZİ

Alaa ALNEMER
(Y1995.010031)

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Tez Danışmanı: Prof. Dr. ALİ OKATAN

ŞUBAT, 2023

ONAY FORMU

ONUR SÖZÜ

Yüksek Lisans tezi olarak sunduđum "Beyin Tümörünün Verimli Sınıflandırılması İçin Makine Öğrenme Yöntemleri Araştırması" adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuđunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (10/02/2023)

Alaa ALNEMER

ÖNSÖZ

Bu tezi yazma fırsatı için minnettarım ve bu süreçte bana destek olan herkese minnettarlığımı ifade etmek istiyorum. İlk olarak, danışmanım Ali Okatan'a en derin şükranlarımı sunmak istiyorum. Rehberliği, bilgeliği ve teşvikleri benim için çok değerli oldu. Araştırmaya olan tutkusu ve öğrencilerine olan bağlılığı beni akademik bir kariyeri sürdürmeye teşvik etti.

Ayrıca, akademik hedeflerim boyunca sürekli olarak sağladıkları destek ve sevgiyle beni yalnız bırakmayan aileme teşekkür etmek istiyorum. Onların teşvikleri, sürekli bir motivasyon kaynağı oldu ve hayatımdaki varlıklarından dolayı son derece minnettarım.

Son olarak, araştırma sürecinde bana değerli geri bildirimler, teşvikler ve destek sağlayan meslektaşlarıma ve arkadaşlarıma büyük bir teşekkür borçluyum. Katkılarınız çok değerliydi ve son ürünü şekillendirmeme yardımcı oldular.

Tüm akademik yolculuğuma yaptığınız değerli katkılar için hepinize teşekkür ederim.

Şubat, 2023

Alaa ALNEMER

INVESTIGATING MACHINE LEARNING FRAMEWORKS FOR EFFICIENT CLASSIFICATION OF BRAIN TUMOR

ABSTRACT

The review, analysis, and comparison of the performance of pre-trained models for the classification of brain tumors based on magnetic resonance imaging is the primary objective of this thesis (MRI). In the first part of the study, some background information on artificial neural networks, such as perceptrons and multilayer perceptrons, as well as the frameworks that are going to be used in the study, is presented. The background of brain tumors, including their causes, symptoms, and diagnostic approaches, is also covered in this article. The use of pre-trained models in image classification, and more specifically in brain tumor MRI classification, is analyzed in the section of the paper devoted to the literature review. Additionally, the various classification algorithms that are put to use in this area of research are discussed. The MRI brain tumor dataset and the pre-trained models (VGG16, ResNet50, and InceptionV3) that will be compared are then described in detail in the following section of the study. After that, feature extraction, fine tuning, transfer learning, and a combination of these four methods are put into action and evaluated as potential methods for classifying brain tumors using the previously trained models. The outcomes of these methods are charted and compared using a variety of metrics, and the models that perform the best are retained for further examination. The purpose of this study is to provide insight into the most effective methods for classifying brain tumors using pre-trained models and to suggest potential directions for future research in this area. The models used in this study were obtained from the Brain Tumor Classification Dataset available publicly on Kaggle.

Keywords: Brain tumor classification, Magnetic resonance imaging (MRI), Medical imaging, Pre-trained models, Convolutional neural network (CNN), Feature extraction, Fine-tuning, Transfer learning, Classification algorithms, Diagnostic

approaches, Glioma, Meningioma, Pituitary, Cancer diagnosis, Machine learning,
Efficiency Comparison.

BEYİN TÜMÖRÜNÜN VERİMLİ SINIFLANDIRILMASI İÇİN MAKİNE ÖĞRENME YÖNTEMLERİ ARAŞTIRMASI

ÖZET

Manyetik rezonans görüntülemeye dayalı olarak beyin tümörlerinin sınıflandırılması için önceden eğitilmiş modellerin performansının gözden geçirilmesi, analizi ve karşılaştırılması bu tezin (MRG) birincil amacıdır. Çalışmanın ilk bölümünde algılayıcılar ve çok katmanlı algılayıcılar gibi yapay sinir ağları ve çalışmada kullanılacak çerçeveler hakkında bazı ön bilgiler verilmektedir. Beyin tümörlerinin nedenleri, semptomları ve teşhis yaklaşımları da dahil olmak üzere arka planı da bu makalede ele alınmaktadır. Önceden eğitilmiş modellerin görüntü sınıflandırmasında ve daha spesifik olarak beyin tümörü MRG sınıflandırmasında kullanımı, makalenin literatür taramasına ayrılan bölümünde analiz edilmektedir. Ek olarak, bu araştırma alanında kullanıma sunulan çeşitli sınıflandırma algoritmaları tartışılmaktadır. MRG beyin tümörü veri seti ve karşılaştırılacak önceden eğitilmiş modeller (VGG16, ResNet50 ve InceptionV3), çalışmanın aşağıdaki bölümünde ayrıntılı olarak açıklanmaktadır. Daha sonra öznelilik çıkarma, ince ayar, transfer öğrenme ve bu dört yöntemin bir kombinasyonu eyleme geçirilir ve daha önce eğitilmiş modeller kullanılarak beyin tümörlerini sınıflandırmak için potansiyel yöntemler olarak değerlendirilir. Bu yöntemlerin sonuçları çizelgelenir ve çeşitli metrikler kullanılarak karşılaştırılır ve en iyi performansı gösteren modeller daha fazla inceleme için saklanır. Bu çalışmanın amacı, önceden eğitilmiş modeller kullanarak beyin tümörlerini sınıflandırmak için en etkili yöntemler hakkında fikir vermek ve bu alanda gelecekteki araştırmalar için potansiyel yönler önermektir. Bu çalışmada kullanılan modeller Brain Tumor Classification Kaggle'den temin edilmiştir.

Anahtar Kelimeler: Beyin tümörü sınıflandırması, Manyetik rezonans görüntüleme (MRG), Tıbbi görüntüleme, Önceden eğitilmiş modeller, Evrişimli sinir ağı (ESA),

Özellik çıkarımı, İyileştirme ayarlaması, Aktarma öğrenimi, Sınıflandırma algoritmaları, Tanı yaklaşımları, Glioma, Meningiyoma, Hipofiz, Kanser tanısı, Makine öğrenimi, Verimlilik karşılaştırması.

İÇİNDEKİLER

ONUR SÖZÜ	i
ÖNSÖZ	iii
ABSTRACT	v
ÖZET	vii
İÇİNDEKİLER	ix
KISALTMALAR LİSTESİ	xiii
ÇİZELGELER LİSTESİ	xv
ŞEKİLLER LİSTESİ	xvii
I. GİRİŞ	1
A. Giriş ve Motivasyon.....	1
1. Beyin Tümörü	3
B. Beyin Tümörü Nedenleri ve Belirtileri.....	6
C. Gerçekler İstatistikler – Rakamlar	7
D. Amaçlar	9
E. Beyin Tümörü Tespit Tekniği	9
F. AI for Other Diseases	12
G. Karşılaştırma İçin Son Teknoloji Önerilen Sınıflandırıcı.....	13
H. Problem.....	14
I. Amaçlar ve Hedefler.....	14
J. Tez Çizelgesi.....	15
II. TEMEL BİLGİ VE ÖN İNCELEMELER	17
A. Yapay Sinir Ağları	17
1. Perseptron.....	17
2. Çok Katmanlı Perseptron	17
B. Beyin Tümörü MRG Sınıflandırmasındaki Çerçevesel.....	18
C. Kanser Nedir?.....	19
D. Kanser Türleri	19

III. LİTERATÜR TARAMASI.....	22
A. Giriş	22
B. Literatür Tarama Araştırması	22
1. Beyin Tümörü (BT), Malign ve İyi Huylu	23
a. Beyin Tümörünün Aşamaları	23
b. Beyin Tümörü; Nedenleri ve Belirtileri	23
c. Beyin Tümörü Tanı Yöntemleri ve Görüntüleri.....	23
2. Manyetik Rezonans Görüntüleme (MRG); Tanım ve Tarihçe.....	24
a. Tanımı.....	24
b. Tarih	25
3. Beyin Tümörü MRG Sınıflandırması.....	26
4. MRI BT Sınıflandırması ve Segmentasyonu Arasındaki Fark.....	32
5. BT MRI Sınıflandırmasında Kullanılan Algoritmalar	33
a. MRG Sınıflandırmasında Kullanılan Algoritmaların Kısaca Tanıtımı	33
b. Uygulamalar	34
c. BT MRG'de Kullanılan Sınıflandırma Algoritmalarının Türleri.....	34
6. Derin Öğrenme Çerçevesi	38
a. Tanımı.....	38
b. BT MR'inde Derin Öğrenme Uygulamaları	38
7. BT MRG Beyin Tümörü Sınıflandırmasında Önceden Eğitilmiş Modeller ..	39
C. Geleneksel Görüntü İşleme Tabanlı Teknikler	41
IV. MATERYALLER.....	44
A. Veri Setleri	44
V. YÖNTEMLER.....	45
A. Temel Algoritmalar	45
1. Doğrusal Regresyon	45
2. Destek Vektör Makinesi (SVM)	46
3. Temel.....	46
a. Çekirdek	49
4. Doğrusal Ayrımıcı Analizi (LDA)	49
5. Lojistik Regresyon (LR).....	51
B. Yaygın Olarak Kullanılan Mimariler ve Transfer Öğrenimi	52
1. Derin Öğrenme	52
2. Convölüsyonel Sinir Ağı (CNN).....	52

3. Figure of Layers	54
4. Önceden Eğitilmiş Modeller	54
a. AlexNet	55
b. ResNet	56
c. DenseNet	58
d. Efficient Net	59
e. Squeeze -Net	60
f. VGG19	60
VI. DENEYSEL SONUÇLAR	62
A. Sınıflandırma Görevlerinde Önceden Eğitilmiş Modellerin Kullanım Teknikleri....	62
B. Metrikler ve Karmaşıklık Matrisleri	69
VII. GELECEK ÇALIŞMALAR.....	74
VIII. SONUÇ	75
IX. KAYNAKÇA.....	77
RESUME.....	Hata! Yer işareti tanımlanmamış.

KISALTMALAR LİSTESİ

AIAN	: Amerikan yerlisi ve Alaska yerlisi
ANN	: Yapay Sinir Ağı
AYA	: Genç ve yetişkinler
BT	: Beyin tümörü
CNN	: Evrişimli Sinir Ağları
CNS	: Santral sinir sistemi
CT	: Bilgisayarlı Tomografi
MRG	: Manyetik Rezonans Görüntüleme
NCI	: Ulusal Kanser Enstitüsü
TL	: Transfer Öğrenme
WHO	: Dünya Sağlık Örgütü

ÇİZELGELER LİSTESİ

Çizelge 1	Araştırma Yapısı	64
Çizelge 2	Önceden Eğitilmiş Modellerin Üç Kullanım Yöntemi.	66
Çizelge 3	Genişletilmiş Bir Araştırma İçin Olası Senaryo (a Kısımı)	67
Çizelge 4	Genişletilmiş Bir Araştırma İçin Olası Senaryo (b Kısımı)	67
Çizelge 5	Basit Karşılaştırma	67
Çizelge 6	Araştırılan Veri Büyütme Teknikleri	68
Çizelge 7	AlexNet Metrik Sonuçları	69
Çizelge 8	DenseNet Metrik Sonuçları.....	69
Çizelge 9	ResNet50 Metrik Sonuçları.....	71
Çizelge 10	Xception Metrics Sonuçları.....	71
Çizelge 11	VGG-16 Metrik Sonuçları.....	72

ŞEKİLLER LİSTESİ

Şekil 1	Beyin Tümörleri, Primer veya Sekonder Kansere Tiplerine Ayrılır.	4
Şekil 2	İyi Hüylü ve Kötü Hüylü Beyin Tümörleri Arasındaki Ayrımı Göstermektedir.	5
Şekil 3	Sınıflandırma Sınıflandırıcı Modelinin Girdileri ve Olasılıksal Çıktılarıdır....	13
Şekil 4	Çok Katmanlı Algılayıcı Yapılandırması	18
Şekil 5	Derin Sinir Ağı Yapısı	29
Şekil 6	Bölümlenmiş Resim Özellik Tabanlı Sınıflandırıcı (SIFC): (A) Eğitim, (B) Test ve (C) Operasyonel Aşamalar	29
Şekil 7	"Görüntü Özellikleri Temelli Sınıflandırıcı (AIFC)"yi Göstermektedir.	30
Şekil 8	Gerçek ve Segmente Edilmiş Görüntü Özellikleri Temelli Sınıflandırıcı ..	30
Şekil 9	Gerçek Görüntüye Dayalı Sınıflandırıcı ve Bölümlenmiş Görüntüye Dayalı Sınıflandırıcı	31
Şekil 10	Gerçek ve Bölümlenmiş Görüntü Tabanlı Sınıflandırıcı	32
Şekil 11	Algoritmanın Girdi ve Çıktılarına.....	34
Şekil 12	Evrişimli Sinir Ağlarının Mimarisi	35
Şekil 13	36
Şekil 14	Transfer Öğrenme Kavramı	37
Şekil 15	Kaggle Verisetinden Örnek Veriler	44
Şekil 16	SVM (a)	47
Şekil 17	SVM (b)	47
Şekil 18	SVM (c)	48
Şekil 19	SVM (d)	48
Şekil 20	LDA (a).....	50
Şekil 21	LDA (b).....	51
Şekil 22	Sigmoid Fonksiyonu, Sigmoid Şekline Sahip Bir Fonksiyon Türüdür.	51
Şekil 23	İki Gizli Katman İçeren DNN Mimarisi Örneği. Oklar Ağırlıkları Temsil Ederken, Düğümler Girdi, Gizli ve Çıktı Değişkenlerini Temsil Eder. Değiştirilmiş Resim	52
Şekil 24	CNN'nin Mimarisi.....	53

Şekil 25	Geleneksel 3 Katmanlı Sinir Ağı	53
Şekil 26	CNN'nin Nöronlarının Üç Boyutlu Yerleşimi	54
Şekil 27	Tezdeki Araştırma İçin Önerilen Teknikler	54
Şekil 28	İnce Ayarlama Stratejileri	55
Şekil 29	CIFAR-10 veri kümesinde 20 ve 56 katmanlı "düz" ağlarla eğitim hatası (sol) ve test hatası (sağ).....	56
Şekil 30	Artımsal Öğrenme: Bir Yapı Taşı	57
Şekil 31	Kalıntı Öğrenimi: Bir Yapı Bloğu.....	58
Şekil 32	Standart ConvNet	58
Şekil 33	ResNet Konsepti.....	59
Şekil 34	DenseNet'teki Bir Yoğun Blok	59
Şekil 35	Büyüme Oranık Olan DenseNet'teki Yoğun Blok	59
Şekil 36	EfficientNetB0 Temel Model Mimarisi	60
Şekil 37	VGG-19 Modelinin Temel Mimari Yapısı.	61
Şekil 38	Bu Tezde Önerilen Önceden Eğitilmiş Modellerin Araştırılması Yöntemi. ...	65
Şekil 39	EfficientNetB0 Sonuçları	69
Şekil 40	Resnet50 Sonuçları.....	70
Şekil 41	InceptionResnetv2 Sonuçları Metrikleri ve Karışıklık Matrisi	70
Şekil 42	VGG16 Sonuçları Doğruluk ve Kayıp.....	72

I. GİRİŞ

Bugün, ölümün önde gelen nedenlerinden biri kanserdir. Dünya Sağlık Örgütü (WHO), 2018 yılında dünya genelinde yaklaşık dokuz milyon kişinin kanserden öldüğünü belirtmektedir (www.who.int). Doğru teşhis, bunların %30 ila %50'sinin önlenmesine neden olabilirdi. Beyin tümörleri, en ölümcül kanser türleri arasındadır. İstatistikler, 2019 yılında yaklaşık 18.000 yetişkinin beyin tümörlerinden ölmesinin mümkün olduğunu göstermektedir (www.cancer.net). Beyin tümörlerinin sınıflandırılması ve tanımlanması için gelişmiş ve doğru yöntemler, son teknolojilerle otomatik sistemler kullanılarak sınıflandırılabilir. Beyin tümörü oluşumu, beynin anormal şekilde büyüyen kanserli bir hücre topluluğudur. Primer beyin tümörleri beyin ve sinir sistemi hücrelerinden kaynaklanır. Adlarını ilk gördükleri doku türünden alırlar. Beyinde tümörler için 100'den fazla farklı tür bulunmaktadır. Beyinde yayılabilen de görülmektedir. Beyin tümörleri nöbetlere, baş ağrılarına ve diğer semptomlara neden olabilirler. Makine öğrenimi, beyin tümörleri için MRG okumalarının zaman ve doğruluğu konusunda büyük bir problemi çözdü, bu çalışmanın sonraki bölümlerinde gösterilecektir.

A. Giriş ve Motivasyon

Beyindeki hücrelerin kontrolsüz ve hızlı büyümesi, tümörlerin gelişmesine neden olur. Zamanında tedavi edilmezse, ölüme neden olabilir. Bu alanda yapılan çeşitli önemli çalışmalar ve umut verici sonuçlara rağmen, doğru segmentasyon ve sınıflandırma hala zorlu görevlerdir. Beyin tümörü tanısında önemli bir engel, hastalıklı hücrelerin değişkenliği, formu ve hacmi olarak görülür. PET, CT, DWI ve MRG gibi üç ana teknoloji, beyin tümörü olan hastaların beyin anatomisini değerlendirmek için yaygın olarak kullanılmaktadır (Amin vd., 2021).

BT görüntüleri, geleneksel X-ışınları ile elde edilen görüntülere göre daha detaylı bilgi sağlar. İlk kullanıldığından bu yana, Bilgisayarlı Tomografi geniş çapta önerilmiş ve kullanılmıştır. Bir araştırmaya göre, Amerika Birleşik Devletleri'nde yıllık BT tarama oranı 62 milyon olup, bunun 4 milyonu gençler için yapılmaktadır.

BT taramaları sayesinde, insan vücudunun birçok bölgesinde kan damarları, kemikler ve yumuşak dokular görülebilir. Bununla birlikte, BT taramaları geleneksel X-ışınlarına göre daha fazla radyasyon üretir. Birden fazla BT taraması yapıldığında, bu radyasyon kanser riskini artırabilir. Kanser riskleri, CT radyasyon maruziyetleri ile ilgili olarak değerlendirilmiştir (Amin vd., 2021). MRG taramaları, CT taramalarıyla gizlenen özellikleri de değerlendirmek için kullanılabilir, çünkü yumuşak dokular arasında büyük bir kontrast sağlar ve daha belirgin bir anatomik yapı oluşmasına neden olur. MRG taraması, çeşitli vücut bileşenlerini kapsamlı bir şekilde incelemek için kullanılır ve diğer görüntüleme yöntemlerinden daha erken beyin bozukluklarının tespitine yardımcı olur. Bu nedenle, beyin mimarisi karmaşık olduğundan, tümör segmentasyonunda daha kullanışlıdır (Amin vd., 2021). Beyin tümör taramaları sınıflandırma yöntemi için çözümler olarak, ön işleme stratejilerini, CT ve MRG segmentasyon tekniklerini, kullanılan sınıflandırma yöntemlerini ve uygulanan derin öğrenme yaklaşımlarını, benchmark veri setleri ve performans ölçümlerini incelemektedir.

Surveillance, Epidemiology, and End Results (SEER) Projesi, Amerika Birleşik Devletleri'nde kanser yükünü azaltmak için kanser istatistiklerini yayınlamaktadır. 100.000 kişi başına beyin ve diğer sinir sistemi kanserlerinde yeni enfeksiyon ve ölümler yılda 6,3 oranında yeni vaka olarak teşhis edilmiştir. Yıllık ölüm oranı 100.000 kişide 4,4 erkek ve kadın olarak hesaplanmıştır. Bu rakamlar, 2015-2019 yılları arasındaki vakalar ve ölümlere dayanmaktadır ve yaşa göre uyarlanmıştır. Beyinde veya diğer ilişkili sinir sistemlerinde oluşan kanserler, ABD'deki kanser ölüm oranları açısından dokuzuncu sırayı alır. Yıllık ölüm oranı, 2015-2019 yılları arasındaki ölümlere dayanarak hesaplanan, yaşa göre ayarlanmış 100.000 erkek ve kadında 4,4'tür. (SEER, t.y.) Hastalığın ciddiyeti, kanserin boyutu ve beyindeki yeri tarafından belirlenir. Erken teşhis ve doğru sınıflandırma sağlamak için bu tezde makine öğrenimi algoritmaları değerlendirilecektir.

Dünya Sağlık Örgütü verilerine göre, 2020 yılında küresel olarak 10 milyon kişi kanserden öldü (www.who.int). Erken teşhis, bu vakaların %30-50'sini önleyebilirdi. Beyin kanseri, en kötü kanser türleri arasındadır. Genel olarak kanser türleri farklılık gösterirken, (Types of Brain Tumors | Neurological Surgery | University of Pittsburgh, t.y.) beyin tümörleri, primer ve sekonder olarak iki tür tümörü içerir. Primer beyin tümörlerinin ortaya çıktığı doku türü, onları

sınıflandırmak için kullanılır. Destekleyici glial dokuda başlayan gliomlar, en yaygın beyin tümörleridir. Gliomların farklı tipleri vardır. Meningiyomlar, meninkslerden kaynaklanır. Genellikle zararsızdırlar. Yavaşça büyüdükleri için beyin bu tümörlerin varlığına uyum sağlayabilir; meningiyomlar belirtilere neden olmadan oldukça büyük olabilirler. 30-50 yaşları arasındaki kadınlarda daha sık görülürler. Schwann hücrelerinden oluşan miyelin tabakasını koruyan tümörler olan schwannomalar, kanserli tümörlerdir. Akustik nöroma bir tür schwannomadır. Genellikle yetişkinleri etkiler. Kadınlar bu tümörlere erkeklere göre iki kat daha yatkındır (Types of Brain Tumors | Neurological Surgery | University of Pittsburgh, t.y. 2020).

Kraniyofaringiyomalar, hipotalamusa yakın olan hipofiz bezinin yakınında ortaya çıkarlar. Genellikle iyi huyludurlar; ancak hipotalamusa zarar verebilir veya baskı yapabilirler ve önemli işlevleri etkileyebildikleri için bazen kanserli olarak yanlış teşhis edilebilirler. Bu tür kötü huylu tümörlerin en sık kurbanları çocuklar ve gençlerdir. Germ hücreli kanserler, primitif (gelişmekte olan) hücreler olan germ hücrelerinden kaynaklanır. Beyindeki en yaygın germ hücreli tümör bir germinomadır. Pineal bölgedeki kanserler, beyin merkezine yakın küçük bir organ olan pineal bölgesinde gelişir. Tümör yavaş (pineositoma) veya hızlı (adenokarsinom) şekilde gelişebilir (pineoblastoma). Pineal bölgesine erişim çok zor olduğu için, bu tümörler çoğu zaman çıkarılamazlar (Jemal vd., 2012).

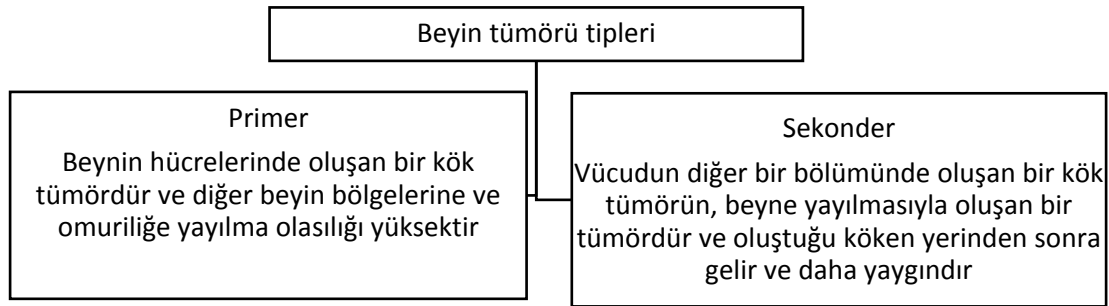
Hızlı nüfus artışı, yaşlanma ve artan risk faktörlerinin neden olduğu etkiler nedeniyle, küresel kanser yüzdesinin sadece %5'ine sahip olan ekonomik olarak az gelişmiş ülkelerde kanserle ilgili ölüm oranlarının giderek arttığı gözlemlenmiştir. Örneğin, Jemal ve ark. (2012) araştırmasına göre, 2008 yılında Afrika kıtasında yaklaşık 715 bin yeni kanser vakası ve 542 bin kanser ölümü vakası beklenirken, bu rakamların önümüzdeki iki on yıl içinde dört katına çıkması beklenmektedir.

1. Beyin Tümörü

Beyin tümörü, hastanın beyni içinde veya çevresindeki hücrelerin anormal büyümesidir ve nörolojik sistemde bozukluklara neden olabilir ve ölüme yol açabilir. Uluslararası Kanser Araştırma Ajansı (IARC), bu kanseri tüm kanser ölümleri arasında %2,52 ile 12. sırada sıralamaktadır. Sadece ABD'de kaydedilen vaka sayısı 700.000'in üzerinde olup, bunların %42'si erkek ve %58'i kadındır. Benzer şekilde, Kanada Beyin Tümörü Vakfı, Kanada'da her gün 27 yeni beyin tümörü vakasının

tespit edildiğini rapor etmektedir. Bu hastalık tekrarlayan baş ağrısı, denge ve konuşma sorunları, işitme sorunları, kişilik değişiklikleri, yorgunluk ve açıklanamayan bulantı gibi belirtilere neden olabilir (Agravat vd., 2021).

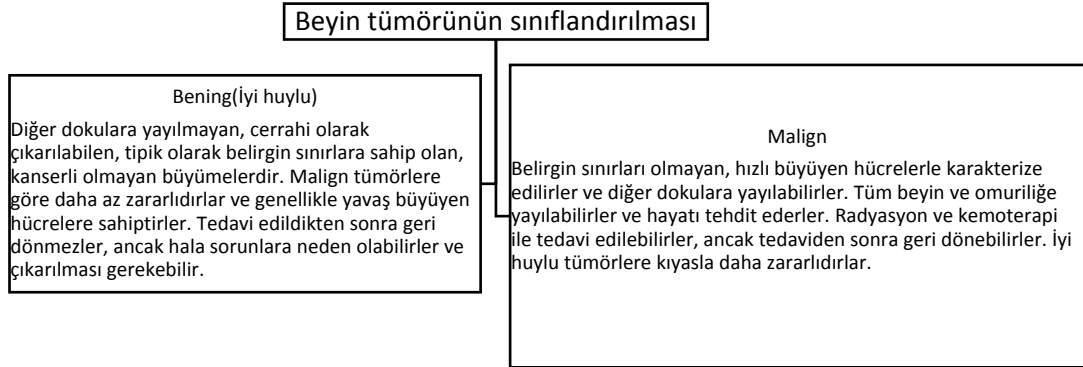
Dünya genelinde 150 çeşit beyin tümörü vardır ve bunlar kanserli (malign) veya kansersiz (benign) olarak sınıflandırılır. Düşük dereceli Astrocytoma, Pilocytic Astrocytoma, Glioblastoma, Anaplastik ve Astrocytoma tümü de I. derece malign tümörlerdir. İlk iki kategori yarı malign iken, son iki kategori malign ve ölüme neden olabilir (Deimling vd., 2009). Beyin tümörü gelişimi çok çeşitlidir. Lokasyonu ve büyüme hızı nörolojik sistem üzerindeki etkilerini belirler. Beyin tümörlerinin teşhisinde biyopsiler, nörolojik muayeneler ve radyografik görüntüler gibi çeşitli prosedür ve yöntemler zaman içinde gelişmiştir (Kotrotsou vd., 2016). Çoğu teşhis yöntemi uzun zaman alacağından, doktorlar erken aşamada tümörü keşfedip teşhis edebilecek hızlı bir beyin tümörü teşhis aracına ihtiyaç duyarlar ve bu da mortaliteyi azaltır.



Şekil 1 Beyin Tümörleri, Primer veya Sekonder Kanser Tiplerine Ayrılır.

Beyin tümörleri, önceden belirtildiği gibi anormal hücrelerin birikimleri veya büyümeleridir. Beyin dokusunda başlayıp geliştiği için, beyin tümörü en ölümcül ve nadir kanser türlerinden biridir. Baş ağrısı, görme sorunları, ruh hali değişiklikleri ve ani nöbetler gibi belirtiler görülür. Şekil 1'de görüldüğü gibi, beyin kanserinin iki temel farklı türü vardır: primer tümör ve sekonder tümör. Temel olarak, primer tip en yaygın olanıdır ve aile öyküsü, genetik veya bu tür beyin tümörlerine duyarlı olan genetik bir bileşen nedeniyle oluşur. İkinci tür daha az yaygındır ve radyasyon veya kimyasallar gibi harici uyarıcılardan veya beyne ilerleyen belirli diğer kanser türlerine maruz kalmanın bir sonucu olarak ortaya çıkar. Primer beyin tümörleri benign (kansere değil) ve malign (kansere) kategorilere ayrılır. Şekil 2, benign ve malign tümörleri ayıran özellikleri göstermektedir. Metastatik veya sekonder tümörlerin çoğu kanser öncesi ve malign olarak sınıflandırılır (www.cancer.net).

