

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



BEYİN TÜMÖRLERİNİN CNN ALGORİTMASI YARDIMIYLA
TESPİT EDİLMESİ

YÜKSEK LİSANS TEZİ

Hasan BAŞYILDIZ

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

AĞUSTOS, 2022

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



BEYİN TÜMÖRLERİNİN CNN ALGORİTMASI YARDIMIYLA
TESPİT EDİLMESİ

YÜKSEK LİSANS TEZİ

Hasan BAŞYILDIZ
(Y1913.010022)

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Tez Danışmanı: Dr. Öğr. Üyesi PERİ GÜNEŞ

AĞUSTOS, 2022

ONAY FORMU



ONUR SÖZÜ

Yüksek Lisans tezi olarak sunduğum “BEYİN TÜMÖRLERİNİN CNN ALGORİTMASI YARDIMIYLA TESPİT EDİLMESİ” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça ’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (21/07/2022)

Hasan BAŞYILDIZ

ÖNSÖZ

Bu çalışmada, Beyin Tümörlerinin Tezi Cnn Algoritması Yardımıyla Tespit Edilmesi vakit alan ve beşerî hatalara açık bir yöntemdir. Bu nedenle görüntü işleme yöntemleri yardımı ile yer işareti implantasyonu esnasında geçen süreyi ve bu işlem sırasında oluşabilecek beşerî hata payını mümkün olan en aza indirmek için bir yöntem önerilmesi amaçlanmaktadır.

Bu bilimsel çalışmamın gerçekleştirilmesinde uzun süre boyunca değerli bilgilerini benimle paylaşan, saygıdeğer Dr. Öğr. Üyesi PERİ GÜNEŞ hocama teşekkür ederim.

Çalışmanın başladığı günden bitimine kadar bana her konuda desteğini esirgemeyen tüm hayatım boyunca aldığım kararları her zaman destekleyen, hatalarımı düzelten, sadece bu çalışma sürecinde değil tüm hayatım boyunca ve bu çalışmamda çok büyük emeği olan anneme, tez çalışmamı hazırlarken her zaman yanımda kalan sevgili eşime Hannen'e, uzaktan bana destek veren takip eden babama, çalışmamda yardım eden kardeşlerim Ayhan, Ömere ve tüm arkadaşlarıma teşekkürlerimi bir borç bilirim.

Ağustos,2022

Hasan BAŞYILDIZ

BEYİN TÜMÖRLERİNİN CNN ALGORİTMASI YARDIM İLE TESPİT EDİLMESİ

ÖZET

Beyin Tümörü segmentasyonu, tıbbi görüntü işleme alanındaki en önemli ve zorlu görevlerden biridir, çünkü insan destekli manuel sınıflandırma yanlış tahmin ve teşhise neden olabilir. Ayrıca, manuel olarak işlenecek büyük miktarda veri olduğunda sıkıcı bir görev haline gelir. Hasta için hoş olmayan sonuçlara yol açan değerlendirilmesi zor olabilen birden fazla Beyin Tümörü türü vardır. Bu nedenle beyin tümörünün tespiti ve tedavi planlaması süreçteki en önemli faktördür. Manyetik rezonans görüntüleme (MRI), beyin tümörlerini değerlendirmek için yaygın olarak kullanılan bir tekniktir. Beyin tümörünün MRI'dan manuel olarak segmentasyonu daha fazla zaman alır ve makine öğrenimine bağlıdır. Bu nedenle, tedavi planlamasını kolaylaştırmak için segmentasyon için otomatik teknikler gerekir. Beyin tümörlerinin çeşitli türleri nedeniyle segmentasyon için otomatik yöntemlerde neredeyse hiç kolay değildir. Bu nedenle, beyin tümörü segmentasyonu için, tümörleri etkin bir şekilde ve daha az zaman alıcı olarak rahatlatılabilen güvenilir bir yöntemle sahip olmak gerekir. Bu çalışmanın amacı, tümörlü ve tümörsüz 253 MR görüntüsünden oluşan bir veri seti kullanılarak, MaskR-CNN ile tümörlerin yeri ve boyutu tespit edilerek %88-94 doğruluk oranı elde edilmiştir.