Hücrelerin DNA'sı zarar gördüğünde, tümör oluşumu, iyi huylu veya kötü huylu olabilen kanser hücrelerinin oluşmasına neden olur. Bu hücrelerin genetik yapısındaki mutasyonlar, düzensiz hücre bölünmesine neden olur ve sonuç olarak bir kitle oluşur. Kötü huylu bir tümör, kanserli bir tümördür. Bu, erken bir aşamada keşfedilmezse, farklı vücut bölgelerine yayılabileceği anlamına gelir. Öte yandan, iyi huylu bir tümör gelişebilir ancak yayılmaz. Bir iyi huylu tümör, çoğu zaman zarar vermeden alınabilir (www.cancer.net).



Şekil 2 İyi Huylu ve Kötü Huylu Beyin Tümörleri Arasındaki Ayrımı Göstermektedir.

Beyin tümörleri farklı formlarda gelebilirler. Ancak bu tezde, glioma, meningioma ve hipofiz olmak üzere üç farklı tür tümör incelendi. Hipofiz tümörleri, beyinde hipofiz bezinin büyüyen anormal hücrelerden oluşur. Bazen hipofiz tümörleri, önemli vücut süreçlerini düzenleyen belirli hormonların miktarını azaltabilir. Adenomlar, benign olarak adlandırılan kanser olmayan büyümeler, hipofiz tümörlerinin çoğunu oluşturur. Adenomlar, hipofiz bezi çevresindeki dokularda kalır ve diğer beyin bölgelerine yayılmaz (www.mayoclinic.org).

Beyin tümörlerinin bir başka türü olan meningioma, omurilik ve beyin zarlarını kaplayan zarların (meninksler) bir kısmından gelişir. Beyinde gelişen en yaygın tümör türüdür. **Genellikle meningiomalar birkaç yıl boyunca ciddi yan etkilere neden olmadan çok yavaş bir şekilde gelişir. Fakat** bazı durumlarda, yakındaki beyin dokuları, sinirler veya kan damarları üzerindeki etkisi ciddi bir engelliliğe neden olabilir. Her olgunluk seviyesi kötü huylu tümörlerden etkilenebilir, ancak genellikle kadınlarda ve daha ileri yaşlarda bulunur. **Meningiomalar çoğunlukla herhangi bir belirti olmadan yavaş büyür,** bu nedenle genellikle hemen tedavi gerektirmez ve zamanla izlenebilirler (www.mayoclinic.org).

Beyin ve omurilikte gelişebilen gliom adlı tümörlerin bir türü vardır. Glioma beyin tümörü türü, sinir hücrelerini koruyan ve destekleyen jelatinöz destek hücrelerinden (glial hücreler) kaynaklanır. Tümörleri üç farklı glial hücre tipi üretebilir. Tümörü oluşturan özel glial hücre tipi, gliomları sınıflandırmak için kullanılır ve tümörün yaşam boyunca nasıl davranacağı ve en iyi çalışma şansına sahip tedavileri tahmin etmek için kullanılabilir. Tam konumu ve büyüme hızına bağlı olarak, gliom beyin fonksiyonlarını etkileyebilir ve yaşam tehdidi oluşturabilir. Beyin tümörleri arasında en sık teşhis edilen primer türler; gliomlardır. Prognoz ve tedavi süreci glioma türüne bağlıdır. Genel olarak, glioma tedavileri; hedefli tedavi, radyasyon tedavisi, kemoterapi, cerrahi ve deneysel klinik denemeleri içerir (www.mayoclinic.org).

B. Beyin Tümörü Nedenleri ve Belirtileri

Beyin tümörünün teşhisinde çeşitli yöntemler vardır. Bunlar arasında, nörolojik muayene, görme, işitme ve denge testleri ile refleks testleri gibi duyuşal testler, beyin tümörünü tespit etmek için diğer testler ve her bir kişi için uygun tedavi planını belirlemek için manyetik rezonans görüntüleme kullanılması bulunur. Pozitron emisyon tomografi (CT) taraması ile beyin tümörünün görüntülenmesi ve diğer vücut bölgelerinde kanser varlığını tespit etmek için teşhis prosedürleri serisi kullanılması yer alır. Ayrıca, beyin tümörü çıkarılırken biyopsi yapılması veya beyin omurilik sıvısının mikroskop altında incelenmesi için bir omurilik ponksiyonu yapılması gibi yöntemler de kullanılabilir (Suneetha vd., 2018).

Beyin tümörünün kesin bir sebebi olmayabilir, ancak bazı faktörler beyin tümörüne neden olabilir. Bunlar arasında radyoaktif maddelere ve atom bombalarından kaynaklanan radyasyona maruz kalma, yaşlanma, koku ve kimyasallara maruz kalma, fazla sigara tüketimi, toksinler ve viral enfeksiyonlar gibi faktörler yer alır. Aile öyküsü veya beyin tümörü geliştirme riskini artıran genetik sendromlar gibi genetik faktörler de beyin tümörü geliştirme şansını artırabilir (Kotrotsou vd., 2016).

C. Gerçekler | İstatistikler – Rakamlar

Yaklaşık 700.000 Amerikalıda birincil beyin tümörleri vardır. Yaklaşık %71'i iyi huylu beyin tümörleridir. Malign beyin tümörleri, beyinde oluşan tümörlerin yaklaşık %29'unu oluşturur. Yaklaşık %58'i kadınları etkilerken, bu yüzdenin yaklaşık %16'sından azı erkekleri etkiler. 2022'de, malign beyin kanseri nedeniyle 18.200'den fazla insanın hayatını kaybedeceği tahmin ediliyor. Yüzden fazla farklı beyin tümörü türü vardır ve her birinde belirtiler, tedaviler ve prognozlar farklılık gösterir.

ABD'de, 13.657 çocuğun birincil beyin tümörü olduğu tahmin edilmektedir. Yıllık tespit edilen tüm beyin tümörlerinin yaklaşık dörtte biri 0-14 yaş grubundaki çocukları etkilemektedir. 2022 yılında 4.170 çocuğa beyin tümörü tanısı konulması beklenmektedir. (www.cancer.net). Tüm birincil pediatrik beyin tümörleri için göreceli beş yıllık sağkalım oranı %82,8'dir. Malign tümörler için beş yıllık sağkalım oranı %74,8'dir. Beyin tümörleri, 0-14 yaş arası çocuklarda kansere bağlı ölümlerin başlıca nedenidir. Pilocytic astrocytoma (%18,3), glioma, malign, NOS (%14,8), embryonal tümörler (%12,3), medulloblastoma (%67,7), AT/RT (%17,1) ve PNET çocuklarda en sık görülen beyin kanserleridir (%8,5). Bu yaş grubundaki tümörlerin yaklaşık %51'i gliomalardır (www.cancer.net).

ABD'de, 0-19 yaş arası çocuklar ve gençler arasında beyin tümörleri en yaygın katı malignite grubudur. Tüm çocuk birincil beyin tümörleri için göreceli beş yıllık sağkalım oranı %75,6'dır. Pediatrik tümörler, 0-19 yaş aralığındaki çocuklar ve gençler arasında kansere bağlı ölümlerin başlıca nedenidir. Çocuklarda en sık görülen beyin kanserleri pilositik astrocytoma (%15,2), çeşitli gliomalar (%12,2) ve embryonal tümörler (%9,4) dir. Gençlerde (15-19) en sık görülen beyin kanserleri hipofiz tümörleridir (www.cancer.net). Tüm birincil pediatrik beyin kanseri vakaları da dahil olmak üzere insidans oranları, beyazlarda diğer ırklardan bireylerde daha yüksektir (www.braintumor.org).

Adölesanlar ve genç yetişkinlerde beyin kanserinin en yaygın tipleri sinir kılıfı tümörleri ve hipofiz tümörleridir. Buna karşılık, 40 yaşın üzerindeki insanlarda nadir görülmektedir. 2022 yılında, ABD'de 40 yaşın üzerinde 72.360 kişi birincil beyin kanseri tanısı alması beklenmektedir. Tümörler, 40 yaş ve üzeri kişilerde altıncı en yaygın kanser türüdür. BT, 40 yaş ve üzeri kişilerde kansere bağlı ölümün on ikinci

en büyük nedenidir. Böyle bir beyin kanseri birincil tipi ile tanı konulan kişilerin nispi toplam beş yıllık ölüm oranı %72.2'dir. Malign tümörlerin oranı %21 iken, benign kanser oranı %90.3'tür. Meningiomalar ve astro-sitomaların gliomları, ependimomlar, glioblastomalar, ependimomlar ve oligodendrogliomalar yetişkinlerin %81'ini oluşturmaktadır (www.braintumor.org).

ABD Nüfus Sayım Bürosu'nun etnik köken beyin tümörleri üzerine verilerine göre, beyin kanserleri ve diğer sinir sistem kanserlerinde Siyah/Afrika kökenli Amerikalılar diğer ırklardan biraz daha yüksek bir ölüm oranına sahiptir, 100.000 kişide 24.58'e karşın Beyazlar 24.24/100.000 oranında bir ölüm oranına sahiptir. Bununla birlikte, Hispanikler 22.12/100.000, AIAN 14.63/100.000 ölüm oranlarına sahiptir. İyi huylu tümörler en yaygın olarak Siyah ve Afrika kökenli Amerikalılarda görülmektedir (100.000'de 20.14), bunu Beyazlar (16.69/100.000) takip ederken, Hispanikler (6.35/100.000) ve (AIAN) 11.08/100.000'de bulunur. Beyin kanseri insidans oranları türlerine göre değişmektedir. Bazı tümör tipleri belirgin ırksal/etnik insidans farklılıkları gösterse de, gerçek farklılıklar genellikle küçüktür ve önemli olmayabilir. Glioblastoma insidansı beyazlarda Siyah/Afrika kökenli Amerikalılara göre iki kat daha yüksektir. Meningioma ve hipofiz tümörü oranları Siyah/Afrika kökenli Amerikalılarda beyazlardan daha yüksektir. Embriyonik tümörler hariç, Asya ve Pasifik Adalı Amerikalılar birçok tümör tipi için beyazlardan daha yüksek sağkalım oranlarına sahiptir. Etnik köken olarak Hispanic/Latino/Latinx, çoğu tümör tipinde sağkalım oranını artırır. Yalnızca hipofiz ve CNS lenfomasının Hispanik/Latino/Latinx insanlar arasında, Hispanik/Latino/Latinx olmayan insanlardan daha sık görüldüğü gösterilmiştir (www.braintumor.org). **Beyin tümörleri ve santral sinir sistemi (SSS) tümörleri kadınlarda (%58) erkeklere (%42) göre daha sık teşhis edilmektedir. Kanser olmayan beyin tümörleri de kadınlarda daha sık görülmektedir (%64 kadın, %36 erkek). Öte yandan, kötü huylu beyin tümörleri erkeklerde (%56) kadınlara (%44) göre daha sık rastlanmaktadır.** Farklı beyin tümörlerinin insidansı değişir. Erkekler glioblastom ile tanı alırken, kadınlar meninjiyom ile tanı alır. Embriyonik tümörler hariç, glioblastom ve germ hücreli tümörler, erkeklerin malign beyin tümörlerinden daha sık ölmesine neden olur (www.braintumor.org).

D. Amaçlar

Bu araştırmanın temel amacı, önceden eğitilmiş model ve makine öğrenme çerçeveleri ile birleştirilmiş algoritmaların en iyi uygulamalarını belirlemek ve tarama sonrası manyetik rezonans görüntüleme (MRG) klinik tanı sürecinde tümör tipinin belirlenmesinde sınıflandırma hassasiyetini artırmaktır.

E. Beyin Tümörü Tespit Tekniği

Metastatik beyin tümörleri her yıl yaklaşık 150,000 kanser hastasını etkilemektedir (www.aans.org, s.a. 2019). Bu nedenle, bu beyin tümörlerinin mümkün olan en kısa sürede tespit ve teşhis edilmesi hayati önem taşır. Tümör yüksekliği, şekli ve varlığındaki geniş farklılıklar nedeniyle, tümörü uygun şekilde teşhis etmek için kesin ölçümler yapmak zordur. Beyin kanserleri ileri görüntüleme yöntemleri kullanılarak tespit edilebilir. En sık kullanılan teşhis teknolojileri bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MR) ile görüntülenir. Manyetik rezonans spektroskopisi (MRS) kullanılarak, bir MR'da bulunan lezyonun tipi belirlenebilir ve tümörün kimyasal özellikleri değerlendirilebilir. Pozitron emisyon tomografisi (PET) kalıcı beyin kanserlerini belirlemede kullanılabilir (www.aans.org, s.a. 2019).

Resim segmentasyonu, önceden belirlenmiş kriterlere dayanarak tek bir resmi birbirinden tamamen farklı ve eksiksiz parçalara ayırmak için **kullanılan** tekniktir. Beyin tümörlerine göre kesim, anormal beyin dokusunu normal dokudan ayırmayı içerir (Gordillo vd., 2013). Eşik teknolojisi, Bölge yetiştirme teknikleri, Kenar tabanlı teknoloji, Montaj teknolojisi, Deformasyondan etkilenen Çanak teknolojisi ve Tipik teknoloji, gölgeleme teknolojisinin temel tipleridir (Rogowska vd., 2009).

Enlistment prosedürü, birçok segmentasyon yaklaşımında kullanılan bir yaklaşımdır. Seçilen eşik değerine bağlı olarak görüntüler iki gruba ayrılır: eşik değerinden büyük veya eşit piksel değerlerine sahip olanlar ile eşik değerinden küçük veya eşit piksel değerlerine sahip olanlar. Bir gruptaki piksel değeri eşik değerinden küçükken, diğer grupta piksel değeri eşik değerinden büyüktür. Kriter tekniklerinin üç kategorisi vardır: yerel, global ve uyarlamalı kriter yaklaşımları. Sınır belirlemeye geldiğinde, resim alanlarının standart sapması veya yerel ortalamasına göre yerel değişkenlere dayalı olarak eşik değerleri seçilir. Büyük resimler için uluslararası

sınırları belirlemek için resmin histogramına dayalı olarak tek bir eşik değeri seçilir. Değişken veya dinamik eşik değerlerini tanımlamak için, her pikselin yerel sınır değeri ayrı ayrı seçilir (Altameem vd., 2014).

Eşik değerleri, segmentasyon sonuçları üzerinde büyük bir etkiye sahiptir. Yanlış eşik değeri seçimi yanlış segmentasyona neden olabilir. Birkaç yaklaşım sunulmuştur. Örneğin, Otsu eşik belirleme gibi eşiklerin otomatik olarak seçilmesi için kapsam yaklaşımları, resmin mekansal özelliklerinden bağımsız olarak gürültü hassasiyeti oluşturur. Bölgesel ekim teknolojisi, yakın piksellerin aynı türde olduğu şekilde sıralanmasıyla artan alan segmentasyon yaklaşımı kullanılarak resim bölünür. (Benzerlik kriterlerine göre, dokulu ve yoğunluk düzeyleri ile başlayan homojenlik standartlarına dayalı olarak bazı başlangıç konumları seçilerek, çevresindeki pikseller, parçacıklara homojenlik standartlarına bağlı olarak yavaş yavaş eklenir) (Varshney vd., 2009).

Bu yaklaşım oldukça basittir; bir görüntünün piksellerini benzer niteliklere sahip gruplara ayırabilir, bu da doğru şekilde oluşturulmuş büyük bir bölgeye yol açabilir. Bu, teknolojinin görüntünün uzamsal özelliklerini dikkate alması nedeniyle gürültüye daha az duyarlı olup, histogram belirleme teknolojisine göre daha iyi segmentasyona yol açar (Varshney vd., 2009). Bu strateji ayrıca bölgeleri benzer niteliklere sahip ayrı alanlara ve bölgelere ayırmak için de kullanılır.

Bu yaklaşım bağlantı alanını oluşturmak için kullanıldı. Holes (boşluklar) çeşitli şekillerde üretilebilir, bu tekniklerin temel kısıtlamasıdır. Ayrıca bağlantısı olmayan bölgeler de oluşturulabilir.

İllerleşmiş teknoloji, görüntülerde görülebilen bölgelerin kenarına karşılık gelen resim pikselini algılar ve sınır veya kenar, bir grup pikselin veya yerel bir pikselin yoğunluk gradyanına karşılık gelir. Bu, Laplacian, Sobel, Canny ve Prewitt gibi kenar operatörleri kullanılarak bir kenarlı biner resimle sonuçlanır. Basit, gürültüsüz fotoğraflar için kenar tabanlı teknoloji idealdir. Bu yaklaşımlar gürültülü görüntülerde aşırı veya eksik sınırlara neden olabilir. Bu algoritmaların hesaplanması kolaydır ve görüntünün içeriği hakkında herhangi bir önceden bilgi gerektirmez. Bu teknolojilerin temel sorunu, kenarın nesneyi tamamen çevreleyememesidir. Kalabalık bir arka plan üzerinde, bu işlemlerin hiçbiri istenen sonuçları vermeyecektir.

Gruplama teknikleri, nitelikleri, özellikleri ve özellikleri temel alınarak parçaları kategorik gruplara ayırma yöntemidir. Böylece, benzer veri kümelerinden oluşan kümeler oluşturulur. Bu, veri toplama gerektirmeyen bir gözetimsiz stratejidir. Kümeleme tabanlı algoritmalarla segmente veri oluşturma süreci daha az zamana ihtiyaç duyar. En sık kullanılan kümeleme yaklaşımları, K-mean kümeleme ve Bulanık C ortalaması kümelemedir (Mustaqeem vd., 2012).

Havza teknolojisi, bu teknikte her nesne için en az bir işaretçi veya köken seçilmelidir ve işlem görür. Bu teknik, görüntü piksellerini piksel yoğunluğuna göre gruplandırarak benzer yoğunluktaki pikselleri bir araya getirir. Belirgin tanımlanmış işaretçilerin kullanılması nedeniyle bu teknik, aşırı bölütleme ve az bölütleme sorunlarına sahiptir (Kanas vd., 2015).

Dönüştürülebilir model tabanlı teknoloji, bu yaklaşımlarda, güç fonksiyonunun segmentasyon derecesini elde etmek için optimize edildiği bir optimizasyon problemi olarak tanımlanır (Giraldi vd., 2005). Yılan modellerine dayalı yaklaşımlar olarak iki tip dönüştürülebilir model veya yaklaşım vardır: grafiksel modeller ve grafik modeller. Genel yapıyla ilgili önceden bilinen bilgiler şekil modelinde serbest form ve şekil modelinin belirli yapısının parametrelendirme yöntemi kullanılarak saklanır. Yılan gibi bağımsız bir modelde önceden bilinen veriler, genellikle süreklilik kısıtlamaları ve yerel düzleştirme ile oluşur ve belirgin bir küresel yapı bırakmaz (Shivhare vd., 2019). Aktif kontur modeli (ACM), rastgele alan yaklaşımı ve seviye ayarlama yöntemi (Giraldi vd., 2005).

Anonim topolojiye sahip, şekli değişmiş veya yılan gibi objeleri çıkarmak için, dönüştürülebilir modeller idealdir. Dönüştürülebilir modelin matematiksel formülü, tek bir resim çıkarma işlemine dahil etmeyi kolaylaştırır. Bilgi temelli kısıtlamalar ve temel sınır özelliklerine dayalı kısıtlamalar mevcuttur (Kanas vd., 2015).

Bu modellerin temel kısıtlamalarından biri, sadece basit topolojik nesnelere kontrol edebilme yeteneğidir. Başlangıç koşuluna karşı yılanın hassasiyeti, çözülemeyen enerji ve kasılma kuvveti davranışından kaynaklanan başka bir kısıtlamadır. İç enerji periyodunun uzunluğu da bir başka sınırlamadır (Shivhare vd., 2019).

F. AI for Other Diseases

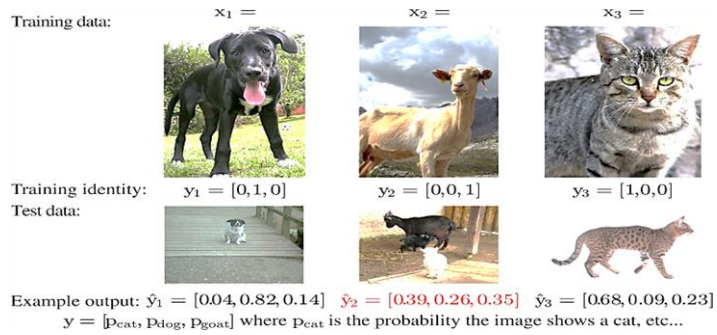
"Makine öğrenmesi" terimi, veri kümelerini kullanarak anlamlı tahminler oluşturan geniş bir algoritma yelpazesini tanımlar. Genellikle, bu veri kümeleri oldukça büyüktür. Makine öğrenmesi, semantikleri yorumlayıp insan bilgisini çıkarabilecek noktaya ilerledi. Bazen soyut desenler insan uzmanlarından daha doğru bir şekilde tespit edilebilir. Geleneksel istatistiksel modelleme yaklaşımlarının geniş veri hacmi nedeniyle ciddi bir güç kazandığı modern makine öğrenmesi, algoritma tasarımının gelişmesi ve bilgisayar gücündeki patlamayla birlikte bir güç haline gelmiştir.

Makine öğrenmesi algoritmaları birçok şekilde kullanılır. Bu genellikle mevcut model olarak adlandırılır. Verinin doğası ve ihtiyaç duyulan çözüm türü, belirli bir zorluk için bir modelin seçilmesinde rol oynar. En önemli faktör benzersiz veri noktalarının sayısıdır. Yeni derin öğrenme yöntemleri, 106 benzersiz veri noktalı büyük bir veri kümesi ile daha uygun olabilir. Az veri noktası varsa, geleneksel yaklaşımlar, örneğin doğrusal regresyon, daha etkilidir. Alternatif olarak, karar ağacı tekniği, önceden belirlenmiş kurallara dayanarak verileri bölgelere ayırır. Verinin doğası temel alınarak prosedürlerin değiştirilmesi daha iyi çalışma eğiliminde olduğunda dikkatli olunmalıdır. Bu, görüntü zaman serilerinin bir koleksiyonu veya genel bir tanımlama olsun, önemli değildir (Silver vd., 2017).

Makine öğrenimi algoritmaları birçok şekilde kullanılır. Çoğunlukla, bu mevcut model olarak adlandırılır. Verinin doğası ve ihtiyaç duyulan çözüm türü, belirli bir sorun için bir model seçmede rol oynar. En önemli faktör, benzersiz veri noktalarının sayısıdır. Yeni derin öğrenme yöntemleri, 106 benzersiz veri noktalı büyük bir veri kümesinde daha iyi uyum sağlayabilir. Daha az veri noktası olduğunda ise doğrusal regresyon gibi geleneksel yaklaşımlar daha etkilidir. Alternatif olarak, karar ağacı tekniği, önceden belirlenmiş kurallara göre veriyi böler. Verinin doğası temel alınarak prosedürlerin değiştirilmesi durumunda, daha iyi çalışma eğilimine dikkat edilmelidir. İster bir resim zaman serileri sinyallerinin koleksiyonu isterse genel bir açıklama olsun, insan müdahalesi veya makine olsun, önemli değildir. (Silver vd., 2017).

Model çıktılarıyla ilgili konuşulduğunda, en yaygın iki seçenek sınıflandırma ve regresyondur. Sınıflandırma, niteliksel etiket verilerinin tahminine dayanır

(örneğin, görüntünün etiketi kedi veya köpek olarak görüntülenir) (Şekil 3), regresyon ise sürekli değişkenlerin tahminine dayanır (örneğin, belirli bir yükseklikte her kişinin ağırlığı nedir?) Aşağıdaki gösterim tanıtılmıştır: Model seçiyoruz, bu sadece $f(x_i)$ bir fonksiyondur, burada x model parametrelerini ve girdi verilerini temsil eder (parametrelerin bir koleksiyonunu temsil eder). Amaç, parametreleri tekrarlayarak tahmin edilen sonucu y_i $f(x_i)$; (birden fazla olabilir) elde etmektir. Model, y_i 'ye en yakın olduğu için kullanılabilir hale gelir. Yeni, daha önce gözlemlenmemiş girdi verileri x kullanılarak, tahminler $y = f(x)$ yapılır.



Şekil 3 Sınıflandırma Sınıflandırıcı Modelinin Girdileri ve Olasılıksal Çıktılarıdır.

Şekil 3, sınıflandırma sınıflandırıcı modelinin girdilerini ve olasılıksal çıktılarını göstermektedir. Sistemde üç parçalı bir sınıflandırıcı kullanılmaktadır. Resim olarak kedi, köpek veya keçi kullanılabilir. Sistem, kediler ($y_3 = [1, 0, 0]$), köpekler ($y_1 = [0, 1, 0]$) ve keçiler ($y_2 = [0, 0, 1]$) gibi diğer hayvanlarla etiketlenmiş fotoğraf koleksiyonu üzerinde eğitilir. Sınıflandırıcı daha sonra yeni bir test veri kümesinden geçer. Köpekleri ve kedileri ayırt edebilir. Ancak, keçinin fotoğrafı yanlışlıkla köpek olarak etiketlenmiştir.

G. Karşılaştırma İçin Son Teknoloji Önerilen Sınıflandırıcı

Doktorlar, tümörün aşamasını ve şeklini belirlemek için X-ışını görüntüleme kullanırlar (Rogowska vd., 2009) ve bu araştırma, terapinin beyin tümörünün tipine bağlı olduğu için önceden eğitilmiş modeller üzerinde derinlemesine bir araştırma sunmaktadır. ResNet152V2'nin önceden eğitilmiş modeli, taşıma ağı işlemleriyle birlikte kullanılmıştır. Beyin tümörlerinin teşhis ve sınıflandırmasında hızlı ve güvenilir bir yöntem olarak MRG görüntüleri kullanılmaktadır. Görüntü önışlemesi yapılarak (gürültü ve kenar boşlukları ortadan kaldırılır) veri kümesi geliştirilmiştir

(Alnemer vd., 2021). Ardından, önerilen eğitim modeline yüklenir. Son olarak, model insan beynindeki dört beyin kanseri türünü (glioma, meningioma, hipofiz ve hipofiz) ve malignitelerin yokluğunu ayırır. Geçmiş çalışmaların kapsamlı bir değerlendirmesi, aşırı doluluğun sorununu hafifletmek için veri zenginleştirme ve daha büyük veri kümelerinin kullanılmasını içermektedir. Dört kategori karışık öğrenme stratejisi kullanılır (glioma, meningioma, hipofiz ve tümör yok) (Alnemer vd., 2021).

H. Problem

Belirli bir beyin tümörü tespit makine öğrenmesi algoritması gerekmektedir. Çağdaş tıbbi görüntüleme yöntemlerinin geliştirilmesi sayesinde, beyin anormalliklerinin çoğu görünümü artık tamamen tespit edilebilir hale gelmiştir. Çeşitli faydaları nedeniyle, beyin anormalliklerinin teşhisi için bu teknikler arasında manyetik rezonans görüntüleme (MRG) öne çıkmaktadır. Bununla birlikte, günümüzde tıbbi araştırmalarda standart uygulama olan manuel tümör tanısı uzun sürmektedir (Nilakshi vd., 2018).

Tıbbi görüntüleme konusu genişleyen ve karmaşık bir alandır ve görüntü işleme, tıbbi endüstride önemli bir rol oynamaktadır. Bazı kanserler, tıbbi görüntüleme yoluyla daha doğru bir şekilde teşhis edilebilir. Beyin tümörleri, yaygın ancak önemli ve ölümcül bir durumdur. Görüntüleme teknikleri kullanılarak, beyin tümörü doğru bir şekilde teşhis edilebilir (Deepa vd., 2016).

MRG görüntülerindeki hastalıkların insan tarafından tespiti, hastanın gereksinim duyduğu tıbbi tedaviyi yavaşlattığı için hastanın hayatı tehlikeye girmektedir. Ayrıca, bir biyopsi olarak bilinen ve tümörün durumu hakkında veri toplamak için beyne bir cihazın yerleştirilmesini içeren cerrahi bir teknik, sonrasında hastayı etkiler. Bu nedenle, tümörün yerini ve sınıflandırılmasını belirlemek birkaç saat alabilir. Geleneksel yöntemlere kıyasla daha hızlı ve etkili bir bilgisayar destekli tanı yöntemi, bu dezavantajların üstesinden gelmek için ilk adım olarak önerilir (Nilakshi vd., 2018).

I. Amaçlar ve Hedefler

Bu çalışmada amaçlar ve hedefler aşağıdaki konuları araştırmaktır:

İnceleme: Bu çalışmada yapay sinir ağıları (ANN) ve yapısının blokları, evrişimli sinir ağıları (CNN) ve kullanımları ve önceden eğitilmiş modellerin kullanımı incelenecektir. Önceden eğitilmiş modellerin genel olarak görüntü sınıflandırmasında ve özellikle beyin tümörü MRG sınıflandırma görevlerinde kullanımı, önceki çalışmaların atıfları ile gözden geçirilecektir.

Değerlendirme: Bu araştırmada önceki araştırmalara dayanarak ve deneysel testler yaparak derin bir değerlendirme yapılacaktır. Deneysel testlerde, MRG B.T. sınıflandırma yeteneklerini değerlendirmek için özellikle özellik çıkarımı, ince ayar ve transfer öğrenme tekniklerini kullanarak modifiye edilmiş önceden eğitilmiş model test edilecektir.