Anahtar kelimeler: Evrişimsel Sinir Ağı, Beyin Tümörü, Maske R-CNN, Tespit, MR

DETECTION OF BRAIN TUMORS WITH THE HELP OF CNN ALGORITHM

ABSTRACT

Brain Tumor segmentation is one of the most important and challenging tasks in the field of medical image processing because human-assisted manual classification can lead to inaccurate prediction and diagnosis. Also, it becomes a tedious task when there is a large amount of data to be processed manually. There are multiple types of Brain Tumors that can be difficult to assess with unpleasant consequences for the patient. Therefore, detection of brain tumor and treatment planning are the most important factors in the process. Magnetic resonance imaging (MRI) is a widely used technique to evaluate brain tumors. Manual segmentation of a brain tumor from MRI takes more time and is dependent on the experience of the mechanic. Therefore, automated techniques for segmentation are required to facilitate treatment planning. Because of the various types of brain tumors, automated methods for segmentation are almost never easy. Therefore, it is necessary to have a reliable method for brain tumor segmentation that can relieve tumors effectively and in less time. In this study, using a dataset consisting of 253 MR images with and without a tumor, and the location and size of the tumors were detected with MaskR-CNN, an accuracy rate of 88%-94% was obtained.

Keyword: Convolutional Neural Network, Brain Tumor, Mask R-CNN , Detection, MR

İÇİNDEKİLER

Sayfa

ONUR SÖZÜ.....	i
ÖNSÖZ	ii
ÖZET	iii
ABSTRACT.....	iv
İÇİNDEKİLER.....	v
KISALTMALAR LİSTESİ.....	viii
ÇİZELGELER LİSTESİ.....	ix
ŞEKİLLER LİSTESİ	x
I. GİRİŞ.....	1
II. LİTERATÜR TARAMASI.....	3
III. METODLAR VE MATERYERLER.....	11
A. Beyin.....	11
B. Beyin Tümörü	11
1. Glioma.....	13
2. Meningiom tümörü	13
3. Hipofiz Tümörü (Pituitary Tumor)	13
4. Sinir Kılıfı Tümörleri (Schwannomalar)	13
5. Merkezi Sinir Sistemi (MSS) lenfoma.....	13
C. Tıbbi Görüntüleme Teknikleri.....	14
1. Magnetic Resonance Imaging.....	15
2. Manyetik R Enine Ezonans.....	16

3. Gevşeme.....	17
D. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme	18
1. Yapay Zeka	18
2. Makine Öğrenmesi.....	18
3. Tıbbi Görüntü Analizinde Makine Öğrenimi	19
4. Beyin Tümörü Segmentasyonu için Görüntü İşleme.....	19
5. Ön İşleme:	19
6. Makine Öğrenimi Sınıflandırma algoritmaları	22
a. K-En Yakın Komşu	23
b. Lojistik regresyon	23
c. Çok Katmanlı Algılayıcı (MLP).....	24
d. Naive Bayes	24
e. Random Forest (Rastgele Orman)	25
f. Destek Vektör Makinesi (SVM).....	25
7. Derin Öğrenme.....	26
a. Yapay Sinir Ağı	26
b. Evrişimsel Sinir Ağı (CNN)	27
c. R-CNN.....	29
d. Fast R-CNN	29
e. Faster R-CNN	30
f. Mask R-CNN (Bölgesel tabanlı Evrişimsel Sinir Ağı) :	30
IV. YÖNTEM.....	32
V. DENEYSEL SONUÇLAR	34
A. Veri Seti Hazırlama	35
VI. GELECEKTE YAPILABİLECEK ÇALIŞMALAR	40
VII.SONUÇ	41

VIII. KAYNAKÇA	42
ÖZGEÇMİŞ	49



KISALTMALAR LİSTESİ

AI	: Yapay Zeka
CNN	: Evrişimli Sinir Ağları
CT	: Bilgisayarlı Tomografi
ESA	: Evrişimsel Sinir Ağları
Fast R-CNN	: Hızlı Bölge Tabanlı Evrişimli Sinir Ağı
FCM	: Fuzzy C-Means Clustering
KNN	: K-En Yakın Komşu
KNN	: K-En Yakın Komşu
MLP	: Çok Katmanlı Algılayıcı
MRF	: Markof Rastgele Alanı
MRI:	: Manyetik Rezonans Görüntüleri
NMV	: Net Manyetizasyon Vektörü
PCA	: Temel Bileşen Analizi
PET	: Pozitron Emisyon Tomografisi
RELU	: Doğrultulmuş Lineer Birim
SVM	: Destek Vektör Makinesi