Karşılaştırma: Bu çalışmada bahsi geçen makalelerle ve bu araştırmada yapılan deneysel sonuçlar arasında bir karşılaştırma yapılacaktır.

Bu çalışmanın temel amacı, önceden eğitilmiş modellerin B.T. MRG sınıflandırmasındaki performanslarını incelemek, **değerlendirip karşılaştırmak** ve gelecekteki çalışmaları yürütmek için araştırmacıların hangi yolda ilerlemeleri gerektiğini belirlemektir.

Zorluklar: Başlangıçta belirtilen çalışma konularına geçmeden önce, öncelikle çözülmesi gereken bazı zorluklar vardır. Özellikle bu durumda CNN'ler olmak üzere derin öğrenme teknikleriyle çalışırken karşılaşılan en büyük engellerden biri veri yetersizliğidir. CNN sınıflandırıcılarının doğruluğu, temel eğitim örneklerinin miktarı ve kalitesine çok bağlıdır (Junghwan vd., 2015). Bu nedenle, örneklerin eksikliğini telafi etmek için veri artırma yöntemleri uygulanarak mevcut veri setinin geliştirilmesi gerekecektir. Verilerin farklı organizasyonlar tarafından toplanması nedeniyle, kaçınılmaz olarak ortaya çıkan bir başka sorun da alan genelleştirmesidir. Ayrıca, ağların eğitimine devam etmek için öncelikle tümörlerin çıkarılması gerekmektedir. Bu, ağların yalnızca tümör içeren resimlerle eğitileceği anlamına gelmektedir. Sonuç olarak, beyin tümörlerinin tür kategorizasyonunu gerçekleştiren yayınlanmış materyaller olsa da, tanımları genellikle farklılık göstermektedir. Beyin tümörlerinin sınıflandırılması için literatürde yeterli kanıt bulunmamaktadır.

J. Tez Çizelgesi

Bu tezin amacı, manyetik rezonans görüntüleme (MRG) taramalarında beyin

tümörlerinin sınıflandırılması için yapay zeka tekniklerinin kullanımını araştırmaktır. İlk bölüm, çalışmanın arka planını ve motivasyonunu, araştırmanın bağlamını ve amacını içeren bir giriş sunacaktır. Bu, beyin tümörü tespiti için şu anda kullanılan tekniklerin tartışılmasını ve yapay zekanın diğer hastalıkların teşhisindeki potansiyel uygulamalarını da içerecektir. İkinci bölüm, yapay sinir ağlarına ve çalışmada kullanılacak çerçevelere ilişkin bir arka plan sağlayacak ve kanser ve çeşitli kanser türlerinin genel bir bakışını sunacaktır.

Üçüncü bölüm, beyin tümörleri hakkında mevcut literatürü, nedenleri ve semptomları, teşhis yöntemlerini ve görüntüleri ve MRG kullanarak beyin tümörlerinin sınıflandırılmasını inceleyecektir. Bu aynı zamanda derin öğrenme çerçevelerinin ve beyin tümörü MRG sınıflandırmasındaki uygulamalarının bir incelemesini de içerecek, bu alanda kullanılan önceden eğitilmiş modellerin bir gözden geçirilmesi de yapılacaktır. Dördüncü bölüm, veri setleri ve çerçeveler de dahil olmak üzere çalışmada kullanılan materyalleri tanımlayacaktır.

Tamamlanan tezin beşinci bölümü, doğrusal regresyon, destek vektör makineleri, doğrusal diskriminant analizi ve lojistik regresyon gibi temel algoritmaları içeren yöntemleri açıklayacak. Bu ayrıca sıklıkla kullanılan mimarilerin ve transfer öğreniminin yanı sıra kullanılacak önceden eğitilmiş modellerin açıklamasını da içerecektir. Altıncı bölüm, çalışmanın sonuçlarını, çeşitli modellerin performansını ve doğruluklarının karşılaştırılmasını sunacaktır. Yedinci bölüm, çalışma sırasında karşılaşılan herhangi bir kısıtlama veya zorlukları içeren sonuçların tartışılmasını sağlayacaktır. Son olarak, sekizinci bölüm, araştırmanın temel bulgularını özetleyecek ve bu alanda gelecekteki araştırmalar için olası yönelimler önererek bir sonuç sunacaktır.

II. TEMEL BİLGİ VE ÖN İNCELEMELER

A. Yapay Sinir Ağları

Beyindeki nöronlar arasındaki biyolojik bağlantılar yapay sinir ağı (ASA) temelini oluşturmaktadır. İlk olarak Rosenblatt tarafından 1958 yılında tanımlanan ASA'lar, biyolojik nöronları yapay nöronlarla değiştirirler (Cui vd., 2018). Yapay nöronlarda, birçok sinaptik ağırlık bir eşik veya sigmoid işlevi gibi bir aktivasyon işlevine iletilir. Bir nöronun çıkışı, işlevine bağlıdır, burada nokta ürün işlemi, $F(x)$ aktivasyon fonksiyonu, X özellik vektörü, W ise ağırlık vektörüdür. Aşağıdaki şekilde gösterilmiştir.

$$F(x) = \phi(x \cdot w)$$

Denklem 1

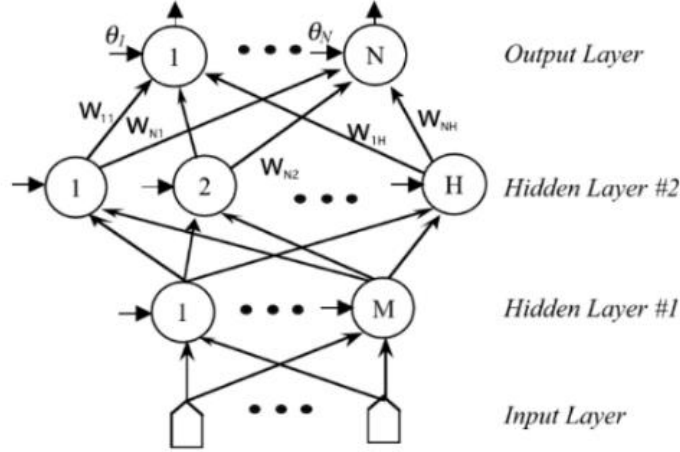
1. Perseptron

Perseptron, yapay sinir ağlarının temel ögesi olarak adlandırılır ve aynı zamanda yapay bir nöron olarak da anılabilir. Biyolojik insan nöronunu temsil eden bir çizim gibi düşünebiliriz. Biyolojik benzeri gibi, perseptron da önceden belirlenmiş girdilere, dendritlerle bilinen, bir çıkışa, aksana sahip olan bir "kapalı kutu" türüdür. Hem yapay hem de biyolojik nöronların temel yapısı aynıdır. Her girdiye bir ağırlık atanır ve bu, o belirli bağlantının genel çıktıya ne ölçüde katkıda bulunduğunu temsil eder.

2. Çok Katmanlı Perseptron

Tüm yapay sinir ağları (YSA) arasında, çok katmanlı perseptron (MLP) sinir ağı modeli şimdiye kadar en popüler ve yaygın olarak kullanılanıdır. Çok sayıda tıbbi uygulamaları tahmin etmek ve analiz etmek de dahil olmak üzere çeşitli zorlukları ele almak için, girişler ve çıktılar arasında doğrusal olmayan bir eşleme sağlamak için geniş çapta kullanılmıştır (Hu & Hwang, 2001).

Çoğu durumda, MLP bağlantıları Fig. 4'de gösterildiği gibi yapılandırılır. Bir giriş katmanı, bir veya daha fazla gizli katman veya seviyeler ve bir veya daha fazla çıkış katmanı bulunur. Dolayısıyla, özellik vektöründeki tanımlayıcı sayısı, girdi katmanı boyutuna eşit olmalıdır. Çoğu durumda, bu katmanda herhangi bir nöron fonksiyonu uygulanmaz (Hu & Hwang, 2001).



Şekil 4 Çok Katmanlı Algılayıcı Yapılandırması

Kaynak: Hu ve Hwang, 2001.

B. Beyin Tümörü MRG Sınıflandırmasındaki Çerçeveseler

Bu çalışmada, farklı BT türleri gösterilmiş ve tüm sınıflandırmaların birleştirilmiş gerçek ve segmente edilmiş sinir ağı türleriyle birlikte BT MR sınıflandırma türlerinin çeşitli türleri detaylarıyla açıklanmıştır. Ayrıca, özellikle radyoloji departmanında tıbbi alanda makine öğrenimi kavramının açıklanması ve uygulamaları, bu alanın MRG görüntülerinin geliştirilmesinde nasıl etkili olduğu da belirtilmiştir. Araştırmacı, BT MR için en pratik ve faydalı teknik olan derin öğrenmenin (DL) makine öğreniminin bir türü olduğunu göstermiştir. Derin öğrenme (DL) altındaki en başarılı modellere odaklandı, bunlar algoritmik işlemeyle sonuçları açıklamak için kullanılan evrişimli sinir ağı (CNN) modelleridir, örneğin VGG 16 ve ReLU. Ayrıca, önceden depolanan verilere dayanan algoritmik fonksiyonları ve hesaplamalarıyla CNN'in bir geliştirme türü olan aktarım öğrenmesi (TL) de açıklanmıştır. Bu çalışmaya ve diğer çalışmalara göre, aktarım öğrenmesi (TL) modeli en pratik olandır ve algoritmik işlevleriyle en net ve kesin BT MR görüntüleri üretmektedir. Ayrıca, bu çalışma, özellikle CNN ve TL gibi derin

öğrenme modellerinin algoritmalarla ilişkisi ve bağlantısı ile BT MRG'nin belirlenmesinde ve tespit edilmesinde algoritmaların işlevlerine bağlı olarak MRG hesaplamaları sonuçlarının hassasiyeti, özgüllüğü, doğruluğu, hassasiyeti ve hatırlama değerlerine nasıl bağlı olduğunu açıklamıştır. Genel olarak, bu çalışma, CNN ve TL çerçevelerinin model ve algoritmalarla ilişkisi ile BT'nin tüm tipleri, örneğin glioma (glioblastoma), meningioma, hipofiz tümörü veya iyi huylu olanı gibi MRG görüntülerini kesin olarak belirlemedeki çerçevesi takip edilerek yapılmıştır.

C. Kanser Nedir?

Normal durumlarda, vücut hücreleri mitoz olarak bilinen bir sürece göre bölünürler. Ancak hücrelerde aniden bir hata meydana gelirse, kontrolsüz hücre bölünmesi gerçekleşir ve trilyonlarca yeni hücre oluşur. Bu durum kanser veya tümör olarak adlandırılır. Bu hastalık genellikle kalp gibi bazı organlar hariç vücudun herhangi bir yerinde oluşabilir ve hücrelerinin diğer yerlere yayılabilme özelliği vardır. Bu duruma metastaz denir (NCI, 2021). Hücreler sinyal almadan anormal şekilde büyür ve çoğalırlarsa ve programlanmış hücre ölümü olan apoptozis durdurulursa, tümör olarak adlandırılan bir doku kümesi oluştururlar. Bu tümör kanserli veya kanserli olmayan bir tümör olabilir (NCI, 2021).

Ayrıca, bu hastalık dünya genelinde en yaygın olan hastalıktır ve her 6 ölümden **birinin nedeni** kanserdir, özellikle kanserli hücrelerin metastazı büyük ölçüde ölüm sayısının artmasına neden olur. **Kanserin, 2020'de dünya genelindeki ölüm oranı yaklaşık 10 milyon idi.** Ve her yıl yaklaşık 400.000 çocuk kanser hastalığına yakalanmaktadır (WHO, 2022). Kanserin ana kaynağı genetikle ilişkilidir, özellikle hücre gelişimi ve bölünmesinden sorumlu olan gen ile ilgilidir. Bu genin anormal şekilde çalışmaya başlaması kansere neden olur. Çevredeki kimyasallar, kirleticiler ve diğer faktörler nedeniyle insanlar etrafındaki pek çok değişiklik ve kanserojen madde, bu genin DNA'sında değişikliklere neden olarak kanser hastalığına yol açar (NCI, 2021).

D. Kanser Türleri

Vücudun konumuna ve organına bağlı olarak, birçok kanser türü bulunmaktadır. Bunlar arasında mesane kanseri, meme kanseri, akciğer kanseri,

serviks kanseri, boyun kanseri, kolorektal kanser, baş ve boyun kanseri, karaciğer kanseri, jinekolojik kanser, böbrek kanseri, lenfoma kanseri, mezotelyoma kanseri, miyeloma kanseri, over kanseri, prostat kanseri, cilt kanseri, beyin kanseri, tiroid kanseri, uterus kanseri, vajinal ve vulvar kanser yer almaktadır (CDC, 2022). Mesane kanseri belirli kimyasallar, mutasyonlar ve bazen sigara tüketimi nedeniyle oluşur. Mesane, üreter ve böbreklerin ürotelyal hücrelerinde meydana gelir ancak çoğunlukla mesane boşluğunda görülür. Erken teşhis edilebilen belirtileri vardır, ancak tekrarlayabilen bir kanser türüdür ve sürekli takip gerektirir (Mayo Clinic, 2022).

Meme kanseri, meme hücrelerinin anormal şekilde büyümesiyle bir tümör oluşmasıdır. Bu tümör lenf düğümleri yoluyla diğer alanlara ve organlara yayılabilir. Genellikle kadınlarda görülür ve mammografi ile erken teşhis edilebilir (Mayo Clinic, 2022). Serviks kanseri, uterus ile vajina arasındaki bölgede meydana gelir. Kadınlarda insan papilloma virüsü ve korunmasız cinsel ilişki sonucu ortaya çıkabilir. Bu kanser türünden korunmak için insan papilloma virüsü aşısı yapılabilir (NHS, 2021). Kolorektal kanser, kolon veya rektal kanser olarak da adlandırılan bir kanser türüdür. Kolon ve rektum bölgesinde ortaya çıkar. 45 yaşın üzerindeki herkes için test önerilmektedir (The American Cancer Society medical and editorial content team, 2020).

Kadın üreme sistemiyle ilgili olan ginekolojik kanser, HPV virüsü, cinsiyet, aile öyküsü, yaş ve obezite nedeniyle oluşur (Johns Hopkins Tıp Merkezi, s.a.). Baş ve boyun kanseri, sigara ve HPV nedeniyle boğaz, ağız veya farinks bölgesinde yayılır ve ilk aşamada tespit edilirse tedavi edilebilir (Cleveland Clinic tıbbi profesyonel, 2022). Karaciğer kanseri, karaciğer hücrelerinde, safra kanalında veya karaciğerin kan damarlarında bir tümördür. Kişinin bu tür kanserin enfeksiyonunu azaltmak için hepatit B ve C aşısı olması gerekmektedir (Cancer Council, s.a.).

Akciğer kanseri, özellikle hava yolu ve kirleticilerinden, sigaradan, pasif içicilikten ve nargileden kaynaklanan bir kitle oluşumdur. İki temel türü vardır: küçük hücreli kanser ve küçük hücreli olmayan kanser. Farklı şekillerde tedavi edilir (MedlinePlus, 2021). Böbrek kanseri, böbrek hücrelerinde oluşur ve temel olarak iki türü vardır: açık hücreli böbrek hücreli karsinom ve açık olmayan hücreli böbrek hücreli karsinom (The American Cancer Society tıbbi ve yayın ekip, 2020). Lenfoma kanseri, beyaz kan hücrelerinin bir alt sınıfı olan lenfositlerde oluşan bir kan

kanseridir. Miyeloma kanseri ise kemik iliğinde, özellikle plazma hücresinde oluşan bir kanser türüdür (Scott, 2022).

Mezotelyoma kanseri, akciğerler ve karın bölgesi gibi birçok organın dış sınırlarında oluşan bir kanser türüdür ve bu asbest adı verilen belirli bir lif türünün inhalasyonuna bağlıdır (Mesothelioma.com, 2022). Vajinal kanser, Over kanseri, Vulvar kanseri ve rahim kanseri, yaklaşık olarak pelvik bölgede oluşan üç kanser türüdür. İlk olarak, rahim ağzından önce vajinada, ikincisi kadınlarda yumurtalıklarda ve üçüncüsü ise rahim tabakalarında oluşur ve tümü kadınlarda yaygın olarak görülür. Prostat kanseri, erkeklerde ve bazı trans kadınlarda prostat bezinin hücrelerinin anormal bölünmesi sonucunda oluşur (Cancer Research UK, 2022). Cilt kanseri, uzun süre ultraviyole ışınlarla maruz kalmadan kaynaklanan anormal cilt hücrelerinin oluştuğu koyu lekeler nedeniyle oluşur (American Academy of Dermatology Association, n.d.).

Tiroid kanseri, tiroid bezindeki hücrelerde teşhis edilir ve bu tür kanserin 5 çeşidi vardır (Patient Engagement Synapse, n.d.). Beyin kanseri, tüm vücut fonksiyonlarını etkileyen bir tür tümör olup, merkezi sinir sisteminde yani beyinde veya omurilikte teşhis edilir ve etkilenen ve değiştirilen hücreler bu bölgede büyüyerek malign veya benign olabilen bir kitle oluşturur. Bu tür tümörlerin tehlikeli olması veya olmaması, kanser hücrelerinin moleküler ve genetik yapısına bağlıdır (American Brain Tumor Association, 2022). Tümörün tehlike seviyesine göre, malign veya benign tür olarak da tespit edilir. Malign tümör tüm vücuda yayılma ve metastaz yapabilme özelliğine sahiptir ve hastalar için en zararlı olanıdır. Karsinom, sarkom ve blastoma gibi birçok türü vardır. Hızlı bir tedavi gerektirir ve yaşam için büyük bir tehdit oluşturur. Benign tümör ise diğer bölgelere yayılmaz ve acil bir tedavi gerektirmez, ayrıca malign olan kadar zararlı değildir. Ancak çevreleyen alanlara baskı yaparak ağrıya neden olabilir (Whelan, 2022).

III. LİTERATÜR TARAMASI

Bu bölümde, derin öğrenme algoritmaları kullanarak beyin hastalığı tespitiyle ilgili araştırmaların bir incelemesini sunuyoruz. Son zamanlarda, CNN'ye dayalı otomatik beyin tümörü segmentasyon yaklaşımlarının sayısı artmıştır. Bu bölüm, CNN ve önceden eğitilmiş modellerin bazı algoritmaları ve yöntemlerine bir giriş sunarak, çeşitli bozuklukların tanısında derin öğrenme ve makine öğrenmesinin uygulanması ile ilgili diğer MRG görüntü sınıflandırma tekniklerinin tartışmalarını içermektedir.

A. Giriş

Bu çalışmada, programlama yapmadan bilgisayarların çalışmasını hızlandıran ve kolaylaştıran yapay zekanın bir parçası olan makine öğrenimini araştırıyoruz. Bu, farklı alanlarda çoğu işi yerine getirmek için en yaygın kullanılan yöntemdir ve Deloitte tarafından yapılan araştırmalar, şirketlerin çoğunun (%67) bu makine öğrenimi fenomenini kullandığını ve (%97) önümüzdeki yıllarda bunlara bağımlı olacağını göstermektedir (Brown, 2021). Bu makine öğrenimi araştırması, araştırmacıların manyetik rezonans görüntüsü (MRG) ile beyin tümörünü doğru bir şekilde tespit etmek için en iyi ve en verimli segmentasyon ve sınıflandırma süreçlerini belirlemeye çalıştığı alandır. Ayrıca bu çalışmanın bu bölümünde, kanser, tipleri, teşhis süreçleri, MTI görüntüleri, makine öğrenimi, MRG görüntüsü segmentasyonu ve sınıflandırma süreçlerine yardımcı olan algoritmik formüller ve pratikler gibi araştırma konusu konuları hakkında önceki çalışmalar açıklandı.

B. Literatür Tarama Araştırması

Şu anda teknolojinin çağında, hayatın çoğu alanı yapay zeka tekniklerinin

geliştirilmiş olanlarını kullanmaktadır, örneğin makine öğrenmesi. Bunlardan biri, kanser gibi birçok hastalığın tanısı için medikal alan ve radyoloji ve görüntüleme bölümleridir.

1. Beyin Tümörü (BT), Malign ve İyi Huylu

Malign beyin tümörü, bahsedildiği gibi tüm vücut parçalarını ve fonksiyonlarını etkileyen çok tehlikeli bir kanser türüdür ve diğer organlara hızla yayılırken, iyi huylu beyin tümörü çevreleyen merkezi sinir sistemi parçalarında basınç oluşturur, ancak zararlı değildir ve diğer vücut organlarına yayılmaz.

a. Beyin Tümörünün Aşamaları

Beyin tümörü, tüm tiplerinde gelişme ve büyüme için birçok aşamaya sahiptir; değiştirilmiş anormal hücrelerin oluşumunun başlangıcından itibaren 4 ila 5 aşamaya sahiptir. Bu dereceler, uzmanlar tarafından bu alanda hücreleri mikroskop altında gözlemledikten sonra sınıflandırılır. Bu derecelerden ilki, tümörün zararsız olduğu ve hastaya hiçbir zarar vermediği kabul edilir. İkinci derece, yavaş büyüyen malign olarak kabul edilir. Beyin tümörünün üçüncü derecesi, anaplastik bir tümördür ve hücreleri anormaldir ve yüksek bir hızda büyürler. Son derece en anormal hücre durumu ve önceki derecelerden daha hızlı gelişir (Pasadena CyberKnife Center, n.d.).

b. Beyin Tümörü; Nedenleri ve Belirtileri

Beyin tümörleri, hücre bölünmesi ve apoptozis için sorumlu olan genlerde özellikle DNA yapısında değişiklikler gibi birçok farklı nedenden dolayı ortaya çıkabilir. Ayrıca, yüksek seviyelerde radyasyona maruz kalma, çevresel faktörler, aile öyküsü vb. nedenler de olabilir (Cleveland Clinic, s.y.). Beyin tümörlerinin belirtileri baş ağrısı, bulantı, kusma, görme ve işitme bozuklukları, nöbetler, denge zorlukları, ağrı hissi, karar verme zorlukları ve bilişsel, davranışsal ve nöromusküler sorunlar olabilir (Musella Foundation, s.y.).

c. Beyin Tümörü Tanı Yöntemleri ve Görüntüleri

Bu yılın yakın zamanında, yaklaşık 25050 hasta Merkezi Sinir Sistemi kanseri ile enfekte olmuştur. BT ve spinal tümörün keşfi, kliniklerde veya hastanelerde uzman doktorlar tarafından yapılan nörolojik muayeneden, tüm hayati işaretler ve duyu fonksiyonlarından yataktaki muayeneden oluşan birçok tanı yöntemleri ile

gerçekleşir. Ayrıca, enfekte tümörden kanserli hücreleri içeren bir doku almak için, beyindeki hassas bölgelere ulaşabilen bir iğne kullanılarak biyopsi yapılır ve daha sonra bu örneğe kültür yapılır, böylece kanser hücreleri ve bu hücrelerin iyi huylu veya kötü huylu olup olmadığı keşfedilir (Markman, 2022).

Nükleer tıp kemik taraması, beyin tümörünün kemik dokusuna metastaz yapıp yapmadığını göstermek için yapılmıştır. Kan dolaşımına belirli bir radyoaktif madde enjekte edilir ve kemikte toplanarak görüntü olarak floresan olarak ortaya çıkar. İleri genetik test, tümörün beslendiği kan damarlarını gözlemlemek için X-ışınları kullanan anjiyografi yöntemidir. Bu yöntem, beyin tümörlerinin tespitinde belirsiz ve kesin olmayan bir yöntemdir (Markman, 2022).

Bilgisayarlı Tomografi taraması (BT taraması), hastanın obez olması ve MRG makinesine girmekte zorluk yaşaması veya hastanın klostrifobik olması gibi durumlarda MRG taramasının kullanılmasına engel olduğu durumlarda kullanılır. Pozitron Emisyon Tomografisi (PET), hızlı büyüyen tümörlerde son aşamalarda kullanılır ve tümörün hala var olup olmadığını veya yok olup olmadığını belirlemek için kullanılır (Markman, 2022). Son teknik ise manyetik rezonans görüntülemesidir (MRG), bu yöntem tümör dokusunun yerini, yayılımını, hacmini ve sınırlarını, özellikle yumuşak dokuda tespit etmek için önceki tekniklere göre daha fazla ayrıntı ve daha kesin sonuçlar sağlar (Markman, 2022).

2. Manyetik Rezonans Görüntüleme (MRG); Tanım ve Tarihçe

a. Tanımı

Manyetik Rezonans Görüntüleme (MRG), vücuttaki herhangi bir organın varlığını ve bozukluğunu, beyin tümörleri de dahil olmak üzere vücudun çeşitli bölgelerindeki tümörleri teşhis etmekle ilgili olan bir görüntüleme yöntemidir. Hassas ve doğru bir şekilde teşhis edilen bölgelerin üç yönlü anatomik görüntüsünü oluşturur. Bu görüntü teknolojisi, dikkat edilen canlı doku su bölümündeki proton hareketinin eksenlerinin değişimini belirler ve organın etli kısmını belirler, CT taraması ve X-ışını görüntüsü gibi diğer görüntülerden daha net ve doğru ayrıntılar verir. MRG, beyin tümörlerini ve anevrizmaları bulmak için kullanılır. En yaygın kullanılan BT teşhisi yöntemi MRG'dir çünkü hassasiyeti yüksektir (NIBIB, n.d.). Çok güçlü manyetik enerji alanı, radyo dalgaları ve bir bilgisayara bağlanarak tüm vücudu, özellikle beyin tümörleri gibi yumuşak dokuları hassas bir şekilde

değerlendirerek sonuç veren bir görüntüleme yöntemidir. Ayrıca bağırsak bölgesindeki iltihaplanma, hamile kadınların fetüs durumunu değerlendirme ve safra kanalı gibi belirli organların anormallikleri gibi diğer sağlık sorunlarının değerlendirilmesinde de kullanılır (Radiological Society of North America and ACR, 2022).

MRG tarama, teşhis için gereken bölgenin yüksek manyetik enerjiye maruz bırakılması yoluyla çalışır ve vücudun protonlarının uygulanan manyetik alanla hizalanmasını zorunlu kılar. Radyo frekansı kapatıldıktan sonra, ikinci uygulamadan sonra protonlardan gelen manyetik enerjinin yansması, moleküllerin türüne ve bileşimine bağlı olarak yüksek enerji sağlar. Daha sonra doktor, salınan enerji miktarına bağlı olarak tümörün türünü ayırt edebilir. MRG kabini içindeki hasta, görüntü sonuçlarında herhangi bir bulanıklık olmaması için hareket etmemelidir (NIBIB, n.d.).

b. Tarih

MRG tarama, tıbbi görüntüleme alanında bir devrimdi ve bilim insanlarının, vücuttaki elektronların çalışması yoluyla manyetik rezonansı geliştirme çabaları 1930'lara kadar gitmektedir. 1937'de Kolombiyalı bir fizikçi olan Isidor Rabi, insanlık için nükleer manyetik rezonansı belirlemek amacıyla atomun çekirdeğini belirledi ve bu keşif için 1944 Nobel Ödülü'nü aldı (Radlib, 2021). Daha sonra Edward Purcell ve Felix Bloch, moleküllerde ve atomlarda manyetik rezonansı bağımsız bir şekilde inceledi ve 1946'da, belirli bir süre sonra, bu fenomen bir görüntüleme tekniğine dönüştürüldü (Tretkoff, 2006).

Ancak tam olarak 1969'da, Dr. Raymond Damadian manyetik rezonansın bu farkı tespit etme yeteneğini beklemiş ve bu keşif sonrasında Downstate Medical Center State University of New York Brooklyn'deki diğer bilim insanları ve hekimlerle birlikte MRG görüntüsünün fikrini ortaya atmıştır. Damadian, 1974'te hazır kullanıma uygun bir MRG makinesi inşa etti. 3 Temmuz 1977'de ilk MRG görüntüsü ilk hastaya yapıldı. Sonuç olarak, yıldan yıla bu görüntü her taraftan daha iyi sonuçlar vermek üzere geliştirilmiştir (Garet, 2020). 1980'lerde, bu MRG görüntüsü hastanelerde ve tıbbi merkezlerde bulunarak vücudun organlarını ve özellikle beyin gibi yumuşak dokuları görüntülemek için kullanılmıştır (Tretkoff, 2006). Günümüzde MRG taraması en güvenli görüntü türüdür ve BT gibi diğer vücut bölgelerindeki sorunları teşhis etmek için de kullanılan en yaygın görüntüdür.

Sonuçları açısından diğer görüntü türlerine göre daha net ve etkilidir ve bu tanısal teknik manyetik alan, makinenin şekli ve hacmi, bağlantılı tarayıcılar ve algoritmalar ve tümörleri daha doğru bir seviyede belirlemek için kullandığı sınıflandırma süreçleri gibi tüm yönlerden sürekli olarak geliştirilmektedir. Ek olarak, bu görüntü hakkındaki ayrıntılar da yeni tarayıcıların kullanımını içerecek şekilde geliştirilmiştir ve manyetik alanların gözeneklerini 75 cm'den 30-35 cm'ye kadar azaltma gibi değişiklikler yapılmıştır (Sobol, 2012).

3. Beyin Tümörü MRG Sınıflandırması

BT, son zamanlarda en yaygın tümörlerden biridir ve nedenlerini, semptomlarını, etkilerini ve teşhis tekniklerini belirlemek için tüm çabalar bu yönde toplanmaktadır. MRG, BT teşhisi için en kullanışlı ve verimli tekniktir. Bu tür tümörlerle ilgili tüm yönleri açıklar. MRG görüntüsünün sınıflandırılması, beyin gelişiminin farklı aşamalarında alınan ve uygulanan birçok stratejiye bağlıdır. MRG sınıflandırma sistemi (MRICS), malformasyonlar, baskın beyaz madde hasarı, baskın gri madde hasarı, çeşitli diğer bulgular ve normal bulgular olmak üzere 5 sınıflama grubuna ayrılmaktadır (Himmelman vd., 2016: 57-64).

Malformasyonlar grubu, bebeğin beyin veya merkezi sinir sistemi oluşumu sırasında prenatal olarak meydana gelen nörolojik bozukluktur. Bu, ailede kalıtsal faktörlere bağlı genetik bir anormallik veya kazanılmış bir anormalliğe bağlı olabilir (İbrahim & Hachem, 2020). Baskın beyaz madde hasarı grubu, gestasyon dönemindeki 23 ile 32 hafta arasındaki fetüslerde genellikle ultrasondan daha çok MRG ile tespit edilen bir problemdir. Bu, beyindeki kranyal alandaki beyaz maddenin hakimiyeti sonucu oluşur ve bu alanda açık bir şekilde çoklu lezyonlar ve kistler içerir. Bu MRG sınıflandırma grubu, teşhis edilen alanı kesin olarak belirler ve daha sonra tedavi edilmesi için lezyonları açıklığa kavuşturur (Martinez-Biarge vd., 2016).

Baskın gri madde hasarı grubu, beyindeki gri maddenin beyaz maddeden daha fazla baskın olduğu ve manyetik rezonans görüntüleme (MRG) ile belirlenen lezyonların olduğu gruptur. Bu sınıflandırmada, beyindeki problem veya anormallik gri maddededir ve daha sonraki birçok ilişkili etkiye yol açar (Reid vd., 2015: 1159-1167). MRG sınıflandırmasının diğer bir grubu, kemik iliği ve kas-iskelet sistem gibi belirli alanlarda meydana gelen bozukluklara odaklanır (Hegazi & Wu, 2019).

Normal Bulgular, MRG beyin görüntüsünün herhangi bir kusur veya tümör olmadan normal olduğu beşinci sınıflandırmadır.

Beyin tümörü teşhisi, tümörlerin detaylarını ve iyi huylu veya kötü huylu olup olmadığını belirlemek için önemli bir rol oynayan bilgisayara dayanır. Ayrıca, bilgisayarlı MRG görüntüsünün bu dijital teşhisi, beyin tümörlerinin uygun tedavisini bulmakta doktorlara ve teknisyenlere yardımcı olur, çünkü hastalığın son aşamalarında dışında neredeyse tespit edilemez. Son zamanlarda, derin öğrenme (DO) tabanlı nötr mimari tekniği, pikseli voksele ayırmak için kullanıldı. gerekli girdiyi tespit ederek gerekli bilgiyi alarak tümörün konumu ve mekansal bilgileri için daha az karmaşıklıkla ve daha fazla hassasiyetle sonuçlar elde edildi. Bu tekniğin deneylerinin sonuçları, doğruluk, özgüllük ve duyarlılık gibi birçok değerlendirme metriği kullanılarak kabul edilir ve geçerli hale gelir (Veeramuthu vd., 2022).

Dolayısıyla, beyin tümörü dünyadaki en tehlikeli hastalıklardan biridir ve 2021 yılında 84.000 kişide BT görülmesi ve aynı yıl içinde bunlardan yaklaşık 18.600 kişinin ölmesi bekleniyordu (Kadam, Bhuvaji, & Deshpande, 2021). Bu tümörler, konumlarına göre glioma tümörü, menenjiyoma tümörü, hipofiz tümörü ve tümör yok (iyi huylu) olarak MRG ile tespit edilir. Glioma, 45-70 yaşları arasındaki insanlarda meydana gelen ve yaşa bağlı olarak herhangi bir kişide etkileyebilen glioblastoma olarak da adlandırılır. Büyümesini azaltmaya veya önlemeye yönelik olarak küçültme yöntemi dışında tedavisi yoktur (Glioblastoma Research Organization, n.d.). Bu beyin tümörü türü, beyin pedikülü ve omurilik gibi sinir sisteminin farklı bölgelerinde meydana gelir. Baş ağrısı, genel hastalık, kusma ve bir tür tahriş gibi birçok semptomu vardır (Vankdothu, Abdul Hameed, & Fatima, 2022).

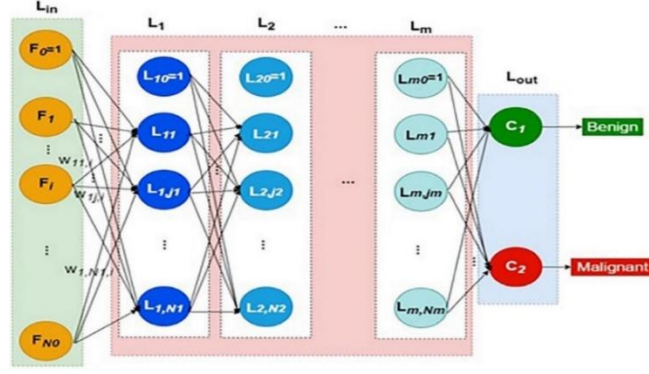
Meningiyoma tümörü, beyni ve omuriliği saran tabakalarda meydana gelen en yaygın BT türüdür (Vankdothu, Abdul Hameed, & Fatima, 2022). Konumuna göre çeşitli türleri vardır; konveksite menenjiyoma, falx ve parasagittal menenjiyoma, kokusunu alan oluk menenjiyoma, sfenoid kanadı menenjiyoma, petroz ve petrokival menenjiyoma, posterior fossa menenjiyoma, intra-ventriküler menenjiyoma, intra-orbital menenjiyoma, spinal menenjiyoma. Bu tümörün, konuşma zorlukları, işitme kaybı ve görsel sorunlar gibi duyuyla ilgili semptomlarının yanı sıra uyuşma, hafıza ve kaslarda zayıflık gibi birçok semptomu vardır (Brigham and Women's Hospital, n.d.).

Üçüncü tip hipofiz tümörüdür ve hipofiz bezindeki değişiklikler ya da anormal

gelişimlerden kaynaklanır ve bu tür tümörler genellikle iyi huyludur (Vankdothu, Abdul Hameed, & Fatima, 2022). Adından da anlaşılacağı gibi, burun yakınlığında bulunan beynin çok küçük bir organında meydana gelir. Bu tümörün fonksiyonel ve nonfonksiyonel olmak üzere iki türü vardır ve vücutta birçok soruna neden olan hipofiz hormonlarının daha fazla salgılanmasına sebep olabilir (Endocrine Society, 2022). Son tür ise kanser olmayan BT'dir ya da iyi huylu olan ve metastaz yapmayan ancak çevresindeki bölgelere baskı yapabilir ve bazen hastanın hayatı için tehdit oluşturabilir.

Ayrıca, bu tür tümörlerin tespiti tedavileri için anahtardır. Bu nedenle, BT MRG bu görev için en iyi görüntüleme tekniğidir. Bu teknik, farklı sinir ağlarına bağlı olarak derin öğrenme (DL) modellerine dayanır ve konvolüsyonel sinir ağı (CNN), yapay sinir ağı (ANN) ve transfer öğrenme (TL) gibi farklı sinir ağı tekniklerini kullanarak, beyin tümörlerini kanserli, iyi huylu, kötü huylu veya hipofiz olarak sınıflandırır ve segmente eder (Kadam, Bhuvaji, & Deshpande, 2021).

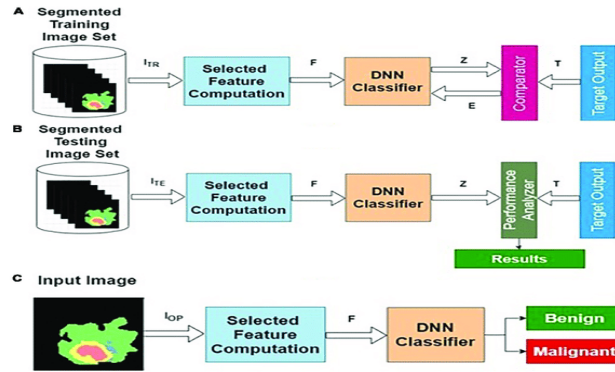
Convolutional Neural Network (CNN), birçok katmandan oluşan bir yapıya sahiptir ve bu katmanlardan biri olan konvolüsyon katmanı, resim oluşturulmadan önce çok sayıda filtreye sahiptir. Bu, resim için ilgili detayları ve özellikleri seçerken gereksiz özelliklerden kaçınacaktır (Kadam, Bhuvaji, & Deshpande, 2021). Ayrıca, önceden eğitilmiş CNN, MRG BT sınıflandırması için en doğru teşhis sınıflandırıcısı olarak kabul edilir (Filatov & Ahmad Hassan Yar, 2022). Yapay Sinir Ağları da çok sayıda katmandan oluşur ve bunlar girdi katmanı, çoklu gizli katmanlar ve çıktı katmanından oluşur. Bu katmanlar birbirine bağlıdır ve her katman düğümlerden oluşur. Tüm katmanların düğümlerinin ağırlığı sonunda her düğümün çıktısını almak için kullanılır. Ancak, hesaplama sonuçlarındaki hata, alttan üste doğru her bir düğüme bir kayıp işlevi uygulanarak gerçekleştirilir (Kadam, Bhuvaji, & Deshpande, 2021). Transfer öğrenimi (TL), bir görevdeki çalışmanın, ikinci görevdeki çalışmanın temelini oluşturduğu bir tür nötr ağıdır (Kadam, Bhuvaji, & Deshpande, 2021).



Şekil 5 Derin Sinir Ağı Yapısı

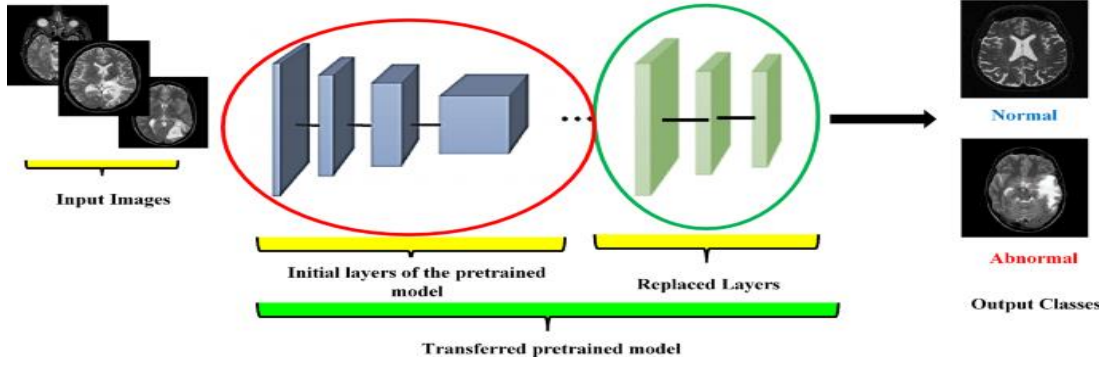
Kaynak: Veeramuthu vd., 2022.

Bu nedenle, teşhis teknikleri benign ve malign beyin tümörü arasındaki farkı tam olarak belirlemek ve tümörün aşamasına bağlı olarak tedavi yöntemini belirlemek için teknik olarak gerçekleştirilen yedi sınıflandırmaya sahiptir ve sonuçları DCNN sistemi üzerinde bağımlıdır (Veeramuthu vd., 2022). Tüm bu sınıflandırıcılar derin konvolüsyonel sinir ağları (DCNN) sistemi kullanılarak gerçekleştirilir. İlk sınıflandırıcı birleştirilmiş özellik ve görüntü temelli sınıflandırıcı (CFIC) olup, mimari ve düzenleme tekniklerine dayanmaktadır (Tzelepi vd., 2022: 131-164). MRG sınıflandırıcılarının bir kategorisi olarak kabul edilir ve burada görüntü detaylarını doğrudan ham görüntülerden almaya çalışır ve bu detaylar ve özellikler eğitim veri tabanı boyutuna dayanır (Kaur & Gandhi, 2020).



Şekil 6 Bölümlenmiş Resim Özellik Tabanlı Sınıflandırıcı (SIFC): (A) Eğitim, (B) Test ve (C) Operasyonel Aşamalar

Kaynak: Veeramuthu vd., 2022.

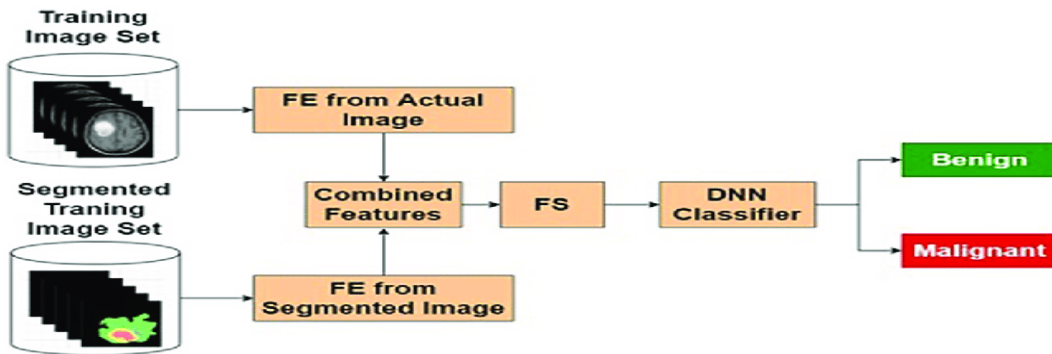


Şekil 7 "Görüntü Özellikleri Temelli Sınıflandırıcı (AIFC)"'yi Göstermektedir.

Kaynak: Veeramuthu vd., 2022.

İkinci sınıflandırma türü, gerçek görüntü özelliklerine dayalı sınıflandırıcı (AIFC) dir. Bu sınıflandırıcı, orijinal görüntünün tüm özelliklerini, ilgili ve ilgisiz olanları ayırt eder. Gerçek bir görüntü olarak sınırlı çözünürlüğü vardır ve arka plandaki görüntü özelliklerinin bulanıklığını azaltmak için bölümlenmiş görüntü ile birleştirilir. Bu birleşme daha iyi sonuçlar verir (Veeramuthu vd., 2022).

Üçüncü sınıflandırıcı, segmente edilmiş görüntü özellikleri temelli sınıflandırıcıdır (SIFC). Bu, MR beyin tümörü sınıflandırıcısıdır ve beyin tümörlerinin segmentasyonunu ve sınıflandırmasını tespit etmek için derin sinir ağı (DNN) tabanlı algoritmalar kullanır. Bu sınıflandırıcı, girdi tümörünün iyi huylu veya kötü huylu olması fark etmeksizin daha iyi sonuçlar verir. Sonuçların analizi, doğrulama, test ve eğitimi gibi çıktı işlemleri, şekil 8'de gösterilen derin sinir ağı algoritmik teknikleriyle gerçekleştirilir. (Veeramuthu vd., 2022).




Şekil 8 Gerçek ve Segmente Edilmiş Görüntü Özellikleri Temelli Sınıflandırıcı

Kaynak: Veeramuthu vd., 2022.

Dördüncü sınıflandırıcı, beyin tümörü için MRG görüntüsünün ikinci ve üçüncü türlerinin birleşimidir ve gerçek ve bölümlenmiş görüntü özelliklerini temel

alır (ASIFC). İlgili ve ilgisiz ayrıntıları içeren asıl görüntüyü girdi olarak alır. Ardından, bölümlendirme işlemi, arka plan bulanıklığını gidermeye yardımcı olur (Veeramuthu vd., 2022).

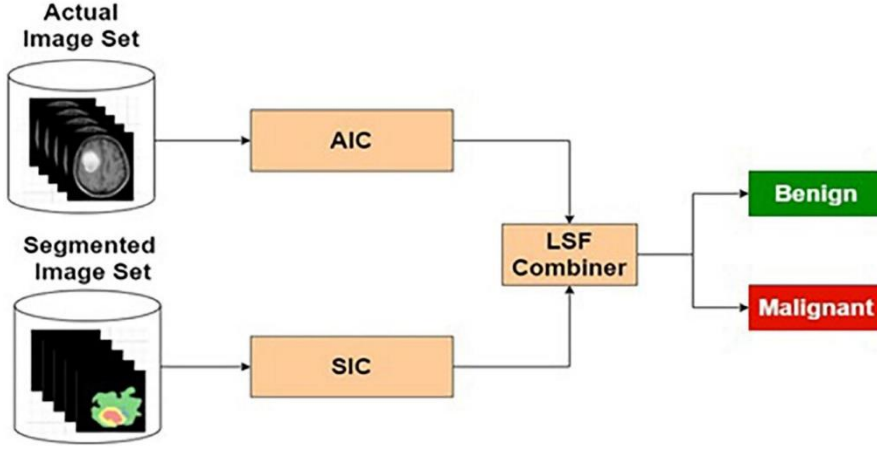
Beşinci sınıflandırıcı gerçek görüntü tabanlı sınıflandırıcı (AIC) olup, beyin tümörlerinin MRG görüntülerinin orijinal ve gerçek resimlerini kullanır ve amaçlanan verileri iyi huylu veya kötü huyludur. Altıncı sınıflandırıcı, bölümlenmiş görüntü tabanlı sınıflandırıcıdır (SIC) ve beyin alanları için MRG görüntülerinin bölümlenmiş görüntülerini kullanır ve derin konvolüsyonel sinir ağı (DCNN) için girdi verileri olarak kabul edilir. Amaçlanan veriler iyi huylu veya kötü huyludur (Veeramuthu vd., 2022).



Şekil 9 Gerçek Görüntüye Dayalı Sınıflandırıcı ve Bölümlenmiş Görüntüye Dayalı Sınıflandırıcı

Kaynak: Veeramuthu vd., 2022.

MRG için BT'nin yedinci ve son sınıflandırıcısı, gerçek ve bölümlenmiş görüntü temelli sınıflandırıcıdır (ASIC). Gerçek ve bölümlenmiş görüntü sınıflandırıcılarının her ikisi de girdi olarak kabul edilerek, yük paylaşımı tesisleri birleştiricisi (LSF birleştiricisi) tarafından işlenir ve çıktı iyi huylu veya kötü huylu olur (Veeramuthu vd., 2022). Bu birleştirici, yalnız başına etkileşemeyen birçok programı alabilir ve büyük kapasiteye, belleğe veya büyük bilgisayar işlem birimlerine ihtiyaç duyar. Bu nedenle yama olarak aktarılır veya işlenir ve çıktı iyi huylu veya kötü huyludur (IBM, 2018).



Şekil 10 Gerçek ve Bölümlenmiş Görüntü Tabanlı Sınıflandırıcı

Kaynak: Veeramuthu vd., 2022.

MRG beyin tümörlerine yönelik tüm bu sınıflandırıcıların açıklanmasından sonra, birleşik özellik ve görüntü tabanlı sınıflandırıcının (CFIC) hassasiyet, özgüllük ve doğruluk gibi tüm yönleriyle en iyi sonuçları gösterdiği görülmüştür. Bu sınıflandırma, daha az parametre ve nokta işlemlerine dayanmaktadır. MRG BT sınıflandırılması, doktorlara tedavi yöntemini belirlemede başka bir görüş sunmaları için olanak tanımaktadır (Veeramuthu vd., 2022).

4. MRG BT Sınıflandırması ve Segmentasyonu Arasındaki Fark

Beyin tümörü sınıflandırması olasılıksal sinir ağı (PNN) tarafından gerçekleştirilirken, segmentasyon K-ortalama kümeleme algoritmasıyla gerçekleştirilebilir ve beyin tümörlerinin yayılma alanlarını belirler (Lavanyadevi vd., 2017). Ayrıca, BT MRG'nin segmentasyonu, beyin anatomisinin ölçülerini tespit ederek tanı sürecinde çok gerekli bir adımdır. Bu teknik ayrıca, istenen bölgeyi görselleştirir ve beynin çalışmasına dair gerekli analizi yapar ve görüntü yönlendirilmiş müdahalelerle bu bölgedeki herhangi bir cerrahi öncesinde planlama yapar (Despotović, Goossens, & Philips, 2015). Segmentasyon süreci genel olarak bölge tabanlı segmentasyon, kenar tabanlı teknik ve sonucusu eşikleme tekniği olmak üzere birçok teknik içerir ve bu segmentasyon tümörü bölgelere ayırır. Tüm bu teknikler kanserli hücrelerin non-kanserli olanlardan ayrımını belirlemek ve yapmak içindir (Arif et al., 2022). Sınıflandırma genel bir tanım olarak aynı doğrultuda olsa da, uygulamada birçok farklılığı vardır. Önceden tanımlanmış desenlere sahip olan görüntülerin gruplandırma sürecidir, örneğin CNN algoritması (Arif et al., 2022). Ayrıca, görüntüyü parçalara ayırmayı deneyerek süreci ve

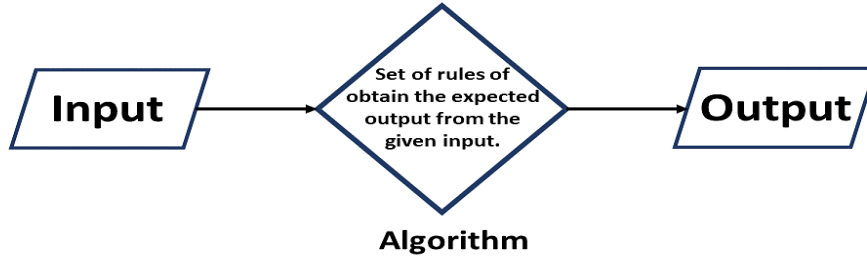
görselleştirmeyi daha kolay, daha net ve daha basit hale getirirken; sınıflandırma, sayısal bilgiyi hariç tutma ve sınıflar veya kategoriler halinde düzenleme işlemidir. Veritabanı algoritmasının sınıflandırması, görüntülerin özelliklerine göre özelliklerini kategorize etmeye çalışır ve bunun temelinde sınıflandırma tekniği, sonuçları net bir şekilde vermek için tespit edilir (Brown, 2019).

5. BT MRG Sınıflandırmasında Kullanılan Algoritmalar

a. MRG Sınıflandırmasında Kullanılan Algoritmaların Kısaca Tanıtımı

BT MRG sınıflandırması, belirli bir ölçü ve hesaplama kullanarak görüntülerdeki sonuçları ve hataları matematiksel algoritmalar kullanarak hesaplayan bilgisayarlaştırılmış bir süreçtir. Bu, hesaplama işlemleri, veri işleme ve problem çözme konularında kullanılan bir bilim dalıdır ve belirli bir dizi talimat ve kuralları takip ederek her adımın etkili ve verimli olması gerekmektedir ki sonuçlar oluşturulabilsin (Gillis, 2022). Ayrıca, belirli bir problemi çözmek ve girdi verileri için hesaplama yapmak ve gerekli çıktıyı vermek için birçok mekanizmanın uygulanmasıdır. Basit veya karmaşık bir prosedür olabilir ve bu, sonunda elde etmek istediğiniz işe bağlıdır. Algoritma, bilgi için programlama sürecidir ve net sonuçlar vermek için ihtiyacımız olanı verir (Geeks for Geeks, 2022). Ek olarak, bilgisayarların işlerini yapmak için verilen birçok komutu takip ederek belirlenmiş bir önceden belirlenmiş ve net adımlar sırasını takip eder ve belirsizlikten uzaklaşır. Algoritma bilimi, belirli bir programlama dili kullanmaz, her adımın doğruluğuna ve netliğine bağlıdır (Upadhyay, 2022).

Ayrıca, bu bilim birçok özelliğe sahiptir. Bu özelliklerden biri, bu bilimin önceden belirlenmiş girdi ve çıktıya sahip olması gerektiğidir. Bir başka karakteristik, pratik bir süreçtir. Yani kolayca kullanılabilir olmalı, ayrıca net ve kesin bir sonuç vermelidir. Etkili ve yüksek bir incelik seviyesine sahip olmalıdır ve son olarak dili bağımsızdır ve girdi ve çıktıya saygı duyarak herhangi bir dilde sunulabilir (Geeks for Geeks, 2022).



Şekil 11 Algoritmanın Girdi ve Çıktılarına

Kaynak: Geeks for Geeks, 2022.

b. Uygulamalar


Algoritmalar; telefon, laptop, hesap makinesi, bilgisayar, internet ve MRG gibi tıbbi merkezlerdeki diğer cihazlar gibi medikal görüntüler gibi her gün hayatta kullanılmaktadır. Algoritmalar, bilgi teknolojisi (BT) ile ilgili her şeyde ve matematik ve bilgisayar bilimleri gibi diğer alanlarda da kullanılmaktadır. Ayrıca, özellikle özellik belirleme, sınıflandırma, kategorize etme ve otomatikleştirilmiş sistemlere dayanan çalışmaların başarılmasında anahtar bir rol oynamaktadır. Sosyal medyada içerikleri düzenleme, programlama gerektirmeden makine öğrenimi sürecinde kullanma, kullanılan aletlerde tıbbi alanda ve MRG gibi tıbbi görüntüleme işlemlerinde kullanılmaktadır (Gillis, 2022). Ayrıca şifreler, çeviri dilleri, günlük kullanılan uygulamalar, insanların birbirleriyle bağlantı kurması, finansal hizmetlere ulaşması, kredi kartlarının kullanımı, ağ bağlantıları, derin öğrenme ve her şeyle ilgilidir (Kumari, 2020).

c. BT MRG'de Kullanılan Sınıflandırma Algoritmalarının Türleri

Bu bilimsel alan, insanların hayatına başlangıcından bu yana tüm alanlarda büyük etkiler yaratmıştır. Algoritma sistemleri, özellikle görüntüleme işlemlerinin yoğun olarak kullanıldığı tıp alanında, özellikle de beyin tümörü tanı işlemlerinde kullanılmaktadır, örneğin MRG. Algoritma, doktorlara ve radyoloji teknisyenlerine hastalık yerini, aşamasını belirlemede ve tedaviyi daha kolay ve zaman harcamadan bulmada yardımcı olmuştur. Bu sistem teknolojisi, BT MRG görüntüleme gibi tıbbi tanı prosedürlerinde kullanılan yapay zeka (AI), derin öğrenme ve sinir ağları ile ilgili makine öğrenimi alanında kullanılmaktadır. Bu gelişmiş makine öğrenimi teknolojisi, BT'yi sınıflandırma, segmentasyon ve tespit etme yöntemlerinin daha basit hale gelmesine yol açmıştır (Khan vd., 2020).

Her bir BT MRG sınıflandırıcısı, eğitim algoritması, test algoritması ve işlem algoritması olmak üzere üç algoritmik işleme sahiptir ve her birinin kendi adımları vardır. Makine öğrenme algoritmasını kullanan sınıflandırıcılardan biri, BT'yi kanserli veya kanser olmayan tümör olarak sınıflandırmak için transfer öğrenimi (TL) olarak adlandırılan başka bir derin öğrenme süreci ile birlikte konvolüsyonel sinir ağı (CNN) kullanmaktır (Khan vd., 2020). Balaji, Sen ve Kirty (2022) çalışmalarına göre, 5 katmandan oluşan CNN yaklaşımının doğruluk yüzdesinin %88,25 olduğu gösterilmiştir ve bu yüzde transfer öğrenimi (TL) kullanarak artırılabilir özelliğine sahiptir. Ayrıca, Balaji, Sen ve Kirty (2022) BT MRG sınıflandırmasında CNN yaklaşımının doğruluğu hakkında veri vererek, algoritmik hesaplamalar kullanarak doğruluğunun yaklaşık %97,5 olduğunu göstermiştir.

Bu işlemde izlenen algoritmik adımlar öncelikle önceden belirlenmiş boyutları, sayıları ve yapıları olan bir dizi görüntüyü uygulamaktır. Daha sonra CNN filtreleri belirli bir sayıda uygulanır. Ardından, eğer sayıları düşükse, görüntülerin karmaşıklığını artırmak için veri artırma işlemi yapılır. Daha sonra, BT hacmi, kenarları, köşeleri ve çizgileri hakkında daha fazla veri elde etmek için konvolüsyonel katmanlara daha fazla katman eklenir. Son olarak, filtre kullanarak girdi görüntüsünde kanser olup olmadığını gösterilir (Khan vd., 2020).




Şekil 12 Evrişimli Sinir Ağlarının Mimarisi

Kaynak: Kang et al., 2021.

Bu teknik aşağıdaki algoritmik işlevleri kullanarak uygulanmıştır: İlk olarak, her evrişim katmanında ReLU aktivasyon işlevi kullanılmıştır. ReLU matematiksel olarak $F(z) = \max(0, z)$ şeklinde verilir. Burada z girdi değeridir ve z negatif veya 0 ise girdi değeri 0 olarak kabul edilir. Eğer girdi değeri 0'dan büyükse, çıkış değeri 1 olur. Sonuç olarak, girdi değeri 0 olduğunda bu işlevde bir ölü nöron olarak kabul edilir ve başka bir aktivasyon gerçekleşmez. İkinci olarak, iki değer arasındaki hata oranını hesaplamak için kullanılan makine öğrenimi Loss işlevi kullanılmıştır. BT

MRG için ikili sınıflandırma uygulandığından, hata oranını hesaplamak için ikili çapraz entropi kullanılmıştır. Burada y gerçek değerdir ve $p(y)$ tahmini değerdir (Khan vd., 2020). Matematiksel olarak formülü $J(z) = y \log P(y) + (1 - y) \log (1 - P(y))$ şeklindedir.