ÇİZELGELER LİSTESİ

Sayfa

Çizelge 1. Önerilen ML ve CNN modeli Arasındaki Performans Karşılaştırması	3
Çizelge 2. Beyin tümörü veri setini kullanan en gelişmiş yöntemlerle karşılaştırma.....	4
Çizelge 3. Algoritmaların karmaşıklık matrisleri ve genel başarı durumları	6
Çizelge 4. Farklı Kapsül sınır ağ mimarilerine dayalı beyin tümörü sınıflandırma doğruluğu	6
Çizelge 5. Önerilen yöntem ile üç farklı performans karşılaştırılması.....	7
Çizelge 6. Test veri setinde önerilen yöntemin ortalama beş kat genel sınıflandırma performansı.	8
Çizelge 7. BRATS 2013 veri setini kullanan diğer yöntemlerle karşılaştırma	8
Çizelge 8. CEMRI veri setinde önerilen ve en son yöntemler arasında doğruluk karşılaştırması.....	9
Çizelge 9. Önerilen çalışmada kullanılan Veri seti	35

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.	Tümör Görünümü	1
Şekil 2.	MR görüntülerinde beyin tümörlerinin türleri: a) kötü huylu tümör; b) iyi huylu tümör	12
Şekil 3.	Atom çekirdeğinin manyetik momenti	16
Şekil 4.	MKG Temel parçaları.....	17
Şekil 5.	Yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi.....	18
Şekil 6.	nesnenin arka plandan bölümlere ayrılması	21
Şekil 7.	bulanık kümeleme parçalara ayrılmış görüntü	22
Şekil 8.	. KNN algoritması.....	23
Şekil 9.	lojistik regresyon	24
Şekil 10.	Yapay sınır ağı.....	26
Şekil 11.	Özellik Haritası Çıkarma Adımı.....	27
Şekil 12.	Max Pooling işlemi örnek uygulaması	28
Şekil 13.	Tam bağlantı katmanı yapısı	29
Şekil 14.	R-CNN Çalışma Yapısı.....	29
Şekil 15.	Fast R-CNN Çalışma Yapısı.....	30
Şekil 16.	Faster R-CNN Çalışma Yapısı	30
Şekil 17.	Maske R-CNN'nin Genel Yapısı	31
Şekil 18.	VIA görüntü açıklayıcı yazılımı ile bir görüntü için gerçek referans maskesi oluşturma	33
Şekil 19.	CNN Algoritmasında kullanılan örnek veri rerimleri	34


Şekil 20. CNN Algoritması ile elde edilen loss ve accuary değerlerinin grafikleri.....	35
Şekil 21. VIA aracı ile kenar belirleme.....	36
Şekil 22. Loss değerleri	37
Şekil 23. loss değerinin grafiği.....	37
Şekil 24. Eğitim sayısı 10'iken İki farklı görüntünün maskernn beyin tümör tespiti ve tahmin değeri	38
Şekil 25. Loss değerleri	38
Şekil 26. loss değerinin grafiği.....	39
Şekil 27. Eğitim sayısı 15'iken İki farklı görüntünün maskernn beyin tümör tespiti ve tahmin değeri	39

I. GİRİŞ

Dijital sağlık içerisinde tanı ve tedavi amacıyla insan vücudunun farklı organların görüntülerini çıkartmak için tıbbi görüntüleme yöntem ve süreçleri kullanılmaktadır. MRI, beynin yumuşak dokuları ve omuriliği de dahil olmak üzere vücudun içinin herhangi bir düzlemde ayrıntılı görüntülerini sağlayan bir tekniktir. Öncelikle vücudun yapısını ve işlevini görselleştirmek için kullanılmaktadır. (Pedapati ve Tannedi 2018).

İnsan beyni, insan vücudunun her hareketini kontrol ettiği için vücudun en mühim organlarından birisidir. Enfeksiyonlar, felçler ve tümörler gibi birçok hastalık beyni zarar vermektedir. Ayrıca, bir beyin tümörü, beyindeki kanserli veya kanser olmayan bir kitle veya anormal hücrelerin büyümesidir. MRI, beyin tümörünü tespit etmek için en mühim bir tekniktir. Son dönemlerde, büyük miktarda verinin etkili ve nesnel olarak değerlendirilmesi ihtiyacı sebebiyle MRI taramalarının tıbbi görüntü incelemesi dikkat çekmeye başlamıştır (Bauer ve ark. 2013).