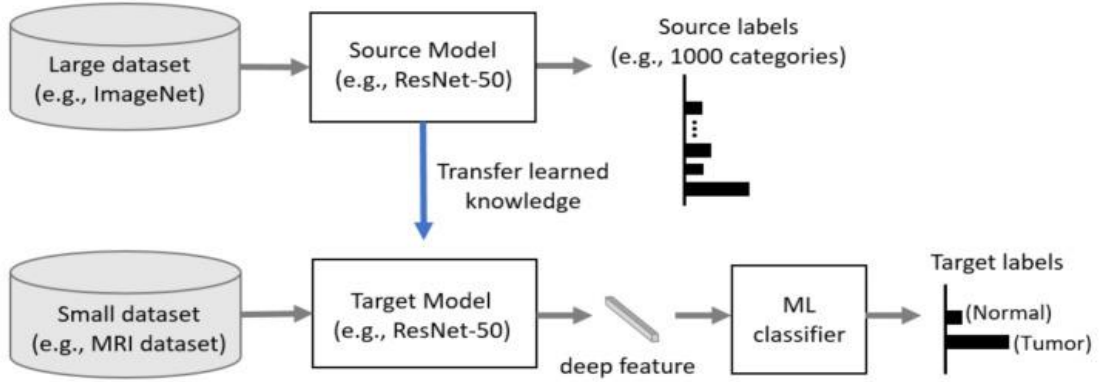
Şekil 13

Başka bir görüntü sınıflandırma işlemi için kullanılan diğer bir tür algoritmik makine öğrenimi, transfer öğrenme modelidir (TL), önceki işlem için (CNN) geliştirilmiştir. BT MRG'nin mükemmel ve daha net sonuçlarını vermek için birçok algoritmik denklem kullanır. TL modeli, bir görevin sonucunun tüm katmanlarını ikinci bir görev olarak kullanmayı, ayrıca önceden eğitilmiş görüntüyü başka bir eğitim için bir başlangıç olarak kullanmayı içerir.

TL modeli kullanımı, derin öğrenme (DL) işlemlerinden biri olarak, örnek olarak, önceki makine öğrenimi gibi evrimsel sinir ağlarından (CNN) bir parçasıdır. Modellerinden biri, önceden eğitilmiş görüntüleri veritabanı girdi görüntüleri olarak kullanan ve daha sonra gruplara veya sınıflara sıralanacakları VGG-16 olarak bilinen 16 katmana sahip bir modeldir (vgg16 VGG-16 convolutional neural network, n.d.). Bu CNN modeli, Oxford Üniversitesi'nde Karen Simonyan ve Andrew Zisserman tarafından ilk kez 2014 yılında kullanılmıştır (Balaji, Sen & Kirty, 2022).

Bu (TL) süreci, önceki veritabanı miktarının düşük olma sorununu çözen geliştirilmiş bir süreçtir. Bu, bu alandaki ikinci görevin başlangıcı olarak önceki veritabanını veya ilgili sorunu kullanarak yapılır, çünkü (DL) net ve anlaşılır sonuçlar üretmek için yüksek düzeyde ve miktarda bilgi ve veri gerektirir. Son zamanlarda, transfer öğrenimi (TL), eski veritabanının depolanması ve aynı alan için bir sonraki başlangıçta sıfırdan başlamak yerine zaman kazandıran en başarılı makine öğrenimi MRG sınıflandırıcısıdır (Kang vd., 2021). Yetersiz veritabanı sorununu aşmak için giriş verilerinin veya görüntülerin çoğaltılması işlemi de

argümantasyonda uygulanmıştır, ancak (TL) algoritmik sistem ile daha iyi bir işlem yapar. Tüm bu adımlar, görüntü hakkında daha fazla özellik elde etmek ve sonuçların daha net olmasını sağlamak için algoritmik olarak yapılır (Alzubaidi vd., 2021). Kadam, Bhuvaji ve Deshpande'ye (2021) göre, bu algoritmik modelin doğruluk seviyesi çok yüksek bir yüzde olan 92,7'dir.



Şekil 14 Transfer Öğrenme Kavramı

Kaynak: Kang et al., 2021.

Transfer learning (TL) alanı şu şekilde algoritmik olarak ifade edilir:

$D = \{X, P(X)\}$, burada X özellik alanını temsil eder ve $X = \{x_1 \dots x_n\} \subset X$ ile bir marjinal olasılık dağılımı olan $P(X)$ ile birlikte yer alır. Daha açıklayıcı olmak gerekirse, X özellikle bir grup hastada belirli bir MRG protokolünden, edinim parametrelerinden ve tarayıcı donanımından elde edilen tüm olası görüntüleri içerebilir (Valverde vd., 2021).

$$\text{Hassasiyet} = \frac{TPp}{TPp + FNp}$$

$$\text{Özgüllük} = \frac{TNp}{TNp + FP}$$

$$\text{Doğruluk düzeyi} = \frac{TPp + TNp}{TPp + FNp + TNp + FPp}$$

gibi algoritmik fonksiyonlarla hesaplanır.

Burada her sembol şu anlama gelir: TPp = kötü huylu olarak önceden tahmin edilen kötü huylu görüntü, TNp = iyi huylu olarak önceden tahmin edilen iyi huylu görüntü, FPp = kötü huylu olarak yanlışlıkla tahmin edilen iyi huylu görüntü ve FNp = iyi huylu olarak yanlışlıkla tahmin edilen kötü huylu görüntü (Veeramuthu vd., 2022). Doğruluk, tüm sınıfların üzerindeki model başarısını göstermek için hesaplanan bir değerdir. Yukarıdaki algoritmik fonksiyon ile hesaplanabilir. Bu fonksiyon, doğru tahminlerin tüm tahminlere oranıdır. Ayrıca, hassasiyet ve geri

çağırma fonksiyonları da bulunmaktadır.

$$\text{Hassasiyet} = \frac{TP}{TP + FP}, \quad \text{Hatırlama} = \frac{TP}{TP + FN}$$

Denklem 2

Precision algoritma fonksiyonu, doğru pozitif görüntülerin doğru pozitif tahmin edilen görüntülerin oranıdır. Geri çağırma değeri ise doğru pozitif görüntülerin doğru pozitif ve yanlış negatif görüntülerin sayısının oranıdır (Balaji, Sen, & Kirty, 2022).

6. Derin Öğrenme Çerçevesi

a. Tanımı

Makine öğrenmesi, yazılımın en iyi ve en kesin sonuçları üretmesine yardımcı olmak için önceden belirlenmiş verileri kullanan algoritmik işlevler kullanarak yapay öğrenmenin bir türüdür. Makine öğrenmesi, programlanmaya ihtiyaç duymadan bu dünyadaki en yaygın teknoloji ve yapay zeka türüdür. Denetimli, denetimsiz öğrenme, yarı denetimli veya güçlendirme öğrenmesi olabilir. İlk öğrenme türünde karmaşık algoritmik modellerde önceden belirlenmiş, etiketli girdi ve çıktı verileri kullanılır. İkinci öğrenme türü; denetimsiz öğrenme, etiketlenmemiş girdi ve çıktı verilerinin kullanılmasıdır. Çoğunlukla derin öğrenme, nöral ağlar gibi ikinci türün denetimsiz öğrenme türündendir (Gillis, 2022). Makine öğrenmesinin üçüncü türü, denetimli ve denetimsiz öğrenmenin bir karışımı olan yarı denetimli öğrenmedir. Makine, kendi verilerini kullanıp geliştirebilir veya önceden belirlenmiş bir veri kümesi ile beklenen sonuçları kullanabilir. Son makine öğrenmesi türü, güçlendirme öğrenmesidir; makine, bir işi başarmak için birçok açık ve kesin adım kullanır ve ardından algoritma, gereken işi gerçekleştirmek için bilim insanı tarafından programlanır (Burns, 2021).

b. BT MR'inde Derin Öğrenme Uygulamaları

Montalt-Tordera, Muthurangu, Hauptmann ve Steeden'e (2021) göre, bu makine öğrenmesi tıbbi dahil olmak üzere tüm alanlarda çok önemlidir ve çoğu şirket kullanmaktadır. Görevleri algoritmik olarak başarma şekli nedeniyle şirketler için rekabetçi bir işaret olarak kabul edilir. Farklı algoritmik modeller ve sınıflandırıcılar gibi CNN ve TL ile BT MR görüntü makinelerinde derin öğrenme

(DL) olarak kullanılır. Bu derin öğrenme (DL) veya derin sinir ağı, birbirine bağlı bir grup katmandan oluşan ve her biri nöron veya düğümlerden oluşan bir makine öğrenmesi algoritması sınıfıdır. Belirli işlemlerin gerçekleştirilmesinden sonra giriş ile çıkışı birbirine bağlar. Sinir ağı daha derin olduğunda, görüntü temsili daha yüksek ve daha net hale gelir. Ek olarak, Zeng ve ark. (2021), makine öğrenmesinin BT için özellikle bu tıbbi görüntüleme için bir gelişme ve iyileştirme olarak kabul edildiğini ve daha iyi, daha net ve daha doğru sonuçlar ürettiğini göstermiştir. Ayrıca, görüntüler daha az gürültülü ve daha yüksek bir yapı benzerlik indeksine sahip hale geldi.

Ayrıca Myers (2021), algoritmik modelleri ve teknikleri ile bu makine öğreniminin radyoloji dünyasını geliştirdiğini ve BT MRG görüntülerinin derin ve küçük detaylarını ve yapılarını netleştirdiğini belirtmiştir. Makine öğrenimi alanındaki sürekli gelişim, daha hızlı sonuçlar, hastalar ve doktorlar için daha az zaman tüketimi ve daha net teşhislerin toplanan daha az önceki veri ile elde edilmesine yol açtı.

7. BT MRG Beyin Tümörü Sınıflandırmasında Önceden Eğitilmiş Modeller

BT MRG ve tümörün konumunu, türünü, alanını, sınırlarını, yapısını ve diğer detaylarını belirlemede CNN ve TL gibi derin öğrenme modelleri gibi makine öğrenimi hakkında ayrıntılı çalışmalar yapılmıştır.

Vankdothu, Abdul Hameed ve Fatima (2022), glioma, meningioma, hipofiz ve iyi huylu tümör gibi BT'nin tipleri hakkında bilgi vererek, CNN gibi BT MRA derin öğrenme modelleri ile nasıl tespit edilebileceğini açıklamıştır. Bu çalışmadaki araştırmacılar, özelliklerin ayrıntılarını elde etmek için CNN'i Uzun Kısa Süreli Bellek (LSTM) ile birleştirmeye çalıştılar. 3264 MRG taraması kullanıldı, bunların yaklaşık 2870'i eğitim fotoğrafları ve geri kalanı olan 394'ü test setleri fotoğrafları olarak kullanıldı. Çalışmanın sonuçları, CNN ve LSTMs'nin bu kombinasyonunun doğruluk ve hatırlatma değerleri açısından büyük başarı gösterdiğini göstermiştir.

Khan, Jue, Mushtaq ve Mushtaq (2020) tarafından BT MRG sınıflandırmasında CNN tekniğinin kullanımı hakkında yapılan bir çalışmada, bu makine öğrenimi algoritmik modelinin BT tespitindeki önemi açıklandı. Ayrıca, CNN çizimlerinin transfer öğrenme (TL) modelleri olan önceden eğitilmiş VGG-16, ResNet-50 ve Inception-v3 modelleri ile karşılaştırıldı. Deney küçük bir veri seti

üzerinde yapıldı ve elde edilen sonuçlar, doğruluğun %100 olduğunu, kullanılan VGG-16 modelinin yüzde 96, Resnet-50'nin yüzde 89 ve V3 modelinin yüzde 75 olduğunu gösterdi. Bu çalışmanın sonuçları, hatta küçük bir veri setinde bile deneysel modelin önceki modellere kıyasla çok yüksek bir doğruluk elde ettiğini göstermiştir.

Filatov ve Ahmad Hassan Yar'ın (2022) çalışması, önceden eğitilmiş CNN kullanarak BT MRG sınıflandırmasına odaklanmıştır ve küçük veri sorununu TL kullanarak aşmıştır. ResNet50, EfficientNetB1, EfficientNetB7 ve EfficientNetV2B1 gibi birçok ağ modeli kullanılmıştır. Sonuçlar, Efficient Net modelinin diğerlerine göre daha başarılı olduğunu ve EfficientNetB1'in %87,67 ve %89,55 doğruluk oranıyla en yüksek doğruluğa sahip olduğunu göstermiştir. Kadam, Bhuvaji ve Deshpande (2021) araştırmacıların çalışmasında, derin öğrenme algoritmalarının kullanımıyla BT sınıflandırmasına odaklandılar. Bu, 3190 görüntü örneği olarak uygulandı, bu görüntüler düzenlenip, kırıldı ve artırıldı. Sonuçlar, yapay sinir ağının (ANN) %78 ve evrimsel sinir ağının (CNN) %90 doğruluk oranına sahip olduğunu göstermiştir. Bu, CNN'nin TL kullanarak BT MRG görüntülerinin özelliklerini belirlemede ANN'den daha iyi olduğunu göstermektedir.

Alzubaidi ve arkadaşları (2021) çalışması, tıbbi görüntüleme alanında CNN modelinin önceden eğitime odaklandı ve derin öğrenme (DL) problemi olan veri eksikliği ile transfer öğrenmenin (TL) karışmasını gösterdi. TL, önceki verileri temel alır ve yeni veri için kaynak olarak kullanır. Bu, zaman kazandırdı ve BT MRG görüntüsünü geliştirdi. Bu uygulama, gri ölçekli tıbbi görüntü ve renkli MedNet adı verilen iki DL modelinin kullanılmasıyla gerçekleşti. Sonuç olarak, MedNet gelecekteki araştırmalarda kullanılabilir, ayrıca görüntü eksikliği sorununu çözebilir ve tıbbi görüntülerin segmentasyonu, sınıflandırılması ve tespitinde kullanılabilir.

Balaji, Sen ve Kirty (2022) çalışmalarında, BT'nin derin konvolüsyonel sinir ağı (DCNN) kullanılarak sınıflandırılması hakkında detaylı bilgi vermişlerdir. Araştırmacılar, glioma, meningioma ve hipofiz tümörü arasındaki farkı belirlemek için TL yardımıyla şu modelleri kullandılar: EfficientNetB0, ResNet50, Xception, MobileNetV2 ve VGG16. Deney, 3264 MRG görüntüsünden oluşan bir örnekle yapıldı. Gerekli artırma, gürültü giderme ve değiştirme işlemleri yapıldıktan sonra, DCNN'nin EfficientNetB0 modelinin kullanıldığı modeller arasında en yüksek doğruluğa sahip olduğu belirlendi (%97,61).

C. Geleneksel Görüntü İşleme Tabanlı Teknikler

Beyin kanseri, anormal ve kontrolsüz sinaptik gelişim olarak tanımlanmaktadır. Beyin tümörlerinin segmentasyonu, tümörleri değerlendirmek ve en iyi terapiyi belirlemek için önemli bir görevdir. Beyin tümörü tespiti için çeşitli görüntüleme yöntemleri bulunmaktadır (DeAngelis, 2001). Tümör dokularını tanımlamak için sınıflandırma ve tespit aşamaları gereklidir (Litjens vd., 2017). Güçlü özellikleri nedeniyle derin öğrenme mimarileri, bu tür tahmin problemleriyle başa çıkmak için diğer tekniklerden daha uygundur. Araştırmalarda en sık kullanılan derin öğrenme tekniklerinden biri olan CNN mimarisi gösterilmiştir (Kakarla vd., 2021). CNN, görüntü işleme de dahil olmak üzere birçok alanda çığır açan buluşlar ortaya koymuştur. CNN tabanlı sistemler, beyin tümörlerini etkili bir şekilde tanımlayabilir ve sağlık uzmanlarına hastaların tedavi seçeneklerini belirlemede yardımcı olabilir. 2016 verilerine göre, 200'den fazla DL tabanlı tıbbi görüntüleme araştırması önerildi ve bunların 190'ı CNN'lerle gerçekleştirildi (Litjens vd., 2017).

Derin öğrenme, dalgalet dönüşümü, evrimsel sinir ağları (CNN), Fourier dönüşümü ve destek vektör makineleri (SVM), beyin tümörü tespiti ile ilgili birçok araştırmada en sık kullanılan teknikler arasındadır. Örneğin Shree vd. tarafından önerilen teknikte, SVM ve Berkeley Dalgacık Dönüşümü (BWT) algoritmaları, MRG beyin resimlerinde normal ve hastalıklı dokuların tespiti için kullanılmaktadır. Beyin taramaları kullanılarak, sağlıklı beyin dokusu (hasarsız) ve kötü huylu tümör dokusu (enfekte) segmente edilebilir (Shree & Kumar, 2018). Önışleme, gürültüyü ortadan kaldırmak ve resmi düzleştirmek için kullanılır ve sinyal-gürültü oranını da artırır. Resimler daha sonra ayırık dalgalet dönüşümü kullanılarak ayrıştırılır ve özellik çıkarma işleminden önce (Gri düzeyi ko-özdeşlik matrisi) ile öznelikler elde edilir. Olasılıksal sinir ağı (PNN), beyin MRG görüntülerinin anormallikleri için sınıflandırma yapmak amacıyla kullanılır. Gözlemlerin sonuçlarına göre, beyin tümörlerinin tespiti, klinik uzmanlar tarafından manuel olarak yapılan tespitten daha hızlı ve doğru yapılmaktadır. Performans değişkenleri incelendiğinde, PSNR ve MSE değerlerinin artırılması daha iyi bir çıktı vermektedir. Shree çalışmasında önerilen strateji, beyin tümörlerinin doğru ve hızlı tespitinde ve tümörün belirli konumunun belirlenmesinde etkilidir (Shree & Kumar, 2018).

55 hastanın manyetik rezonans görüntüleme (MR) görüntüsünü değerlendirdikten sonra, Ocak 2010 ve Mayıs 2011 tarihleri arasında MR beyin tümörü segmentleri ve radyologlar tarafından CBAC kullanarak işaretlenen 856 SROI'nin bir veri seti elde edildi. Sachdeva vd., beyin tümörleri için çok sınıflı bir sınıflandırma geliştirdi. Bu, yapay sinir ağı tarafından geliştirilmiş T1-ağırlıklı MR görüntüleri ile istatistiksel görünüm ve yoğunluk verilerinden oluşmaktadır. PCA kullanılarak öznitelik vektörünün boyutu azaltılarak, bu tekniğin verimliliği %77'den %91'e yükseltildi. Sachdeva vd., ROI'den (MKPC) şekil, yoğunluk ve doku özelliklerinin çıkarılmasına dayalı bir beyin kanseri tanımlama ve kategorize etme tekniği geliştirdiler. Ayrıca (Sachdeva vd., 2013), elde edilen özellikleri en üst düzeye çıkarmak için lineer ayırım analizi (LDA) kullandılar ve daha sonra derin bir sinir ağı tarafından eğitildi (Sachdeva vd., 2013).

Menze vd. (n.d.) büyük ölçekli halka açık veri kümelerini kullanarak, birçok ileri beyin tümörü segmentasyon algoritmasını inceledi ve beyin tümörlerinin segmentasyonunun, MRG teknisyenleri için bile zor olduğunu, ancak mevcut algoritmaların tüm tümörlerin segmentasyonu için %80'in üzerinde dice puanları alabileceğini buldu. Tümör çekirdek bölgesinin, özellikle yüksek dereceli gliomlar için hiperaktif ana bölgenin belirlenmesi daha zor olsa da, bunların sırasıyla %70 ve %60 dice puanlarına sahip olduğu tespit edildi. İncelenen her bölge için hiçbir algoritmanın optimal performans sergilemediği, ancak bazı algoritmaların her bölge için hata oranlarının insanların değerlendirme kabiliyeti değişkenliği içinde olduğu ortaya konuldu. Ayrıca, yeni CNN mimari yenilikleri ve uygulamaları hızla yayılmaktadır. Ancak, bu yeni CNN tasarımlarının çoğu, önceki ünlü 2D-CNN mimarilerinde sunulan kavramlara dayanmaktadır. Bir hastanın organının 2D resimleri temel alınarak, 2D-CNN'ler çeşitli tıbbi alanlarda uzmanlık seviyesinde performans göstermiştir. Literatürde açıklanan en popüler 2D-CNN mimarilerinden biri olan U-Net, 512x512 biyomedikal mikroskopi resimlerinde nöral yapıların segmentasyonu için düzenlenen 2015 ISBI hücre takip yarışmasını kazandı. U-Net'in beyin görüntüleri segmentasyonu dahil olmak üzere birçok özellik çıkarımı segmentasyon görevine uygun olduğu sonucuna varılmıştır (Menze vd., n.d. 2014).

İkinci makalede, derin öğrenme kullanılarak CT MRG görüntülerinin iyi huylu ve kötü huylu türlerine sınıflandırılması için bir sistem geliştirilmiştir. Çalışma, transfer öğrenme tekniklerini kullanarak CT için MR görüntülerinin sınıflandırmasını

geliřtirmek için birçok önceden eğitilmiş ağı incelemektedir. AlexNet üzerinden yapılan transfer öğrenme, bu çalışmada kullanılan tüm PTN'ler arasında en yüksek performansı %99.04 ile sunmaktadır (Mehrotra vd., 2020).

Öncelikle, önceden seçilen DL ağları için eğitim sonuçları, seçilen artırıcının PTN'in performansı üzerinde önemli bir etkiye sahip olduğunu göstermektedir. Ağın doğruluğu üzerinde ve daha da önemlisi eğitim süresi üzerinde etkisi vardır. Ardından, tüm önceden eğitilmiş ağlar arasından, tüm optimize edicileri ADAM ile ayarlanmış GoogLeNet'in ağı eğitmek için en uzun süreyi 112 dakika ile aldığı **gözlemlenmiştir.** (Mehrotra vd., 2020).


Son olarak, belirli bir geliştirici ile eğitim için ortalama süre, en yüksek RMSProp ile 74 dakika ve en düşük olan SGDM adlı bir optimizasyon kullanılarak 63 dakikadır. Veri seti yetersiz olsa da, resim verileri eklenerek başarılı sonuçlar elde edildi. Sağlanan veri seti kullanılarak, önerilen çözümümüz mümkün olan en yüksek olan %99,04 doğruluk oranına sahipti. Gelecekte, daha büyük veri kümeleri ile çalışılarak doğruluğu artırmak ve güçlü işlemciler kullanarak ağ eğitimini hızlandırmak için çalışmalar yapılabilir (Mehrotra vd., 2020).

IV. MATERYALLER

A. Veri Setleri

Bu tez iki farklı veri kümesinden yararlanmaktadır. Beyin tümörleri için halka açık veri tabanları araştırıldıktan sonra, ilk veri kümesi 3064 beyin MRG taramasından oluşurken, ikinci veri kümesi üç farklı beyin türünde toplam 7022 taramadan oluşmaktadır.

Glioma 400, meningioma 421 ve pituiter 374, tümörsüz 510.



Şekil 15 Kaggle Verisetinden Örnek Veriler

V. YÖNTEMLER

A. Temel Algoritmalar

Bilgisayar biliminde, makine öğrenimi, bilgisayarların açıkça programlanmadan bilgi almasını sağlayan bir alt alanı ifade eder. Birçok bilgi işlem uygulaması makine öğrenimini kullanır. Basit bir algoritma tasarlamak ve yazmak başarılı bir şekilde gerçekleştirmek kolay değildir. E-posta eleme işlemi bunun örneklerinden biridir. Makine öğrenimi sistemleri, bilgisayarlara belirli görevleri yapmayı öğreterek zorlu işlemleri otomatikleştirebilir ve sonuçlardan öğrenir. Erişilebilirliğin artması, makine öğrenimi sistemlerinin büyük örneklemeler üzerinde öğrenilebileceğini ve önceden programlanmış kuralları takip etmek yerine öğrenmeyi göstermiştir. Bu sistemlerin temel işlevleri, bilgisayar hesaplama kapasitesinin artması ile desteklenmektedir.

Bugün makine öğrenmesi fikirleri, birçok uygulamanın temelini oluşturuyor. Zeka sistemleri fikri (Gordillo vd., 2013) bu alanda hala gelişmekte olan makine öğrenmesini gösterir. Ardından, tıp alanında önemli bir durum vardır. Bilginin edinilebileceği bir yapay sistem geliştirme sürecine makine öğrenmesi denir. Doktorların daha doğru olmalarına yardımcı olabilir mi? Doğru tanı konulabilen bazı bozukluklar için kamu hizmetleri için potansiyel vardır. Amaç, en çok ihtiyacı olanlara daha iyi yardımcı olmaktır. Kullanıcılar ve makineler için özelleştirilmiş hizmetler gereklidir. Öğrenme, anlamaya yardımcı olur. Bugünün araştırmacıları, biyoloji, fizik ve tıp gibi farklı disiplinlerde taze bakış açıları sunarlar.

1. Doğrusal Regresyon

Bilgisayar algoritmaları, sorunları hızlı bir şekilde çözemezler. Doğrusal regresyon kavramı ilk kez 1894 yılında Sir Francis Galton tarafından sunuldu. Doğrusal regresyon, iki değişken arasındaki ilişkiyi değerlendirmek ve nicelendirmek için matematiksel bir testtir.

İşlemlerden soyut bilginin içeriği doğrusal regresyon kullanılarak tahmin

edilebilir. Hareketin modeli ve iskeletin çalışma açısının iyi anlaşılması için doğrusal regresyon kullanılır. İlaçlar ve egzersiz, kemik oluşumuna ve kemik hareketliliğine yardımcı olur. Öğrenciler, kemik yapılandırması hakkında bilgi edinebilir ve gerçek bir bilimsel bağlamda kemik düzenleme yönetimi uygulayabilirler. Eğitimin iyileştirilmesi çabaları, geleneksel Çin tıbbının tedavi standardı ve mirası ile ilgilidir. Bağımlı değişken üzerindeki etki ile tedavi arasındaki bağlantının gücü doğrusal regresyon analizi kullanılarak belirlenebilir.


2. Destek Vektör Makinesi (SVM)

Sınıflandırma ve/veya regresyon için denetimli makine öğrenmesi için çok basit bir yöntem olan Destek Vektör Makinesi algoritması (SVM) kullanılır. Sınıflandırma için idealdir. Ancak regresyon için de oldukça yararlı olabilir. SVM, veri türleri arasındaki çizgileri ve bir hiperyüzeyi bulur. 2B uzayda, bu hiperyüzey etkili bir doğru çizgisidir.

SVM, yerel veri setindeki her veri ögesini çizer. N veri özneliği veya özellik sayısıdır. İlgili verileri almak için en iyi hiperyüzeyi **seçer**. Sonuç olarak, SVM'in yalnızca ikili sınıflandırma yapabildiğini (örneğin, iki grup arasında seçim yapmak) bilmeniz gerektiğini unutmayın, ancak çeşitli problemleri çözmek için kullanılabilecek bir dizi yaklaşım vardır.


3. Temel

Bağımlı değişkenlerin her biri mavi veya kırmızı bir daire tarafından temsil edildiği iki bağımsız değişken x_1 ve x_2 dikkate alınmaktadır. Şekilde x_3 'den görüleceği üzere, veri noktalarımızı ayıran birkaç çizgi (hiper düzlem, bu durumda iki girdi özelliği olan x_1 , x_2 'yi incelediğimiz için bir çizgidir) vardır. Dolayısıyla, veri noktalarımızı etkili bir şekilde ayıran en iyi hiper düzlemi veya daha genel olarak en iyi hiper düzlemi nasıl seçebiliriz? İki sınıf arasındaki en büyük ayırım veya marjı gösteren hiper düzlem, en iyi hiper düzlem adlandırması için iyi bir adaydır.



Şekil 16 SVM (a)

Kaynak: Geeks for Geeks, 2022.



Şekil 17 SVM (b)


Kaynak: Geeks for Geeks, 2022.

Sonuç olarak, iki tarafındaki en yakın veri noktası arasındaki en büyük mesafeyi gösteren hiperdüzlemi, en iyi hiperdüzlem olarak belirleyebiliriz. Böyle bir hiperdüzlem varsa, matematikte maksimum-margin hiperdüzlemi/sert sınır olarak adlandırılır. Bu nedenle, önceki resimden L2'yi seçeriz. Şu durumda kabul edelim ki, kırmızı topun içinde sınırda bulunan bir mavi topumuz var. SVM verileri bu şekilde nasıl sınıflandırır? Bu kadar basit! Diğer mavi toplardan farklı olan, kırmızı topların sınırındaki garip bir mavi top var. Bu yaklaşım, örnek popülasyonda hatayı en aza indirmek için optimal hiperdüzlemi tanımlarken aynı anda aykırı değerleri göz ardı etme yeteneğiyle ayırt edilir. SVM aykırı değerlerle karşı karşıya geldiğinde sağlamdır (Geeks for Geeks, 2022).