Tümörlerin görünümü, boyut, şekil ve konum açısından farklıdır. Ayrıca, bu tümörler ya hipointens (beyin dokusundan daha koyu), izointens (beyin dokusu ile aynı yoğunlukta) veya hiperintens (beyin dokusundan daha parlak) olarak görünmektedir. (Rachana, R, vd., 2013).



Şekil 1. Tümör Görünümü

Kaynak: (Rachana, R, vd., 2013).

Beyin tümörleri temelde birincil (primer) ve ikincil (seconder) olmak üzere ikiye ayrılmaktadır. Birincil tümörler, tıpkı oluştukları organdan veya dokuya ait olanlar gibi hücrelerden oluşmaktadır. Birincil beyin tümörü beyin hücrelerinden başlamaktadır. Küçük yaştaki hastalarda beyin tümörlerinin çoğu birincildir ve tüm birincil tümörlerin en az yarısı, vücudun sinir sistemini destekleyen beyin hücrelerinden kaynaklamaktadır (Glass-Macenska, D. vd., 2013).

İkincil tümörler, vücudun farklı bir bölümünden bir veya daha fazla alana dağılmış hücrelerden oluşmaktadır. İkincil beyin tümörleri aslında osteosarkom (birincil kemik tümörü) veya rabdomyosarkom (birincil kas tümörü) gibi vücudun bir bölümünden diğerine geçmiş veya beyine yayılmış kanser hücrelerinden oluşur.

Bu lezyonlar oldukça iyi tanımlanmış olma eğilimindedir ve ameliyatla daha kolay çıkarılmaktadır (Glass-Macenska, D. vd., 2013).

II. LİTERATÜR TARAMASI

Mohsena Ashraf ve arkadaşları, Çalışmalarında hem geleneksel sınıflandırıcılar hem de derin öğrenme yöntemleri tarafından takip edilen Fuzzy C-Means kümeleme algoritması ile 2D Manyetik Rezonans beyin Görüntülerinden (MRI) beyin tümörü yerini tespit etmek için model geliştirdiler. Deneysel çalışma, farklı tümör konumları, genişliği, şekilleri ve farklı görüntü yoğunlukları ile gerçek zamanlı bir veri seti üzerinde yapıldı.

Geleneksel sınıflandırıcı bölümünde altı geleneksel sınıflandırıcı uygulamışlardır, Bunlar ise Destek Vektör Makinesi (SVM), K-En Yakın Komşu (KNN), Çok Katmanlı Algılayıcı (MLP), Lojistik Regresyon, Naive Bayes ve Rastgele Orman. Bu sınıflandırıcılar aralarında en iyi sonuç veren SVM olmuştur. Ondan sonra, geleneksel sınıflandırıcılara göre performansta bir gelişme gösteren Evrişimli Sinir Ağı'na (CNN) geçiş yaptılar. Geleneksel sınıflandırıcıların sonucunu CNN'nin sonucuyla karşılaştırdılar. Geleneksel sınıflandırıcıların ve CNN'nin sonuçlarını karşılaştırdı.

Ayrıca performans değerlendirmesi, CNN ve geleneksel sınıflandırıcıların bölünmüş oranı birden çok kez değiştirilerek denenmiştir. Ayrıca sonucumuzu segmentasyon tespiti açısından mevcut araştırma çalışmalarıyla karşılaştırdı ve birçok modern yöntemden daha iyi sonuçlar elde etti. Geleneksel sınıflandırıcı kısmı için, Destek Vektör Makinesi (SVM) ile elde edilen %92.42'lik bir doğruluk elde ettiler ve CNN, %97.87'lik bir doğruluk vermiştir (Mohammed, E. vd 2015).

Çizelge 1. Önerilen ML ve CNN modeli Arasındaki Performans Karşılaştırması

Model	Bölme Oranı	Doğruluk (%)
Geleneksel Sınıflandırıcılar	70:30	92.42
	80:20	88.63
CNN	70:30	96,55
	80:20	97.87

Naghsh ve arkadaşları yaptıkları çalışmada, ROI algılama yöntemi sunulmuştur. İlk bölümde, morfolojik işlem, alçak geçiren filtreleme, eşikleme ve

etiketleme gibi farklı görüntü işleme araçlarının sıralı kombinasyonu kullanılarak tıbbi bir ROI tespit yöntemi önerilmiştir. Kullanılan yöntem, farklı kalitede ve boyut 746 tıbbi görüntü içeren DICOM formatındaki on veri tabanına uygulanmaktadır. İkinci aşama yedi çeşit filtreyi tanıtmakta ve tıbbi görüntüler üzerindeki etkilerini göstermektedir. Daha sonra bu filtreleri uygulandıktan sonra önerilen ROI tespit sisteminin Dayanaklığı incelenir. Bu amaçla filtreden önce ve filtreden sonra belirlenen ROI köşeleri karşılaştırılmış ve çoğu zaman segmentasyon yönteminin ROI için benzer koordinatlar üretmediği ve sistemin kabul edilebilir sonuçlar göstermediği tespit edilmiştir.