Bu tür veri noktalarıyla uğraşırken, SVM önceki veri kümeleriyle uğraştığı gibi aynı prosedürü izler: en büyük marjı olan veri noktasını belirler ve ek olarak, sınırı ihlal eden her nokta için bir ceza uygular. Bu nedenle, bu tür senaryolarda marjlar "yumuşak marjlar" olarak adlandırılır. Veri setinde yumuşak bir marj varsa, SVM, iki tamsayının toplamına eşit olan $(1/\text{margin}+(\text{penalty}))$ 'yi en aza indirmeyi amaçlar. Hinge kaybı genellikle ceza davalarında kullanılan bir tür cezalandırma yöntemidir. İhlal olmadığında menteşe kaybı veya istikrar kaybı olmaz. Bir kuralı ihlal ederseniz

para kaybedebilirsiniz. Kayıp, iki suç arasındaki mesafeye eşittir (Geeks for Geeks, 2022).


Şimdiye kadar, doğrusal olarak ayrılabilir verilerden bahsettik. Şimdi, doğrusal bir çizgi veya çizgi ile ayrılabilen mavi topların grubu ve kırmızı topların grubundan bahsediyoruz.



Şekil 18 SVM (c)

Kaynak: Geeks for Geeks, 2022.

Yukarıdaki örnekte gösterildiği gibi verinin formatı varsayıldığında, SVM kullanılarak bu sorunu çözmek için çekirdek, denklemde yeni bir değişken tanıtmak için kullanılır. Şöyle bir senaryoyu düşünelim: üzerinde bir x_i noktası olan bir çizgi olsun ve nokta ile çizginin orijini arasındaki uzaklığa orantılı başka bir değişken yi oluşturmak istiyoruz. Bu verileri çizdiğimizde, sağ taraftaki şekle benzer bir şey elde ederiz (Geeks for Geeks, 2022).



Şekil 19 SVM (d)

Kaynak: Geeks for Geeks, 2022.

Bu durumda, yeni oluşturulan değişken y 'nin, ilgi noktasının kökünden ne kadar uzakta bulunduğuyla ilgili olarak oluşturulması mümkündür. Çekirdek, orijinal değişkeni temsil etmek için kullanılan yeni bir değişken üreten non-lineer bir fonksiyondur.

a. Çekirdek

SVM çekirdeği ile, düşük boyutlu bir girdi alanı alınarak yüksek boyutlu bir uzay haline getiren bir işlev tanımlanabilir; diğer bir deyişle, ayrılabilen bir problem olmayan bir sorunu ayrılabilir hale getiren bir işlev olarak tanımlanabilir.

SVM'nin bazı avantajları şunlardır: Teknik özellikle yüksek boyutlu ortamlarda başarılıdır. Karar işlevi olarak adlandırılan eğitim noktalarının bir alt kümesine dayanarak kararlar alır, bu nedenle tüm karar fonksiyonuna dayanmaktan daha hafızalıdır. Önceden tanımlanmış çekirdek fonksiyonlarına alternatif olarak, karar fonksiyonları bir dizi farklı çekirdek fonksiyonu ile verilebilir ve özel çekirdek fonksiyonları oluşturma seçeneği de bulunmaktadır.

4. Doğrusal Ayrımcı Analizi (LDA)

SVM'nin kullanım avantajları şunları içerir: Karar verirken, destek vektörleri olarak bilinen bir alt küme kullanarak karar verme işlevindeki eğitim noktalarının sayısını azaltır, bu da gereken bellek miktarını azaltır. Önceden tanımlanmış çekirdek işlevleri yerine, karar fonksiyonları, birçok farklı çekirdek işlevi ile verilebilir ve özel çekirdek işlevleri oluşturma seçeneği de vardır. SVM'nin bazı avantajları şunlardır: Yüksek boyutlu durumlarda özellikle faydalıdır. Karar verme işlevinde, destek vektörleri olarak bilinen eğitim noktalarının bir alt kümesine dayalı olarak kararlar alır, bu nedenle bellek verimlidir. Hazır tanımlanmış kernel fonksiyonları yerine, farklı kernel fonksiyonları kullanmak veya özel kernel fonksiyonları oluşturmak için karar fonksiyonları verilebilir. Yerel ayırıcı analiz, (LDA) olarak bilinen, genellikle makine öğrenimi alanında bir çığır açan bir denetimli sınıflandırma yöntemidir. Rekabetçi makine öğrenimi modellerinin geliştirilmesinde önemli bir bileşendir. Görüntü tanıma ve öngörüsül analiz, pazarlama sektöründe bu tür boyut azaltma yönteminin kullanıldığı iki sektördür.

Boyutsal azaltma teknikleri, Bilgi İşleme, Biyoinformatik, Makine Öğrenimi ve Veri Madenciliği gibi birçok alanda önemlidir. Temel amaç, veri kümesinden gereksiz ve birbirine bağımlı özellikleri çıkarmak için verileri önceden belirlenmiş bir düşük boyutlu uzaya dönüştürmekten kaynaklanır. Bu yöntemle, belirli bir veri kümesindeki boyutların (yani değişkenlerin) sayısı azaltılırken, çoğu bilgi korunur. Genellikle çok boyutlu veriler, birbirine bağlı özelliklerden oluşan bir koleksiyondur. Boyutsal azaltma kavramı, çok boyutlu verilerin tüm boyutlarını değil, yalnızca iki

veya üç boyutta gösterilme yeteneğini ifade eder. Böylece, veriler çoğunluğun kolayca anlayabileceği net bir şekilde sunulabilir.

Basit ve etkili bir yöntem olan lojistik regresyon, doğrusal bir sınıflandırma yöntemidir. Ancak birçok dezavantajı vardır ve bu nedenle alternatif sınıflandırma algoritmalarının oluşturulmasına yol açmıştır, örneğin Lokal Dağılım Algoritması (LDA). Lojistik regresyonun birçok dezavantajı vardır, bunların bazıları aşağıda sıralanmıştır: İki tip insanı içeren problemler - İki sınıflı ve ikili sınıflandırma problemleri söz konusu olduğunda, lojistik regresyon genellikle kullanılan bir sınıflandırma yöntemidir. Sonuçları çıkarıp çok sınıflı sınıflandırmada kullanmak mümkündür, ancak bu gerçek hayatta nadiren kullanılan bir işlemdir. Öte yandan, çok sınıflı sınıflandırma gerektiğinde, Lineer Diskriminant Analizi (LDA) genellikle daha iyi bir seçenek olarak kabul edilir ve ikili sınıflandırmalar gerektiğinde, lojistik regresyon ve LDA birlikte kullanılır.

İki değişken arasında bir bağlantı olduğu düşünülen bir durumda, her renk farklı bir sınıfı temsil etmektedir. Kırmızı renk bir sınıfı temsil ederken, mavi renk ise diğer sınıfı temsil etmektedir. Bu durumda, iyi bir şekilde ayrılmış bir sınıf yapısı, kararlılık problemlerine neden olmaktadır. Eğer sınıflar yeterince ayrılmamışsa, Logistic Regresyonun istatistiksel kararlılığı bozulabilir. Bu durumda LDA devreye girer. Logistic Regresyon, sadece birkaç örnek ele alındığında istatistiksel olarak istikrarsız hale gelir. Logistic Regresyonda parametreleri tahmin etmek için sadece birkaç örnek varsa istatistiksel istikrarsızlıklar ortaya çıkar. Böyle durumlarda Linear Diskriminant Analiz, diğer yöntemlere göre daha istikrarlı bir seçenektir.




Şekil 20 LDA (a)

Kaynak: towardsdatascience.com, 2022.

Boyut sayısını azaltmak için tek boyut yeterlidir, her şeyi x eksenine yansıtabilirsiniz, aşağıdaki örnekte görüldüğü gibi: Bu nedenle, ikinci özellik bu durumda değerli bir bilgi sağlamadığından dikkate alınmamaktadır. Ancak LDA

kullanarak bu özellik de eşleştirilebilir. LDA, tamamen yeni bir eksen oluşturmak için her iki özellikten de bilgi kullanarak, değişkenliği azaltır ve iki değişken arasındaki boşluğu genişletir.




Şekil 21 LDA (b)

Kaynak: towardsdatascience.com, 2022.

Daha düşük boyutlu bir uzayda, en yüksek doğruluğa sahip yönler olarak tanımlanan yönlere yayılan en doğru veri temsili aranır. Ancak bu komutlar sınıflandırma amaçları için yararlı olmayabilir (sağdaki çizelgeye bakın). Bu nedenle, sınıflandırma senaryosunda, farklı sınıflar arasındaki ayırmacı bilgiye dayanan yenilikçi bir projeksiyon stratejisine ihtiyaç vardır. İki sınıf C1 ve C2'den oluşan bir girdi veri seti verildiğinde, eğitim bilgisi olarak aldığımız veri setine dayanarak iki sınıf arasında "en iyi" ayırt edici yönü belirlemeniz gerekmektedir.

5. Lojistik Regresyon (LR)

- Örneğin, bir e-postanın spam olma olasılığının doğru veya yanlış olup olmadığının belirlenmesi, tümörün kötü huylu olup olmadığının doğru veya yanlış olup olmadığının belirlenmesi gibi durumlarda, model çıktısı 0 veya 1'dir. Hipotez, $Z = WX + B$ ve $h(x) = \text{sigmoid}(Z)$ şeklindedir.




Şekil 22 Sigmoid Fonksiyonu, Sigmoid Şekline Sahip Bir Fonksiyon Türüdür.

Kaynak: Stefano Romanazzi, 2018.

B. Yaygın Olarak Kullanılan Mimariler ve Transfer Öğrenimi

1. Derin Öğrenme

Derin öğrenme, insan beyninin işlevleri ve yapısının model alındığı algoritma geliştirmeye odaklanan makine öğrenmesinde önemli bir alanı kapsar. 1990'lardan bu yana, medikal görüntü analizi, yüksek doğrulukları ve farklı resim sınıfları arasında ayırım yapabilen önemli yorumlamaları otomatik olarak tanımlama kapasiteleri nedeniyle görüntü sınıflandırma görevleri için son teknoloji sonuçları üretmek için DL tekniklerine dayanmaktadır (Litjens vd., 2017). CNN'ler resimler için en popüler sinir ağı tasarımlarıdır ve DL ağlarında yer almaktadırlar.



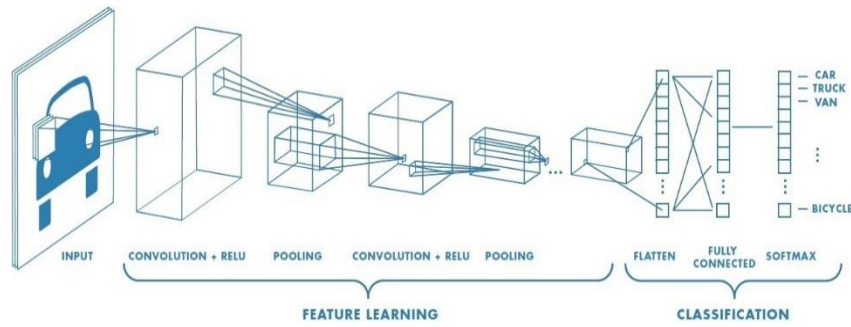
Şekil 23 İki Gizli Katman İçeren DNN Mimarisi Örneği. Oklar Ağırlıkları Temsil Ederken, Düğümler Girdi, Gizli ve Çıktı Değişkenlerini Temsil Eder. Değiştirilmiş Resim

Kaynak: Esfe vd., 2021.

2. Convölüsyonel Sinir Ağı (CNN)


CNN ve geleneksel sinir ağları oldukça benzerdir. Nöronları, eğitilebilir olan önyargılar ve ağırlıklar içerir. Nöronlar, girdilere yanıt olarak nokta çarpımları üretir ve aynı zamanda doğrusal olmayanları da takip edebilir. Ağ, işlenmemiş piksellerinden sınıf derecelendirmelerine kadar tek bir farklı skorlama fonksiyonunu yansıtır. Bu, normal sinir ağlarını eğitmek için öğrendiğimiz tüm yöntemlerin ve tekniklerin hala geçerli olduğu anlamına gelir. Şüphesiz, CNN'ler resimleri sınıflandırmak veya tanımak için son teknoloji bir teknolojidir (Gu et al., 2018). Fikirleri, insanların görsel beyinde meydana gelen anatomik ve fizyolojik süreçlerden kaynaklanır (Vodrahalli et al., 2017). Görsel verinin retinadan optik

sinire nasıl yol aldığını anlamak için bazı çalışmalar görselleştirmeler yapabilirler. Kısaca belirtilen, nöronlar belirli desenler ve renkler için girdi görsel bilgilerini tararlar. CNN'lerin mimarisi, görme korteksinin çok sayıda soyutlama seviyesi içerdiği varsayımına dayanır. Gelen bilginin farklı soyutlamalarından öğrenmek için çok sayıda katman oluştururlar (Banerjee vd., 2017) Özellikle, gradyan geriye yayılımı kullanarak değiştirilen konvolüsyon filtrelerini kullanarak belirli soyutlamaları otomatik olarak öğrenirler. Bu otomatik süreç, bu ağların girdi resminden anında düşük, orta ve yüksek düzeyde temsil edici özellikler öğrenmesini sağlar ve manuel olarak oluşturulmuş görüntü özellikleri gerektirmez. Ayrıca, önceden belirli bir alan uzmanlığına ihtiyaçları olmadığı için sadece eğitim verilerinden öğrenerek bir görevi başarmayı öğrenebilirler. Yoğun ağların aksine, her katman için sınırlı sayıda küçük filtre öğrenmesi gereken bir CNN yalnızca dokuz ağırlığı ve bir sapmayı öğrenerek üçe üç bir resmi işlemek için yeterlidir. Bir megapiksel olan bir görüntüyü işlemek için yoğun bir ağ, her katmandaki her düğüm için bir milyon ağırlık öğrenmek zorundadır, ancak bir CNN yalnızca bir giriş katmanı, bir konvolüsyon katmanı, bir aktivasyon katmanı ve bir özetleme katmanı gibi birkaç bileşen öğrenerek resim verilerini yönetmek için artık önemli ölçüde daha etkilidir.




Şekil 24 CNN'nin Mimarisi.

Kaynak: Rachmad Syulistyo vd., 2020.



Şekil 25 Geleneksel 3 Katmanlı Sinir Ağı

Kaynak: Kumar Vaibhav vd., 2021.

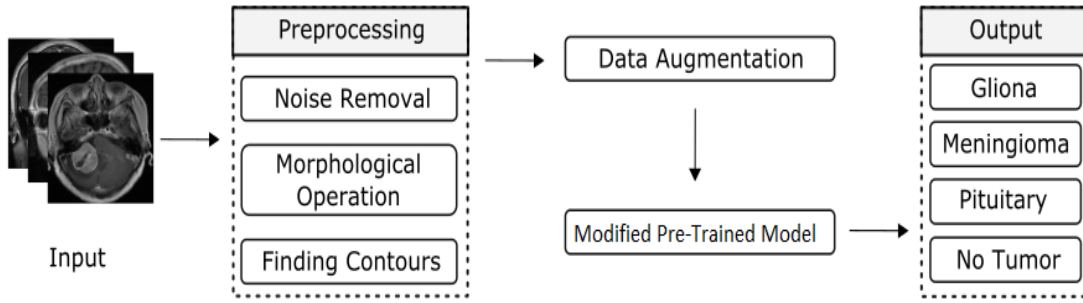


Şekil 26 CNN'nin Nöronlarının Üç Boyutlu Yerleşimi

Kaynak: Kumar Vaibhav vd., 2021.

Şekil 25'te geleneksel 3 katmanlı bir Sinir Ağı gösterilmektedir. Şekil 26'da ise katmanlardan birinin temsili olarak, bir ConvNet üç eksen (genişlik, yükseklik ve derinlik) üzerinde nöronlarını oluşturur. Bir ConvNet'in katmanları, giriş hacmini etkinleştirilmiş nöronların 3D çıkış hacmine dönüştürür. Bu geçiş her katmanda gerçekleşir. Bu görselleştirme de, görüntü kırmızı giriş katmanında yer alır, genişliği ve yüksekliği görüntünün oranlarıyla eşleşirken derinliği katmanın 3 piksel değerine (Kırmızı, Yeşil, Mavi kanallar) denk gelir.

3. Figure of Layers



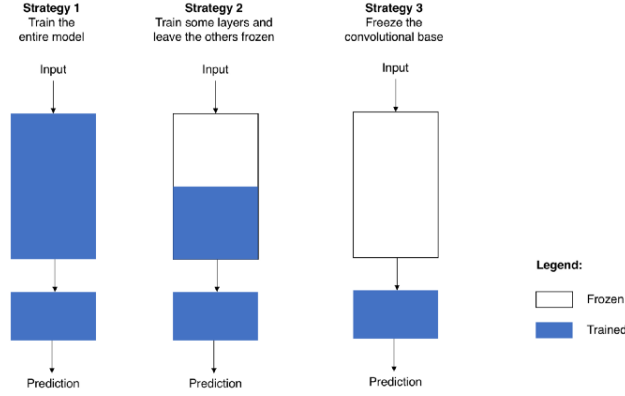
Şekil 27 Tezdeki Araştırma İçin Önerilen Teknikler.

Kaynak: Alnemer vd., (2021) çalışmasından güncelleştirilmiştir.

4. Önceden Eğitilmiş Modeller

Transfer öğrenme, daha önce öğrenilmiş benzer bir görevden bilgi kullanarak yeni bir görevin öğrenilmesini geliştirmek için kullanılan bir süreci ifade eder (Olivas vd., 2009). Başka bir deyişle, bir önceden eğitilmiş model, temel veri kümesi ve görevinde eğitildikten sonra, özellikleri yeni bir ağa aktararak, ya da basitçe yinelenerek, yeni bir hedefin eğitiminde kullanılır. Derin öğrenmede, öğrenilen özelliklerin genel olması

durumunda bu strateji genellikle iyi işe yarar (Yosinski vd., 2014).



Şekil 28 İnce Ayarlama Stratejileri

Kaynak: towardsdatascience.com, 2022.

Üçüncü Stratejinin uygulaması kolay olsa da, Strateji 1 ve Strateji 2, algoritmanın konvolüsyon kısmında kullanılan öğrenme oranının dikkatli bir şekilde düşünülmesini gerektirir. Ağızınızın ağırlıklarını değiştirdiğinizde Şekil 28, ağırlıkların ne kadar değiştirilebileceğini kontrol eden bir hiper-parametre olan öğrenme oranıdır. Önceden eğitilmiş bir CNN modeli kullanırken, öğrenme oranını mümkün olduğunca düşük tutmak önemlidir, çünkü yüksek öğrenme oranları önceki bilgilerin kaybedilme riskini artırır. Önceden eğitilmiş model yeterince eğitilmişse, ki bu olası bir varsayımdır, düşük öğrenme oranını korumak, CNN ağırlıklarının önceden bilgilerin zamanında ve aşırı şekilde bozulmamasını garanti eder.


a. AlexNet

AlexNet, bir üstünde bir konvolüsyonel katman olan 8 katmanlı bir konvolüsyonel sinir ağıdır. Başka bir deyişle, AlexNet bir ağ mimarisidir. AlexNet derin bir mimari olduğundan, özellik haritalarının boyutunun dramatik olarak küçülmesinden kaçınmak için araştırmacılar özellik haritalarına dolgular eklediler. Bu, AlexNet'in derin bir mimari olduğunu fark etmek önemlidir. Bu model için giriş olarak 227x227x3 boyutlu fotoğraflar kullanılır. Toplamda sekiz katmanı ve öğrenilebilir parametreleri vardır. Bu algoritmadaki RGB fotoğrafları modelin girdisi olarak kullanılır. Bu algoritma, bir karışımı oluşturmak için maksimum havuzlama katmanları kullanır. Daha sonra, tamamen birleştirilmiş üç katmana sahiptir. Katmanlar boyunca, birincil aktivasyon fonksiyonu olarak Relu kullanılır. Bu projede dropout katmanları kullanıldı. Son

katmanda Softmax aktivasyon fonksiyonunun kullanımı mevcuttur. Bu modelin mimarisi toplamda 62,3 milyon parametreyi göstermektedir.

b. ResNet


ResNet, Kısaca Residual Network (Artıklık Ağı), son derece başarılı olan bir modele sahiptir ve yapılan istatistikler bunu göstermektedir: bağıl iyileşmelerde %28 oranında artış keşfedilmiştir. Ayrıca, eğitimi etkili bir şekilde gerçekleştirilen 100 ve 1000 katmanlı ağlar da mevcuttur. Klasik bir CNN modelinin, maksimum katman sayısı açısından bir sınırı vardır. Örneğin, 20 katmanlı bir CNN ve 56 katmanlı bir CNN, aşılamayan bir maksimum derinlik eşiği bulundurur. Eğitim ve test verilerindeki hata yüzdesi aşağıdaki grafikte gösterilmiştir.



Şekil 29 CIFAR-10 veri kümesinde 20 ve 56 katmanlı "düz" ağlarla eğitim hatası (sol) ve test hatası (sağ)

Kaynak: João Crespo vd., 2021.

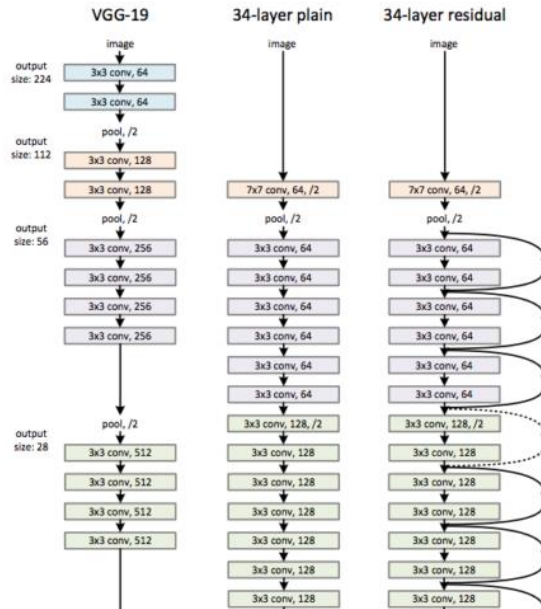
Ağın performansının azaldığı görülebilir. 20 katmanlı bir ağ kullanıldığında test ve eğitim veri setlerindeki hata yüzdesine kıyasla, 56 katmanlı bir ağ için hata yüzdesi daha büyüktür. Bu, bir ağın üstüne ek katmanlar eklendiğinde, ağın performansının düştüğünü göstermektedir. Bu, optimizasyon fonksiyonu, ağın kurulumu ve en önemlisi, kaybolan gradyan sorunu gibi birçok faktörden kaynaklanabilir. Belki de bunun aşırı uyum nedeniyle de bir sonuç olduğunu düşünüyorsunuz, ancak bu durumda, 56 katmanlı ağın eğitim ve test verilerindeki hata yüzdesi en düşük performansı gösterir, ki bu aşırı uyumlu model için geçerli değildir. Blokajın Residual Networks, ResNet'in geliştirilmesi, Residual Bloklar'dan oluştuğu için, yüksek derin ağları eğitmenin zorluklarını azaltmıştır. ResNets, Residual Bloklardan oluşan bir tür residual ağıdır.



Şekil 30 Artımsal Öğrenme: Bir Yapı Taşı

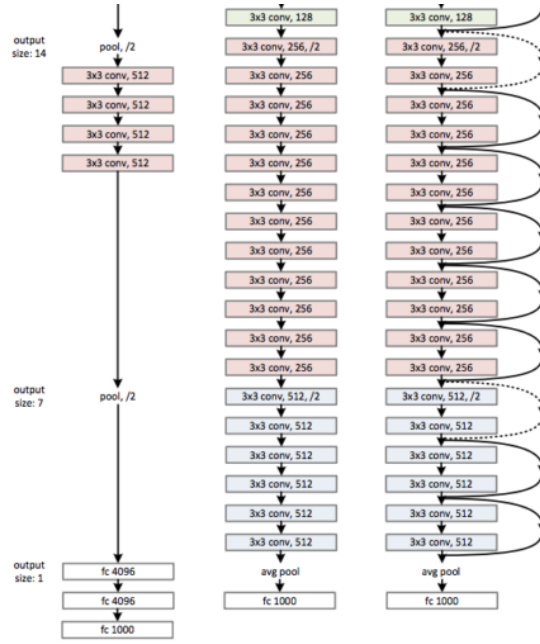
Kaynak: Shuvendu Roy vd., 2019.

Bu yaklaşımda dikkat çeken ilk şey, aradaki belirli katmanları (modelden modele değişebilir) atlayan iki nokta arasında doğrudan bir bağlantı olduğudur. Bu bağlantı "atla bağlantısı" olarak adlandırılır ve kalıntı bloklarının temelini oluşturur. Katmanın çıktısı, atla bağlantısı yapılmadan önceki haliyle aynı kalmaz.



Şekil 31 Kalıntı Öğrenimi: Bir Yapı Bloğu a kısmı

Kaynak: Shuvendu Roy vd., 2019




Şekil 31 Kalıntı Öğrenimi: Bir Yapı Bloğu b kısmı

Kaynak: Shuvendu Roy vd., 2019.

ResNet ağında, VGG-19'dan esinlenilerek 34 katmanlı basit bir ağ tasarımı kullanılmış ve ardından hızlı bağlantı tanıtılmıştır. Daha sonra, kısa yol bağlantıları tasarımı, diyagramda görüldüğü gibi, bir artıklık ağına dönüştürür.

c. DenseNet


DenseNet, yoğun bağlantı ağı (Dense Convolutional Network) anlamına gelen bir kısaltmadır. ResNet ve Pre-Activation ResNet ile karşılaştırıldığında, yoğun bağlantı sayesinde daha az parametre kullanarak mükemmel bir doğruluk elde edilebilir.



Şekil 32 Standart ConvNet

Kaynak: Gao Huang vd., 2017.

Standart ConvNet kavramının Yoğun Bloğu, Standart ConvNet'te, yüksek seviyeli özellikleri elde etmek için girdi resmi birkaç evreli evrişimlere tabi tutulur.




Şekil 33 ResNet Konsepti

Kaynak: Gao Huang vd., 2017.


ResNet kavramı, Kalan Ağ Kavramı anlamına gelen bir kısaltmadır. Gradient yayılımını artırmak için ResNet'te, kimlik eşlemesi, ağın eğitimi için bir yöntem olarak sunulur.

"Eleman-temelli toplama" kullanmak gereklidir. ResNet modülleri birbirlerine aktarılan bir durumu olan algoritmalar olarak düşünülebilir.



Şekil 34 DenseNet'teki Bir Yoğun Blok

Kaynak: Gao Huang vd., 2017.



Şekil 35 Büyüme Oranlı Olan DenseNet'teki Yoğun Blok


Kaynak: Gao Huang vd., 2017.

DenseNet'de yüksek büyüme oranına sahip blok, yoğun blok olarak adlandırılır. İleri yayılım bağlamında birleştirme kavramı aşağıdaki diyagramda gösterilmiştir. DenseNet Mimari Temel Yapı Taşı, ağ bileşimi katmanı türünde bir yapı taşıdır. DenseNet-B, Yoğun Ağ tipi B anlamına gelir. (Flaş Bellekli Katmanlar)

d. Efficient Net

Derin öğrenme modellerinin etkililiğini artırmak için EfficientNet adında bir

dizi evrişimli sinir ağı (CNN) modeli oluşturuldu. Bu modeller, özellikle mobil cihazlarda veya bulutta olduğu gibi sınırlı hesaplama kaynakları olan uygulamalar için oldukça yüksek doğruluk sağlayarak daha az girdi ve hesaplama kullanmaları için tasarlanmıştır. EfficientNet modelleri, ağ derinliği ve genişliği (kanal sayısı ve girdi resminin çözünürlüğü gibi şeyler) ile birlikte ağ boyutunu ölçeklendiren bir bileşik ölçekleme stratejisine dayanır. Sıklıkla derinliği veya genişliği artıran geleneksel CNN modellerine kıyasla, bu modellerin model boyutunu daha etkili bir şekilde artırmasına izin vererek modellerin doğruluğunu artırır.



Şekil 36 EfficientNetB0 Temel Model Mimarisi

Kaynak: Francis Jesmar Perez Montalbo vd., 2021.

EfficientNet modelleri etkilidir ve ayrıca çeşitli diğer avantajlara sahiptir. Basit bir API'ya ve çeşitli resim sınıflandırma görevleri için erişilebilir önceden eğitilmiş ağırlıklara sahip oldukları için kullanımı kolay olacak şekilde tasarlanmışlardır. Ek olarak, belirli bir iş için performansı maksimize etmek için ayarlanabilen birkaç hiperparametreye sahiptirler. Genel olarak, EfficientNet modelleri, çeşitli resim sınıflandırma görevlerinde yüksek performans göstermiş ve etkili derin öğrenme modelleri oluşturmaya çalışan herkes için etkileyici bir seçenektir.