Yapılan çalışmanın üçüncü aşamada, çeşitli filtrelerden önce ve sonra benzersiz ROI köşeleri üretmek için önerilen ROI algılama algoritması için 'Window Size Correction' adı verilen ek bir blok önerilmiştir. Önerilen ek adım, karşılaştırmalı doğruluk sonuçlarını arttırmaktadır. Oranını göstermek için, iyileştirme öncesi ve sonrası karşılaştırmalı doğruluk araçları birbirleriyle karşılaştırıldı ve on farklı veri setinden ortalama %98.48 başarı elde edilmiştir (Naghsh, A. vd 2015).

Muhammad Sajjad ve arkadaşları, yeni bir evrimsel sinir ağı (CNN) tabanlı çok dereceli beyin tümörü sınıflandırma yöntemi önerdiler. Başta, bir MR görüntüsündeki tümör bölgeleri derin öğrenme tekniği kullanılarak bölümlere ayrılır. sonra, sistemi etkili bir şekilde eğitmek için kapsamlı veri büyütme kullanılır ve çok dereceli beyin tümörü sınıflandırması için MRI ile uğraşırken veride eksik problemini ortadan kaldırılır. Son olarak, önceden eğitilmiş bir CNN modeli, beyin tümörü derece sınıflandırması için artırılmış veriler kullanılarak ayrıntılı ayar yapmaktadır. Önerilen sistem, hem çoğaltılmış hem de orijinal veriler üzerinde deneysel olarak değerlendirilmiştir ve sonuçlar, mevcut yöntemlere göre daha iyi sonuç vermektedir (Sajjad M, Khan vd 2019).

Çizelge 2. Beyin tümörü veri setini kullanan en gelişmiş yöntemlerle karşılaştırma.

Yöntem	Duyarlılık (%)	Özgüllük (%)	Doğruluk (%)
Afshar, P. vd (2018)	-	-	86.56
Zia, R. vd (2018)	86.26	90.90	85.69
Muhammad, K. vd ve (2018)	81	92	91.28
Önerilen Yöntem	88.41	96.12	94.58

Ibrahim, W. H ve arkadaşları Sinir Ağı tekniği önerdiler, önerilen yöntem üç aşamadan oluşmaktadır bular ise ön işleme, boyut azaltma ve sınıflandırmadır. İlk olarak, MR görüntüsünü elde edilmiştir ve veri formuna dönüşülmüştür, ikinci aşamada, Temel Bileşen Analizi (PCA) kullanarak boyutsal olarak küçültmeyi elde edilmiştir, daha sonra sınıflandırma aşamasında, Geri Yayılımlı Sinir Ağı, normal veya anormal MRI beyin görüntüleri olarak sınıflandırmak için bir sınıflandırıcı olarak kullanılmıştır. Denemed, önerilen yöntemin renklendirilmesi ve test edilmesi için MRI Beyin sayısal görüntülerinin (sequence01) 3×58 veri seti kullanılmıştır. Önerilen tekniğin sonucunda, temel algoritmaların sonuçları ile karşılaştırılmış ve kalite açısından rekabetçi sonuçlar olarak geçerlilik sunmuş ve yöntemimizin sınıflandırma doğruluğunun %96.33 olduğunu göstermiştir (Ibrahim, W. H vd, 2013).

Ghosh ve arkadaşları çalışmalarında, Önerilen yöntem bulanık k-ortalamar kümeleme algoritması hastaların MRI görüntüleri ile tümör kısmını çıkarmada başarılı olmuşlardır; bir sınırlama kutusu yardımıyla tümörün doğru görsel konumu ile birlikte tümörün sınırının doğru bir şekilde tespiti yapılmıştır. Ayrıca tümörün tam genişliği ile birlikte tümörün var olup olmadığı konusunda bir tanı kararı sağlamıştır. Beyindeki ve diğer beyinle ilgili alanlardaki farklı tümör tiplerini sınıflandırdı ve başarılı sınıflandırma oranı %89.2'dir (Ghosh, D. vd ,2017).