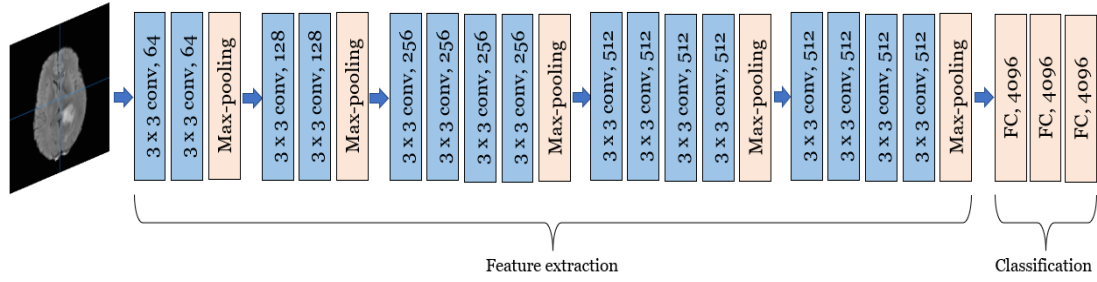
e. Squeeze -Net

"Fire Module" adı verilen bir yapı. Çalışmanın yazarları, bu iki katmanın birleşimini tanımlamak için bir sıkıştırma katmanı ve bir genişletme katmanı olarak "fire modülü" olarak adlandıırırlar. İlk olarak bir giriş resmi, yalnız bir evrişim katmanına aktarılır ve daha sonra üzerinde çeşitli işlemler yapılır. Bir sonraki katman, Birinci stratejiye uygun olarak "fire2-9" olarak belirlenen sekiz "fire modülünden" oluşur. Oluşturulan SqueezeNet aşağıdaki şekilde görülebilir.

f. VGG19

Oxford Üniversitesi'nde Simonyan & Zisserman 2014 yılında VGG-19 konseptini sunmuştur. Araştırmacıların tekniği, ağ derinliğini 19 katmana kadar

geniřletmek için 3 x 3 boyutunda bir çekirdek kullandığı için yeni ve özgündü. Önerilen ağırları, 2014'te ImageNet Challenge'da, yerelleřtirme için birinci ve sınıflandırma için ikinci yer aldı ve en son sınıflandırma doęruluęu sonuçlarına sahip oldu (Simonyan et al., 2015). VGG19, derinlięi nedeniyle kuřkusuz ağır bir modeldir, ancak basit bir yapıya sahiptir. VGG-19 mimarisini oluřturan beř evriřim bloęu ve üç tam baęlı katman bulunur. 37. řekilde görsel bir açıklama verilmiřtir.



řekil 37 VGG-19 Modelinin Temel Mimari Yapısı.

Kaynak: Araujo vd., 2019.

Bu yöntem de önceden belirlenmiř 224 x 224 boyutundaki bir RGB görüntüsünü girdi olarak kullanır. Bu girdi daha sonra, özellięi üreten girdi alanının boyutunu belirleyen 3 x 3'lük bir boyutlu alanı olan bir konvolüsyon katmanını yığınından geçirilir (Araujo et al., 2019). Bu model sol saę veya yukarıdan ařaęıya doęru çalıřır. İlk bloklar 64 görüntü özellięi üretir ve derinlięi arttırmak için ek filtreler eklenerek alınabilecek özelliklerin sayısı artar. Her konvolüsyon bloęundan sonra 2 x 2 piksel boyutunda ve 2'lik adım uzaklıęı olan maksimum havuzlama katmanını uygulanır. Ayrıca tüm görünmeyen katmanlarda ReLU aktivasyon iřlevi kullanılır. Özellik çıkarma iřlemi tamamlandıęında, sınıflandırma iřlemi için üç tam baęlantılı katman devralır. Özellikle, ilk iki tam baęlantılı katmanda sırasıyla 4096 kanal bulunurken, üçüncü katman kategorize etme iřlemini yapar ve 1000 kanala sahiptir. Son katman, softmax aktivasyonunu kullanan yoęun bir katmandır.

VI. DENEYSEL SONUÇLAR

Öncelikle, önceden eğitilmiş modellerin değişikliklerinin ve araştırma yöntemi kombinasyonlarının genel sonuçları tartışılmaktadır. İkinci bölümde, model karşılaştırmalarının sonuçları sunulmaktadır.

A. Sınıflandırma Görevlerinde Önceden Eğitilmiş Modellerin Kullanım Teknikleri

Son yıllarda, önceden eğitilmiş model teknikleri, büyük veri kümelerinden anlamlı özelliklerin çıkarılabilmesi nedeniyle sınıflandırma problemlerinde popülerlik kazanmıştır. Özellik çıkarımı, ince ayar ve aktarım öğrenimi, önceden eğitilmiş modelleri kullanmanın birkaç yöntemidir. Özellik çıkarımı sırasında, önceden eğitilmiş model bir sabit özellik çıkarıcısı olarak kullanılır ve modelin katmanlarının çıktısı başka bir sınıflandırıcıya girdi olarak sağlanır (Bhuvaji et al., 2020). İnce ayar yapmak, önceden eğitilmiş modelin parametrelerini belirli bir görev için değiştirmeyi gerektiren bir işlem olup, belli kısımların katmanlarının çözülmesi ve yeniden eğitilmesini içerir. Aktarım öğrenimi, önceden öğrenilmiş modele başlayıp, önceden öğretilmiş modeli bir özellik çıkarıcısı olarak kullanarak yeni bir modelin sıfırdan eğitilmesini içerir. Hangi yöntemin benimsenmesinin en iyi olacağı, her birinin avantajları ve dezavantajları ile ilgili veri kümesine ve hedefe bağlı olacaktır (Bhuvaji et al., 2020).

Ana Karşılaştırma Akışı, bu çalışmanın amaçları ve hedefleri doğrultusunda, MRG beyin tümörlerini sınıflandırmak için dört yöntemin etkinliğini karşılaştırmaktır: Özellik çıkarma: Eğitilmiş bir model kullanarak özellikleri çıkarmak ve ardından softmax aktivasyon eğitimi ile tümörleri dört gruba ayırmak. İnce ayar: Daha önce eğitilmiş bir modelin birkaç katmanını eğitmek, sonra bu ince ayarlı modeli kullanarak tümörleri dört sınıflandırmadan birine yerleştirmek. Transfer öğrenme: Zaten eğitilmiş bir model üzerine inşa etmek, konvolüsyonel, dropout ve yoğun katmanlar eklemek ve ardından bu modeli kullanarak tümörleri dört gruba ayırmak. Kombinasyon: Yukarıda bahsedilen üç yöntemi birleştirerek tümörleri dört sınıflandırmadan birine ayırmak. **Bu amaç için** başarılı olduğu bilinen

önceden eğitilmiş üç model Python kodunda kullanılacak ve bu yöntemlerin etkililiği karşılaştırılacaktır. Modelleri gelecekteki incelemeler için depolamak için sonuçları çizeceğiz.

Bu çalışmada MRG beyin tümörü veri seti kullanılmış ve daha sonra eğitim setine ve doğrulama setine bölünmüştür. Ayrıca, piksel değerlerinin standartlaştırılması gibi şeyleri içeren veri hazırlığı yapılmıştır. Karşılaştırmaları kolaylaştırmak için, önceden eğitilmiş ResNet152V2, Xception, ResNet50, NasNetMobile ve InceptionV3 modelleri yüklenmiştir. Veri artırma stratejisi uygulanmış ve parametreler seçilmiştir. Birleştirme stratejisi, özellik çıkarımı, ince ayar ve transfer öğrenme olmak üzere dört farklı strateji uygulanmıştır. Bu metodolojiler, modellerin eğitimi ve eğitim ve doğrulama setleri üzerinde test edilmesini içermektedir. Sonuçlar doğruluk, hassasiyet ve özgüllük gibi ölçütler ve F-skoru gibi ölçümler kullanılarak karşılaştırılıp çizdirilir. En yüksek genel puanları olan modeller yalnızca tutulur.

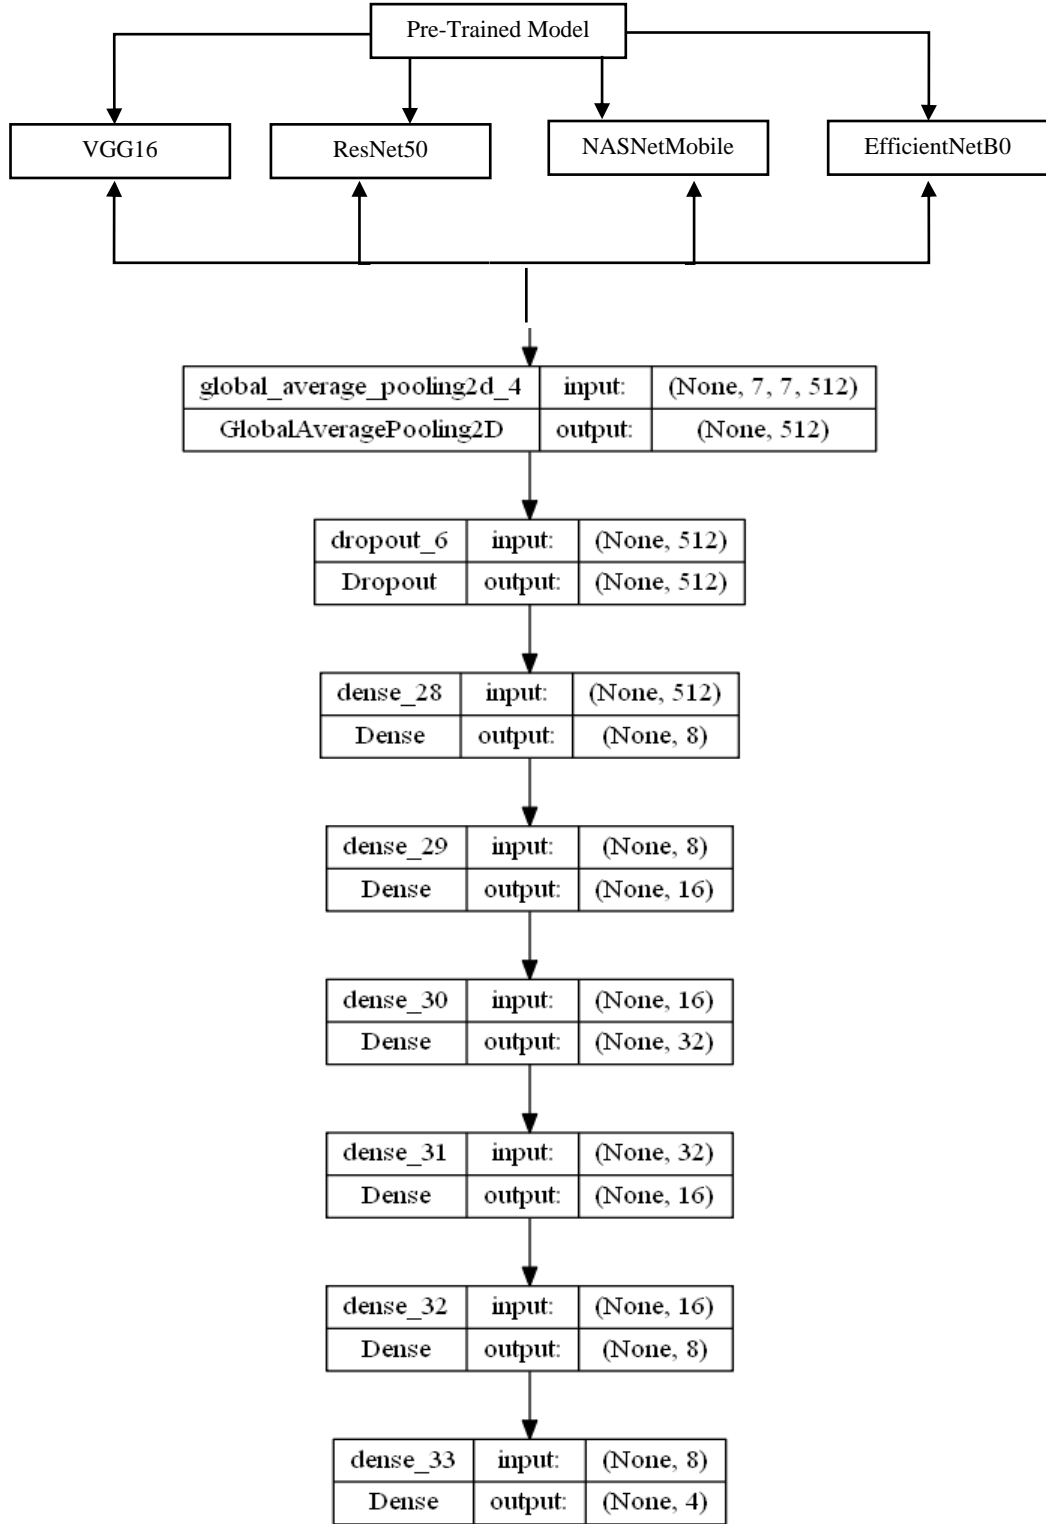
Her bir önceden eğitilmiş modelin farklı bir resim boyutu vardır: Büyük bir veri kümesinde eğitilip, daha sonra diğer araştırmacılar veya uygulayıcılar tarafından kullanılmak üzere kullanılabilir hale getirilen modellere önceden eğitilmiş modeller denir. Bu modellerin belirli bir boyuttaki resimlerle eğitildiği için, modeli değerlendirmek veya ince ayarlamak için kullanılan fotoğrafların aynı boyutta olması önemlidir. Resim boyutu farklı olduğunda, model resimleri doğru şekilde işleyemeyebilir ve bu nedenle modelin performansı etkilenebilir. Aşırı uydurma, bir modelin yalnızca eğitim verisine özgü desen ve özellikleri öğrenmesi ve yeni verilere iyi genelleştirilememesi durumunda meydana gelir. Bu, modelin çok küçük veya çok özelleştirilmiş bir veri kümesi üzerinde eğitildiğinde meydana gelir. Aşırı uydurma, test veya doğrulama setinde kötü performansa neden olabilir. Aşırı uydurmaya karşı koymak için, büyük ve çeşitli bir veri kümesi kullanın ve modeli farklı bir doğrulama seti üzerinde periyodik olarak değerlendirin.

Alt uyarılama: Bir model, verilerdeki temel ilişki ve örüntüleri hesaba katmak için çok basitse, alt uydurma ortaya çıkar. Bu, eğitim kümesinde kötü performans gösteren ve yeni verilerde genelleme yapamayan bir modele yol açabilir. Alt uydurmaya engel olmak için, temel örüntüleri yakalayacak kadar karmaşık bir model seçmek önemlidir. Modelin doğru çalıştığından emin olmak için farklı bir doğrulama seti üzerinde düzenli olarak değerlendirme yapılmalıdır. Evrensel ortalama

havuzlama 2D, girişin her özellik haritasını ortalayarak girişin mekansal boyutunu azaltan bir havuzlama katmanı türüdür. Bu, önemli girdi verilerini korurken parametre sayısını ve hesaplama karmaşıklığını azaltmak için CNN'lerde sıkça kullanılır. Bir havuzlama katmanından sonra, girişi tamamen bağlı katmanların analizi ve hazırlanması için tek boyutlu bir tensöre düzleştirme katmanı sıklıkla kullanılır. CNN'ler, kategorizasyon veya diğer görevler için girdiyi analiz etmek ve hazırlamak için her iki katmanı da sıkça kullanır. Araştırma yapısı aşağıdaki tabloda ve şekilde gösterilmiştir.

Çizelge 1 Araştırma Yapısı

Teknik	Avantajlar	Dezavantajlar
Özellik Çıkarma	Büyük veri kümelerinde verimli eğitim imkanı sağlar	Baz modelin fine-tuning işlemine izin vermez
İnce Ayar (fine-tuning)	Baz modelin fine-tuning işlemine izin verir	Zaman alıcı olabilir ve büyük bir veri kümesine ihtiyaç duyar
Transfer Öğrenme	Daha küçük veri kümelerinde verimli eğitim imkanı sağlar	Baz modelin fine-tuning işlemine izin vermez



Şekil 38 Bu Tezde Önerilen Önceden Eğitilmiş Modellerin Araştırılması Yöntemi.

Önceden eğitilmiş bir modeli temel alarak, bu tezde karşılaştırma için önerilen modelin mimarisi bir evrişimli sinir ağı modeli oluşturur. Önceden eğitilmiş modelle ilgili bilgileri içeren değişken "pre trained model" önceden tanımlanmış olması gerekmektedir. Önceden eğitilmiş modelin çıktı katmanı, toplamda birçok katmanı

olan modelin ilk katmanıdır. Bu katmanın ardından (yükseklik ve genişlik) girdinin uzamsal boyutları boyunca ortalama havuzlama uygulayan bir Global Average Pooling 2D katmanı gelir. Bu katmanın ardından, eğitim sırasında her güncellemede girdinin %20'sini rastgele olarak 0'a ayarlayarak aşırı öğrenmeyi azaltmaya yardımcı olan %0,2'lik bir orana sahip bir dropout katmanı gelir.

Model, önceden eğitilmiş bir model üzerine inşa edilen bir evrişimli sinir ağı modelidir. Önceden tanımlanmış olan değişken "pretrained model" önceden eğitilmiş model hakkında bilgi içerir. Önceden eğitilmiş modelin çıktı katmanı, toplamda birçok katmana sahip olan modelin ilk katmanıdır. Bu durumu takiben, girişin (yükseklik ve genişlik) boyutları boyunca ortalama havuzlama uygulayan GlobalAveragePooling2D katmanı yer alır. Bunu takiben, oranı %20 olan bir dropout katmanı yer alır. Bu, her güncellemede %20'si rastgele olarak sıfırlanan giriş birimlerini azaltarak aşırı uyumlanmayı azaltmaya yardımcı olur.

Model, tamamen bağlı birkaç yoğun katmandan oluşur, her katmanın birim sayısı ve aktivasyon işlevi tanımlanmıştır. Son katman, 4 birime sahip bir katmandır ve çoklu sınıf sınıflandırma problemleri için sıkça kullanılan softmax aktivasyon işlevini içerir. Bu katman için "l1 l2" çekirdek düzenleyicisi sağlanmıştır ve bu düzenleyici, ağırlıklara hem L1 hem de L2 düzenlemesi uygular. Daha sonra modeli oluşturmak için doğruluk metriği, kategorik çapraz entropi kaybı işlevi ve Adam optimizer kullanılır.

Önceden eğitilmiş modelin katmanları daha sonra, son üç katman hariç, eğitilemez olarak yapılandı

Çizelge 2 Önceden Eğitilmiş Modellerin Üç Kullanım Yöntemi.

Araştırma alanı	Tanım	Seçenekler
Özellik Çıkarma	Önceden eğitilmiş modelleri sabit özellikli bir çıkarıcı olarak kullanma	Önceden eğitilmiş modeli kullanarak özellikleri çıkarın ve çıkarılan özellikleri kullanarak yeni bir model eğitin
İnce Ayar	Önceden eğitilmiş modelin birkaç katmanını çözmek ve katmanların geri kalanını donmuş tutarken bu katmanları eğitmek	Belirli sayıda katmanı çözün ve geri kalanını dondururken bu katmanları eğitin
Transfer Öğrenimi	Önceden eğitilmiş ağırlıkları başlatma olarak kullanarak bir modelin sıfırdan eğitimi	Önceden eğitilmiş ağırlıkları başlatma olarak kullanarak sıfırdan bir model eğitin

Çizelge 3 Genişletilmiş Bir Araştırma İçin Olası Senaryo (a Kısımı)

Teknik	Eğitim verileri	Doğrulama verileri	Test Verileri
Özellik Çıkarma	Önceden eğitilmiş model	Önceden eğitilmiş model	Önceden işlenmiş görüntüler
İnce Ayar	Önceden eğitilmiş model	Önceden işlenmiş görüntüler	Önceden işlenmiş görüntüler
Transfer Öğrenimi	Önceden işlenmiş görüntüler	Önceden işlenmiş görüntüler	Önceden işlenmiş görüntüler

Çizelge 4 Genişletilmiş Bir Araştırma İçin Olası Senaryo (b Kısımı)

Optimize edici	Öğrenme oranı	Aktivasyon işlevi	Çağ sayısı	Parti boyutu	Eğitim süresi	Kesinlik
Adam	0.0001	ReLU	50	32	2 saat	85%
Adam	0.00001	ReLU	50	32	4 saat	87%
Adam	0.00001	ReLU	50	32	6 saat	89%

Çizelge 5 Basit Karşılaştırma

Technique	Doğruluk	Hassasiyet	Duyarlılık	Özgüllüğü	F-skoru
Özellik çıkarma	0.92	0.92	0.94	0.97	0.93
İnce ayar	0.96	0.97	0.96	0.94	0.97
Transfer öğrenimi	0.95	0.99	0.98	0.92	0.99

Araştırma, özellik çıkarımı, daha sonra önceden eğitilmiş modelin son katmanlarının ince ayarının yapılması ve bir eklemeli modele aktarım öğrenmesi yapılması sonucunda elde edilen bir yapısal modelin etkili olduğunu gösterdi. Daha önceden oluşturulmuş bir konvolüsyonel veya tam bağlantılı katmanın çıktısını düzleştirmek için kullanılan bir flatten katmanı veya bir GlobalAveragePooling2D katmanı kullanılması bu modelin yapısında yer almaktadır. GlobalAveragePooling2D katmanı, bir konvolüsyon katmanının çıktısının uzamsal boyutlarını azaltmak için kullanılırken, çıktının derinliğini (filtre sayısı) korur. CNN'deki tam bağlantılı katmanın yerine, her filtre için tüm uzamsal boyutlar üzerinde ortalama olarak çıktıyı sabit sayıda özellik haline getiren bir global havuzlama katmanı yerleştirilir. Bu, aşırı uyumun azaltılmasına yardımcı olur ve ayrıca ağırların girdisinin küçük çevirilerine daha dayanıklı hale getirir. Ardından, aşırı uymamanın sağlanması için yoğun katmanlar ve dropout katmanları takip edilir.

Veri artırma: Veri artırma tekniđi, orijinal fotođraflar üzerinde çeşitli deđişiklikler yaparak yapay olarak bir veri kümesinin boyutunu genişletmek için kullanılabilir. Bu deđişiklikler arasında döndürme, yansıtma, ölçeklendirme veya kaydırma gibi şeyler yer alabilir. Orijinal görüntülere bu deđişiklikleri uygulayarak, biraz farklı yeni fotođraflar üretilir, bu da veri kümesinin çeşitliliđini artırmaya ve aşırı öğrenmeyi azaltmaya yardımcı olabilir. Ayrıca, bir modelin genelleme yeteneđini artırmak için daha geniş bir örnek kümesine erişim sağlayarak, veri artırma, bir modelin performansını artırmaya yardımcı olabilir. Küçük veri kümeleri ile çalışırken bu çok faydalı olabilir çünkü aşırı öğrenme riskini azaltabilir ve model performansını artırabilir.

Çizelge 6 Araştırılan Veri Büyütme Teknikleri

Parametre	Deđer Aralığı	Python Kodu Örneđi
Dönme	0 ila 360 derece	<code>rotation_range = 90</code>
Genişlik kayması	-1 ila 1	<code>width_shift_range = 0.2</code>
Yükseklik kayması	-1 ila 1	<code>Height_shift_range = 0.2</code>
Parlaklık	0 ila 1	<code>Brightness_range = [0.5, 1.5]</code>
Zum	0 ila 1	<code>Zoom_range = [0.5, 1.5]</code>
Kırpma	-0.5 ila 0.5	<code>Shear_range = 0.2</code>
Yatay flip	Dođru ya da yanlış	<code>horizontal_flip = true</code>
Dikey flip	Dođru ya da yanlış	<code>dikey_flip = true</code>
Kanal kayması	-1 ila 1	<code>kanal_shift_range = 100</code>
Gauss gürültüsü	0 ila 1	<code>gaussian_noise_range = 0.5</code>
Poisson gürültüsü	0 ila 1	<code>poisson_noise_range = 0.5</code>
Mekansal dönüşüm	-1 ila 1	<code>spatial_transform_range = 0.5</code>
Afin dönüşümü	-1 ila 1	<code>Affine_transform_range = 0.5</code>
Elastik dönüş	-1 ila 1	<code>elastik_transform_range = 0.5</code>
Rastgele silme	0 ila 1	<code>random_erasing_range = 0.5</code>

Araştırma, veri artırmanın aşırı kullanımının veri setini bozabileceđini gösterdi ve bu nedenle veri artırma tekniklerinin dikkatli bir şekilde ve minimal olarak kullanılması gerektiđini, her teknik ayrı ayrı incelenerek veri seti bozulmasının önlenmesi gerektiđini ortaya koydu.

B. Metrikler ve Karmaşıklık Matrisleri

Deneyisel araştırmanın performans sonuçlarını değerlendirmek için, hedef özelliğin tahminleri ve gerçek değerleri karşılaştırılarak confusion matrix'ler kullanılmıştır. Confusion matrix'te, doğru ve yanlış beyanların sayısı, ilgili sayısal değerlerin özetleri ile ilgili sınıflara ayrılır. Matrisin her sütunu gerçek değere karşılık gelirken, her satır tahmin edilen bir sınıfı temsil eder. Confusion matrix'te, True Positive (TP) ve True Negative (TN) modelin doğru tahmin ettiği değerleri, False Positive (FP) ve False Negative (FN) ise modelin yanlış tahmin ettiği değerleri temsil eder. Confusion matrix kullanılarak, precision, accuracy, specificity, F-score ve sensitivity hesaplanmıştır.

Çizelge 7 AlexNet Metrik Sonuçları


AlexNet	Tahmini glioma	Tahmini glioma	Tahmini glioma	Tahmini glioma
Gerçek Glioma	200	20	30	10
Gerçek Yok tümör	30	400	50	20
Gerçek Meningiyom	40	10	300	10
Gerçek hipofiz	20	30	20	400

DenseNet'ı değerlendirmek için söz konusu modelin yürütülmesinden elde edilen sonuçlar Çizelge 8'de yer almaktadır.

Çizelge 8 DenseNet Metrik Sonuçları

DenseNet	Tahmini glioma	Tahmini glioma	Tahmini glioma	Tahmini glioma
Gerçek Glioma	200	20	30	10
Gerçek Yok tümör	30	400	50	20
Gerçek Meningiyom	40	10	300	10
Gerçek hipofiz	20	30	20	400


EfficientNetB0:



Şekil 39 EfficientNetB0 Sonuçları

EfficientNetB0'ı değerlendirmek için söz konusu modelin yürütülmesinden elde edilen sonuçlar Şekil 39 yer almaktadır.

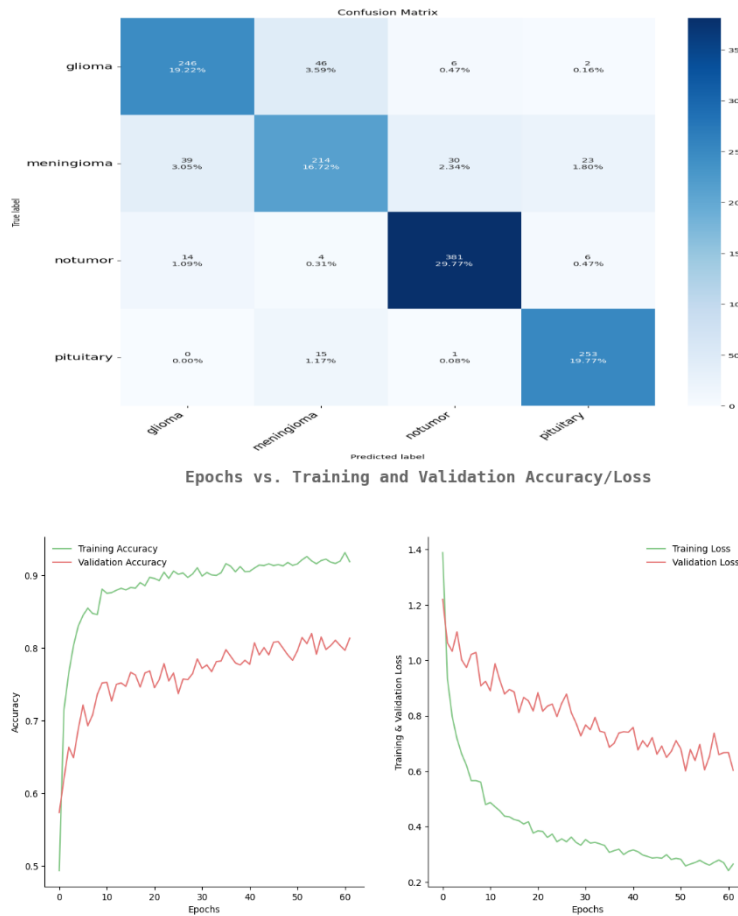
ResNet50:



Şekil 40 Resnet50 Sonuçları

ResNet50'ı değerlendirmek için söz konusu modelin yürütülmesinden elde edilen sonuçlar Şekil 40 yer almaktadır.

InceptionResNetV2:



Şekil 41 InceptionResnetv2 Sonuçları Metrikleri ve Karışıklık Matrisi

Çizelge 9 ResNet50 Metrik Sonuçları

	Kesinlik	Hatırlamak	F1-skor	Destek
Glioma	0.98	0.94	0.95	170
Tümör yok	1.00	1.00	1.00	203
Menenjiyom	0.93	0.96	0.94	174
Hipofiz	0.97	0.98	0.97	156
Kesinlik			0.97	703
Makro Ortalama	0.97	0.97	0.97	703
Ağırlıklı Ortalama	0.97	0.97	0.97	703


ResNet50, model mimarisi sayesinde, katmanlar arasında kısa yolları tanıtarak ağın giderek karmaşık fonksiyonları öğrenmesine olanak tanıyan kalan öğrenmeyi entegre eden model mimarisi sayesinde umut verici sonuçlar göstermektedir. Bu, modelin daha başarılı ve hızlı bir şekilde öğrenmesini sağlar ve görüntü kategorizasyonu gibi görevlerde performansını artırır.

Çizelge 10 Xception Metrics Sonuçları

	Kesinlik	Hatırlamak	F1-skor	Destek
Glioma	0.79	0.82	0.80	170
Tümör yok	0.93	1.00	0.96	203
Menenjiyom	0.79	0.65	0.71	174
Hipofiz	0.88	0.93	0.91	156
Kesinlik			0.85	703
Makro Ortalama	0.85	0.85	0.85	703
Ağırlıklı Ortalama	0.85	0.85	0.85	703

Bir test senaryosu, Xception önceden eğitilmiş modelinin kullanımından sonra karşılaştırma önerilen model mimarisinin ince ayar yapıp yapılmaması ile ilgiliydi ve doğruluk sonuçları sırasıyla 0,8655 ve 0,9446 idi. Önceden eğitilmiş modelin son katmanından önceki son üç katmanın ince ayarının kullanılmasının lehine %8,69'luk bir iyileştirme gözlemlendi. Bu sonuçlar, beyin tümörü sınıflandırması için kullanılan önerilen yöntemlerin kanıtlanması için bu çalışmada seçilmiştir ve araştırmacıların en iyi önceden eğitilmiş modeli ve eklemeli model kombinasyonunu elde etmek için nasıl devam etmeleri gerektiğine dair ipuçları sağlamaktadır.

VGG16 Önceden eğitilmiş model, diğer önceden eğitilmiş modellere göre umut verici sonuçlar ve iyi performans gösterdi. Bu sonuçlar Şekil 42'de ve tabloda görüldü:



Şekil 42 VGG16 Sonuçları Doğruluk ve Kayıp

Çizelge 11 VGG-16 Metrik Sonuçları

	Kesinlik	Hatırlamak	F1-skor	Destek
Glioma	0.99	0.92	0.95	300
Tümör yok	0.92	0.98	0.95	306
Menenjiyom	0.99	1.00	1.00	405
Hipofiz	0.99	0.98	0.98	300
Kesinlik			0.97	1311
Makro Ortalama	0.97	0.97	0.97	1311
Ağırlıklı Ortalama	0.97	0.97	0.97	1311

Bu çalışmadan elde edilen okumalar gösteriyor ki VGG16 Önceden eğitilmiş model, geniş bir görüntü sınıflandırma görevleri yelpazesinde iyi bir performansa sahip olduğu gibi nispeten basit bir mimariye sahiptir. Model, bir dizi evrişimli ve havuzlama katmanından oluşur ve bunu birkaç tam bağlı katman takip eder. VGG16'nın diğer önceden eğitilmiş modellere göre umut verici sonuçlar göstermesinin nedenlerinden biri, modelin verilerden daha fazla özellik öğrenmesine izin veren nispeten büyük bir parametre sayısına sahip olmasıdır (yaklaşık 138 milyon). Ayrıca, daha büyük filtre boyutlarına sahip diğer modellere kıyasla modelin daha ince ayrıntılı özellikler öğrenmesine yardımcı olan 3x3'lük küçük bir evrişim filtresi boyutu kullanır. Ayrıca, çoğul evrişim ve havuzlama katmanları kullanarak, modelin verilerin hiyerarşik bir temsilini öğrenmesine olanak tanır, bu da modelin görüntülerden hem yüksek hem de düşük seviyeli özellikler çıkarmasını sağlar. Başka bir neden, VGG16'nın ImageNet adlı büyük bir veri kümesinde eğitilmiş olmasıdır. Bu veri kümesi, 14 milyondan fazla görüntü ve 1000 farklı sınıf içerir. Bu veri kümesi geniş bir görüntü sınıflandırma görevleri için kullanılır ve üzerinde

eđitilen modeller diđer veri kmeleri ve grevlere iyi genelleme yaparlar. Bu, VGG16'nın ImageNet'te đrendiđi zelliklerin bařka grnt sınıflandırma grevleri iin de kullanıřlı olabileceđi anlamına gelir, bu nedenle genellikle transfer đrenimi iin bir nceden eđitilmiř model olarak kullanılır.

VII. GELECEK ÇALIŞMALAR

Bu bölümde gelecekte yapılacak çalışmaların birkaç fikri daha önceden belirtildi. Model seçimi yapılırken, veri kümesinin niceliğine bağlı olarak daha derin modellere değil, daha basit modellere öncelik verilmesi önerilir. Eğitilmiş modeller kullanılarak doğru MRG beyin tümörü sınıflandırma çalışmaları için gelecekteki çalışmalar birkaç yönde ilerleyebilir. Eğitilmiş modellerin dayanıklılığını ve genelleştirilebilirliğini artırmak için, veri artırma, aktarım öğrenimi ve birleştirme gibi yöntemlerin kullanımı bu kategoride yer alabilir.

Başka bir ilginç araştırma alanı, daha sofistike önceden eğitilmiş modellerin beyin tümörlerinin sınıflandırılmasında uygulanmasının incelenmesi olabilir. ResNet-50 ve EfficientNet gibi modellerin bir aralıkta görüntü sınıflandırma görevlerinde iyi performans gösterdiği göz önüne alındığında, bu araştırmanın bir parçası olabilirler. Farklı ön işlem yöntemlerinin etkilerinin dikkate alınması, beyin tümörlerinin sınıflandırılması için önceden eğitilmiş modellerin etkinliğini etkileyen çeşitli ön işlem yöntemlerinin etkilerinin incelenmesi de faydalı olabilir. Önceden eğitilmiş modellerin performansını artırmak için, resim ölçeklendirmesi, normalleştirme ve gürültü azaltma gibi yaklaşımların incelenmesini gerektirebilir. Önceden eğitilmiş modelleri destek vektör makineleri (SVM'ler) veya karar ağaçları gibi diğer makine öğrenimi yöntemleri ile karıştıran hibrit modeller oluşturmak, beyin tümörü sınıflandırma görevlerinde önceden eğitilmiş modellerin performansını artırmaya yardımcı olabilir. Önceden eğitilmiş modellerin gerçek dünya senaryolarında kullanımının incelenmesiyle ilgili son olarak, önceden eğitilmiş modellerin beyin tümörlerinin sınıflandırılmasında gerçek dünya klinik senaryolarda kullanımını araştırmak ilgi çekici olacaktır. Bu, önceden eğitilmiş modellerin gerçek MRG verilerinde nasıl performans gösterdiğinin incelenmesini ve önceden eğitilmiş modellerin klinik denemelerde kullanılabilirliğinin belirlenmesini gerektirebilir.

VIII. SONUÇ

Beyin tümörü, erken teşhis edilerek tedavi edilmesi gereken en ölümcül hastalıklardan biridir. Manyetik rezonans görüntüleme (MRG) kullanarak tümör tiplerinin sınıflandırılması, kanserlerin karmaşıklığı ve çeşitliliği nedeniyle zor bir iş olabilir. Beyin tümörü hızla genişler ve genellikle boyutu 25 gün içinde iki katına çıkar. Hasta hemen tedavi edilmezse, hayatta kalma şansı sadece %50'dir. Bu çalışmanın amacı, beyin kanseri teşhisi için faydalı bir beyin tümörü MRG veri tabanlı transfer öğrenme aracı oluşturmaktır. Ham veri kümesinin değişken boyutu nedeniyle, görüntü eşikleme, erozyon, genişleme vb. gibi ön işleme prosedürleri uygulanarak istenmeyen gürültü ve aşırı kenarlar ortadan kaldırıldı. Bu çalışmada kullanılan veri seti geniş çapta erişilebilirdir. Aynı veri setlerini kullanan önceki çalışmalar ayrıntılı olarak incelenmiş ve ilgili sonuçlar değerlendirilmiştir. Bu araştırmanın sonuçları, benzer derin öğrenme tekniklerinin makaleleri karşılaştırıldı ve araştırma yolu iyileştirerek daha iyi sonuçlar olarak elde edildi. Sınırlı örneklem büyüklüğü (1086 MR görüntüsü), aşırı uydurmayı önlemek için bu çalışmada veri artırma tekniklerinin benimsenmesini gerektirdi. Önerilen geliştirilmiş ResNet152V2, Xception, ResNet50, NasNetMobile ağları daha sonra iki kez test edildi. Veri artırma tekniklerinin kullanımı, önerilen ağın genel geçerliliğini artırdı. **Gelecek** çalışmalarda, çapraz doğrulama ve diğer sofistike önceden eğitilmiş transfer makine öğrenme modelleri kullanılacaktır.

Beyin tümörlerinin sınıflandırılma süreci, derin öğrenme, makine öğrenmesi ve görüntü işleme tekniklerindeki gelişmelerle daha basit hale gelmiştir. Bu araştırma tezinin amacı, veri setinde bulunan üç farklı beyin tümörünün sınıflandırılması için makine öğrenmesi çerçevelerinin araştırılmasıydı. Taramaların tümü gri monokrom fotoğraflardan oluştuğu için uzman tarafından sınıflandırılması gerekmektedir. MRG kullanılarak menenjiyom, gliom ve hipofiz kanseri arasındaki farklılıklar çeşitli farklı modeller uygulanarak belirlendi. Beyin tümörlerini sınıflandırmak için kullanılan modeller, çeşitli makine öğrenmesi ve derin öğrenme yaklaşımları

kullanılarak deęerlendirilmiřtir ve alıřma tarafından belirlenen karřılařtırma metriklerine gre incelendięinde, VGG16 modelinin nceden eęitilmiř modeller arasında en iyi performansı sergiledięi grlmřtr. Makine ęrenmesinde kullanılan sinir aęı modelleri genellikle zellik ıkarma, veri n iřleme ve sınıflandırma modelinin eęitimi olmak zere  ařamadan oluřmaktadır. Son olarak, aynı konuda gelecekteki geliřmeler iin nerilen birka kavramı belirtmek istiyorum. ereve ve teknikler, veri kmesine gre daha geniř ve daha genel veri kmeleriyle kullanılabilir. Daha fazla fotoęraf veya  boyutlu (3D) teknolojinin kullanımı nerilebilir.

IX. KAYNAKÇA

KİTAPLAR

ALZUBAIDI, L., SANTAMARÍA, J., MANOUFALI, M., MOHAMMED, B., FADHEL, M., ZHANG, J., AL-TIMEMY, A. H., AL-SHAMMA, O., & DUAN, Y. (2021). **MedNet: Pre-trained convolutional neural network model for the medical.**

BALAJI, G., SEN, R., & KIRTY, H. (2022, August 28). **Detection and classification of brain tumors using deep convolutional neural networks.**

FILATOV, D., & AHMAD HASSAN YAR, G. N. (2022). **Brain tumor diagnosis and classification via pre-trained convolutional Neural Networks.** MedRxiv.

KANG, J., ULLAH, Z., & GWAK, J. (2021, March 22). **MRI-based brain tumor classification using ensemble of deep features and Machine Learning Classifiers.** Sensors (Basel, Switzerland).

SCOTT, J. (2022, July 27). **Multiple myeloma and non-hodgkin's lymphoma: Comparison.** Healthline.

TRETKOFF, E. (2006, July). July, 1977: **MRI uses fundamental physics for clinical diagnosis.** American Physical Society.

TZELEPI, M., TEFAS, A., NOUSI, P., & PASSALIS, N. (2022). Chapter 7 - **Lightweight deep learning. In Deep learning for robot perception and cognition** (pp. 131–164). Essay, Academic Press.

VON DEIMLING, A. ED., (2009) "**Gliomas,**" vol. 171, Berlin, Heidelberg: Springer Berlin Heidelberg.

MAKALELER

AGRAVAT, ET AL., (2021) "A Survey and Analysis on Automated Glioma Brain Tumor Segmentation and Overall Patient Survival Prediction," **Archives**

of Computational Methods in Engineering, vol. 28 2021.

- ALNEMER, A. & RASHEED, J. (2021). "An Efficient Transfer Learning-based Model for Classification of Brain Tumor," **2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)**, Ankara, Turkey, pp. 478-482, doi: 10.1109/ISMSIT52890.2021.9604677.
- ALTAMEEM, A. ET AL., (2014) "Medical Image Segmentation Methods, Algorithms, and Applications." **IETE Technical Review**, 31(3): 199–213.
- AMIN, J., SHARIF, M., RAZA, M., & YASMIN, M. (2018) "Detection of Brain Tumor Based on Features Fusion and Machine Learning." **Journal of Ambient Intelligence and Humanized Computing**: 1–17.
- ARIF, M., AJESH, F., SHAMSUDHEEN, S., GEMAN, O., IZDRUI, D., & VICOVEANU, D. (2022). "Brain tumor detection and classification by MRI using biologically inspired orthogonal wavelet transform and deep learning techniques". **Journal of Healthcare Engineering**, 2022, 1–18.
- DANDU, J.R., THIYAGARAJAN, A.P., MURUGAN, P.R. & GOVINDARAJ, V. (2019) "Brain and Pancreatic Tumor Segmentation Using SRM and BPNN Classification," **Health and Technology (Berl)**.: 1–9.
- DEEPA, A.R. & SAM EMMANUEL, W.R. (2018) "An Efficient Detection of Brain Tumor Using Fused Feature Adaptive Firefly Backpropagation Neural Network." **Multimedia Tools and Applications**: 1–16.
- DESPOTOVIĆ, I., GOOSSENS, B., & PHILIPS, W. (2015). "MRI segmentation of the Human Brain: Challenges, methods, and applications". **Computational and Mathematical Methods in Medicine**, 2015, 1–23.
- FILHO, P.P.R., DA SILVA BARROS, A.C., ALMEIDA, J.S., RODRIGUES, J.P.C. & DE ALBUQUERQUE, V.H.C. (2019) "A New Effective and Powerful Medical Image Segmentation Algorithm Based on Optimum Path Snakes." **Applied Soft Computing Journal**, 76: 649–670.
- GIRALDI, G.A., RODRIGUES, P.S., MARTURELLI, L.S. & SILVA, R.L.S. (2005) "Improving the Initialization, Convergence, and Memory Utilization for Deformable Models," in J. Suri, D. Wilson, and S. Laxminarayan (eds)

Handbook of Biomedical Image Analysis. Volume I: Segmentation Models Part A, New York: Kluwer Academic / Plenum Publishers: 359–414.

GORDILLO, N., MONTSENY, E. & SOBREVILLA, P. (2013) “State of the Art Survey on MRI Brain Tumor Segmentation.” **Magnetic Resonance Imaging**, 31 pages: 1427–1437.

HIMMELMANN, K., HORBER, V., DE LA CRUZ, J., HORRIDGE, K., MEJASKI-BOSNJAK, V., HOLLODY, K., & KRÄGELOH-MANN, I. (2016). MRI classification system (MRICS) for children with cerebral palsy: Development, reliability, and recommendations. **Developmental Medicine & Child Neurology**, 59(1), 57–64.

IBRAHIM, R. S., & HACHEM, R. H. (2020). Pediatric cerebellar malformations: Magnetic Resonance diagnostic merits and correlation with neurodevelopmental outcome. **Egyptian Journal of Radiology and Nuclear Medicine**, 51(1).

JAGAN, A. (2019) “A Contemporary Framework and Novel Method for Segmentation of Brain MRI,” in **Proceedings of the International Conference on ISMAC in Computational Vision and Bio-Engineering 2018 (ISMAC-CVB)** 30: 739–747.

K.K.K, M.D.T, & M.S. (2018) “An Efficient Method for Brain Tumor Detection Using Texture Features and SVM Classifier in MR Images.” **Asian Pacific Journal of Cancer Prevention**, 19(10): 2789–2794.

KADAM, A., BHUVAJI, S., & DESHPANDE, S. (2021). Brain tumor classification using Deep Learning Algorithms. **International Journal for Research in Applied Science and Engineering Technology**, 9(12), 417–426.

KANAS, V.G., ZACHARAKI, E.I., DAVATZIKOS, C., SGARBAS, K.N. & MEGALOOIKONOMOU, V. (2015) “A Low-Cost Approach for Brain Tumor Segmentation Based on Intensity Modeling and 3D Random Walker.” **Biomedical Signal Processing and Control**, 22: 19–30.

KAUR, T., & GANDHI, T. K. (2020). Deep convolutional neural networks with transfer learning for Automated Brain Image Classification. **Machine**

Vision and Applications, 31.

- KHAN, H. A., JUE, W., MUSHTAQ, M., & MUSHTAQ, M. U. (2020). Brain tumor classification in MRI image using convolutional neural network. **Mathematical Biosciences and Engineering**, 17(5), 6203–6216.
- KOTROTSOU, A., ZINN, P.O. & COLEN, R.R. (2016) “Radiomics in Brain Tumors,” **Magnetic Resonance Imaging Clinics of North America**, vol. 24, no. 4, pp. 720–728.
- LAVANYADEVI, R., MACHAKOWSALYA, M., NIVETHITHA, J., & KUMAR, A. N. (2017). Brain tumor classification and segmentation in MRI images using PNN. **2017 IEEE International Conference on Electrical Instrumentation and Communication Engineering (ICEICE)**.
- LIM, K.Y. & MANDAVA, R. (2018) “A Multi-phase Semi-automatic Approach for Multisequence Brain Tumor Image Segmentation.” **Expert Systems with Applications**, 112: 288–300.
- MANSI LATHER, DR. PARVINDER SINGH, (2019). “Brain Tumors - Classifications, Symptoms, Diagnosis and Treatments.” **International Conference on Computational Intelligence and Data Science (ICCIDS 2019)**.
- MARTINEZ-BIARGE, M., GROENENDAAL, F., KERSBERGEN, K. J., BENDERS, M. J., FOTI, F., COWAN, F. M., & DE VRIES, L. S. (2016). MRI based preterm white matter injury classification: The Importance of Sequential Imaging in determining severity of injury. **PLOS ONE**, 11(6).
- MONTALT-TORDERA, J., MUTHURANGU, V., HAUPTMANN, A., & STEEDEN, J. A. (2021). Machine learning in Magnetic Resonance Imaging: Image Reconstruction. **Physica Medica**, 83, 79–87
- MUHAMMAD, I. & YAN, Z., (2015). Supervised Machine Learning Approaches: A Survey. **ICTACT Journal on Soft Computing**, 5(3).

- MUSTAQUEEM, A., JAVED, A. & FATIMA, T. (2012) “An Efficient Brain Tumor Detection Algorithm Using Watershed & Thresholding Based Segmentation.” **International Journal Image, Graphics and Signal Processing**, 10: 34–39.
- NANDA, S.J., GULATI, I., CHAUHAN, R., MODI, R. & DHAKED, U. (2018) “A K-Means-Galactic Swarm Optimization-Based Clustering Algorithm with Otsu’s Entropy for Brain Tumor Detection.” **Applied Artificial Intelligence**: 1–19.
- RAJU, A.R., SURESH, P. & RAO, R.R. (2018) “Bayesian HCS-based Multi-SVNN: A Classification Approach for Brain Tumor Segmentation and Classification Using Bayesian Fuzzy Clustering.” **Biocybernetics and Biomedical Engineering**, 38(3): 646–660.
- REID, S. M., DAGIA, C. D., DITCHFIELD, M. R., & REDDIHOUGH, D. S. (2015). Grey matter injury patterns in cerebral palsy: Associations between structural involvement on MRI and clinical outcomes. **Developmental Medicine & Child Neurology**, 57(12), 1159–1167
- ROGOWSKA, J. (2009) “Overview and Fundamentals of Medical Image Segmentation.” in **Handbook of Medical Image Processing and Analysis**, San Diego, USA: Academic Press: 73–90.
- SAPNA VARSHNEY, S., RAJPAL, N. & PURWAR, R. (2009) “Comparative Study of Image Segmentation Techniques and Object Matching Using Segmentation.” in **2009 Proceeding of International Conference on Methods and Models in Computer Science (ICM2CS)**: 1–6.
- SHIVHARE, S.N., SHARMA, S. & SINGH, N. (2019) “An Efficient Brain Tumor Detection and Segmentation in MRI Using Parameter-Free Clustering,” in M. Tanveer and R.B. Pachori (eds) **Machine Intelligence and Signal Analysis**. Advances in Intelligent Systems and Computing 748, Springer Singapore: 485–495.
- SINGH, S., KUMAR, N. & KAUR, N., (2014). Design Anddevelopment Of Rfid

Based Intelligent Security System. **International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)** Volume, 3.

SOBOL, W. T. (2012, October). Recent advances in MRI technology: Implications for image quality and patient safety. **Saudi Journal of Ophthalmology: Official Journal of the Saudi Ophthalmological Society.**

SOMPONG, C. & WONGTHANAVASU, S. (2017) “An Efficient Brain Tumor Segmentation Based on Cellular Automata and Improved Tumor- cut Algorithm.” **Expert Systems with Applications**, 72: 231–244.

SUNEETHA, B. & RANI, A.J. (2018) “Brain Tumor Detection in MR Imaging Using DW-MTM Filter and Region-Growing Segmentation Approach.” in R. S. Bapi, K. S. Rao, and M. V. N. K. Prasad (eds) **First International Conference on Artificial Intelligence and Cognitive Computing: AICC 2018**. Advances in Intelligent Systems and Computing, Springer Singapore: 549–560.

TALWAR, A. & KUMAR, Y., (2013). Machine Learning: An artificial intelligence methodology. **International Journal of Engineering and Computer Science**, 2, pp.3400-3404.

VALVERDE, J. M., IMANI, V., ABDOLLAHZADEH, A., DE FEO, R., PRAKASH, M., CISZEK, R., & TOHKA, J. (2021, April 1). Transfer learning in Magnetic Resonance Brain Imaging: A systematic review. **Journal of Imaging.**

VANKDOTHU, R., HAMEED, M. A., & FATIMA, H. (2022). A brain tumor identification and classification using Deep Learning based on CNN-LSTM method. **Computers and Electrical Engineering**, 101, 107960.

VEERAMUTHU, A., MEENAKSHI, S., MATHIVANAN, G., KOTECHA, K., SAINI, J. R., VIJAYAKUMAR, V., & SUBRAMANIASWAMY, V. (2022). MRI brain tumor image classification using a combined feature and image-based classifier. **Frontiers in Psychology**, 13

VISHNUVARTHANAN, A., RAJASEKARAN, M.P., GOVINDARAJ, V., ZHANG, Y. & THIYAGARAJAN, A. (2017) “An Automated Hybrid

Approach Using Clustering and Nature Inspired Optimization Technique for Improved Tumor and Tissue Segmentation in Magnetic Resonance Brain Images.” **Applied Soft Computing**, 57: 399–426.

VISHNUVARTHANAN, G., RAJASEKARAN, M.P., SUBBARAJ, P. & VISHNUVARTHANAN, A. (2016) “An Unsupervised Learning Method with a Clustering Approach for Tumor Identification and Tissue Segmentation in Magnetic Resonance Brain Images.” **Applied Soft Computing**, 38(C): 190–212.

ZENG, G., GUO, Y., ZHAN, J., WANG, Z., LAI, Z., DU, X., QU, X., & GUO, D. (2021). A review on deep learning MRI reconstruction without fully sampled K-space. **BMC Medical Imaging**, 21(1).

ZHANG, Y., SUN, Y., PHILLIPS, P., LIU, G., ZHOU, X. & WANG, S. (2016) “A Multilayer Perceptron Based Smart Pathological Brain Detection System by Fractional Fourier Entropy.” **Journal of Medical Systems**, 40(7).

ELEKTRONİK KAYNAKLAR

“**Brain Tumors Classifications, Symptoms, Diagnosis and Treatments**, <https://www.aans.org/Patients/Neurosurgical-Conditions-and-Treatments/Brain-Tumors>.

AMERICAN ACADEMY OF DERMATOLOGY ASSOCIATION. (n.d.). **Types of skin cancer**. American Academy of Dermatology.

AMERICAN BRAIN TUMOR ASSOCIATION. (2022, August 11). **Brain tumor faqs - learn more or donate today!:** ABTA. American Brain Tumor Association.

BRIGHAM AND WOMEN'S HOSPITAL. (n.d.). **What is Meningioma?** Meningioma Brain Tumors - Brigham and Women's Hospital.

BROWN, R. (2019, November 28). **What is the difference between image segmentation and classification in image processing?** Medium.

BROWN, S. (2021, April 21). **Machine Learning, explained**. MIT Sloan.

BURNS, E. (2021, March 30). **What is machine learning and why is it important?** Enterprise AI.

CANCER COUNCIL. (n.d.). **Liver cancer: Causes, symptoms & treatments**.

Cancer Council.

CANCER RESEARCH UK. (2022, March 15). **Prostate cancer**. Prostate cancer | Cancer Research UK.

CDC. (2022, June 6). **Kinds of cancer**. Centers for Disease Control and Prevention.

Cleveland Clinic Medical Professional. (2022, November 14). **Head and neck cancer: Symptoms, causes & treatment**. Cleveland Clinic.

Cleveland Clinic. (n.d.). Brain tumor: Symptoms, signs & causes. Cleveland Clinic.

Endocrine Society. (2022, March 31). **Pituitary tumors**. Endocrine Society.

GARET, L. (2020, December 26). **History of MRIs and the evolution of this life-saving technology**. Ezra.

Geeks for Geeks. (2022, November 30). **What is algorithm: Introduction to algorithms?** Geeks for Geeks.

GILLIS, A. S. (2022, May 19). **What is an algorithm?** - definition from whatis.com. WhatIs.com.

GILLIS, A. S. (2022, May 19). **What is an algorithm?** - Definition from whatis.com. WhatIs.com.

Glioblastoma Research Organization. (n.d.). **About Glioblastoma**. Glioblastoma Research Organization.

HEGAZI, T. M., & WU, J. S. (2019). **Miscellaneous**. Springer, Cham.

IBM. (2018, June 23). What is LSF?

JOHNS HOPKINS MEDICINE. (N.D.). **Gynecologic cancers**. Gynecologic Cancers | Johns Hopkins Medicine.

KUMARI, R. (2020, December 2). **What is an algorithm?** Types, applications, and characteristics. Analytics Steps.

MARKMAN, M. (2022, June 8). **Brain tumor diagnosis & how to test for cancer**. Cancer Treatment Centers of America.

Mayo Clinic. (2022, April 19). **Bladder cancer**. Mayo Clinic.

Mayo Clinic. (2022, December 14). **Breast cancer**. Mayo Clinic.

MedlinePlus. (2021, June 19). **Lung Cancer | Lung Cancer symptoms.**
MedlinePlus.

Mesothelioma.com. (2022, October 6). **Mesothelioma cancer: Causes, diagnosis, life expectancy & treatment.** Mesothelioma.com.

Musella Foundation. (n.d.). **Brain tumor symptoms. Brain Tumor Symptoms.**

MYERS, A. (2021, May 17). **Can ai create faster, more reliable MRI scans?**
Stanford HAI.

NCI. (2021, May 5). **What is cancer?** National Cancer Institute.

NHS. (2021, December 2). **Causes -Cervical cancer.** NHS choices.

NIBIB. (n.d.). **Magnetic Resonance Imaging (MRI).** National Institute of Biomedical Imaging and Bioengineering.

Pasadena CyberKnife Center. (n.d.). **Brain cancer types & stages: Pasadena cancer center.** Pasadena CyberKnife Center.

Patient Engagement Synapse. (n.d.). **Condition - thyroid cancer.** Patient Engagement Synapse.

Radiological Society of North America and ACR. (2022, December 6). **Magnetic Resonance Imaging (MRI) - body.** Radiologyinfo.org.

Radlib. (2021, September 25). **Featured history: Magnetic resonance imaging.**
UW Radiology.

The American Cancer Society Medical and Editorial Content Team. (2020, June 29). **What is colorectal cancer?: How does colorectal cancer start?**
American Cancer Society.

The American Cancer Society Medical and Editorial Content Team. (2020, May 5). **What is kidney cancer?** American Cancer Society.

VGG-16 convolutional neural network. (n.d.). **Deep Network designer.** VGG-16 convolutional neural network - MATLAB.

WHELAN, S. (2022, August 16). **Benign vs malignant tumors.** Cancer Research from Technology Networks.

WHO. (2022, February 3). **Cancer.** World Health Organization.

ÖZGEÇMİŞ

Ad Soyad: Alaa ALNEMER

Eğitim Bilgileri:

2014 -2019 İstanbul Üniversitesi Bilgisayar Mühendisliği Bölümü

Profesyonel Deneyim:

2019 – 2022 A. Arge Tekn. Müh. San. Tic. Ltd. Şti. - Çözüm mimarı

2019 – 2020 International Partners Plastik İnş. San. ve Tic. A.Ş. – Ürün yönetici

2018 – 2019 Strateji Geliştirme Müdürlüğü Küçükçekmece Belediyesi - Kıdemli
Yazılım Geliştirici

2015 – 2011 Strateji Geliştirme Müdürlüğü Küçükçekmece Belediyesi - Yazılım
Çözümleri Danışmanı

Diller:

- Arapça: Ana Dil

- Türkçe: İkinci Dil

- İngilizce: İkinci Dilli

Yetenekler:

Takım liderliği, Yaratıcılık, Eleştirel Düşünme, Dijital ürün, Müzakere, Ürün Yönetimi, Topluluk Önünde Konuşma, Altyapı, Problem Çözme, Kişilerarası Beceriler, Çatışma Çözümü, Makine Öğrenimi, Stratejik Planlama.