Bulut ve arkadaşları yapış oldukları çalışmada, yaygın bir hastalık olan beyin tümörünü tespit etmek için görüntü işleme yöntemleri kullanılmıştır. Manyetik rezonans görüntülerde (MRI) beyin tümörleri, görüntü segmentasyon algoritmaları kullanılarak tespit etmişlerdir. Çalışmada kullanılmak üzere beyin tümörleri MR görüntüleri izin alarak devlet hastanelerinden alınmıştır.

MR görüntülerinde beyin tümörleri Markov rastgele alanı (MRF), Kapur, Kittler ve Otsu algoritmaları ile tespit edilmeye çalışmaktadır. Algoritmalar, MR görüntülerinin belirli bölgelerinde (ROI – İlgi Bölgesi) ayrı ayrı test etmiştir. Deneysel uygulamalarda Markov Rastgele Alan (MRF) algoritması diğer algoritmalara göre daha iyi sonuçlar vermektedir. Yaptığı çalışmada Markov Rastgele Alan algoritması 87 doğruluk oranı vermiştir (Bulut F. vd , 2018).

Çizelge 3. Algoritmaların karmaşıklık matrisleri ve genel başarı durumları

Otsu	Kapur	Kittler	MRV
TPR=0,722	TPR=0,611	TPR=0,833	TPR=0,944
FPR=0,600	FPR=0,400	FPR=0,400	FPR=0,200
Acc=0,652	Acc=0,608	Acc=0,782	Acc=0,870

Mohammad ve arkadaşları, yapmış olduğu çalışmanın özel ilgi alanı, Kapsül Sinir ağlarının rotasyona ve afin dönüşüme karşı stabil olması ve beyin Manyetik Rezonans Görüntüleme (MRI) görüntüleri dahil tıbbi görüntü veri setlerinin işlenmesinde olduğu gibi çok daha az eğitim verisi gerektirmesidir. önerilen yöntem , aşağıdaki dört hedefe ulaşmaya çalışılmıştır : 1. Eldeki sınıflandırma sorunun doğruluğunu en üst seviyeye çıkaran gelişmiş bir mimari hazırlamak için beyin tümörü sınıflandırma sorunu için CapsNet'i kullanıldı ve birleştirildi; 2. Gerçek bir MRI görüntüleri kümesine dayalı olarak CapsNets'in aşırı uyum gösterme sorununu incelenmiştir; 3. CapsNets'in tüm beyin görüntülerine mi yoksa sadece segmentli tümöre mi daha iyi uyum sağlayıp sağlayamayacağını araştırmaktadır; 4. öğrenmiş olduğu özellikleri daha iyi anlatmak için CapsNet'in çıktısı için bir görselleştirme paradigması geliştirilmiştir. Yapılan çalışmanın sonucu, önerilen yaklaşımın beyin tümörü sınıflandırma sorunu için CNN'lerin başarılı bir şekilde sonuç vermiştir. Beyin tümörlerinin sınıflandırılmasında %86,56 doğruluk oranı elde edilmiştir (Mohammadi A. vd ,2018).

Çizelge 4. Farklı Kapsül sınır ağ mimarilerine dayalı beyin tümörü sınıflandırma doğruluğu

Kapsül Sınır Ağ	Doğruluk
Orijinal	82.30%
Her biri 64 özellik haritasına sahip iki evrişim katmanı	81.97%
64 özellik haritasına sahip bir evrişimsel katman	86.56%
64 özellik haritası, 16 birincil kapsül içeren evrişim katmanı	83.61%
64 özellik haritası ve 4 boyutlu 32 birincil kapsül içeren bir evrişim katmanı	82.30%
1024, 2048 ve 4096 nöronlu üç tam bağlantılı katman	83.93%

Ergin ve arkadaşları yapmış olduğu çalışmada, MR görüntüleri kullanılarak görüntüde beyin tümörü olup olmadığı belirlenmiş onda sonra tümörlü test görüntülerinde tümör yeri K-means Kümeleme Yöntemi ile bölümlenmesi ve görüntülenmesi gerçekleştirilmektedir. Önerilen çalışmada %84,45 doğruluk ve %95.04 duyarlılıkla beyin tümörü tespit edilmiştir. Tespit edilen beyin tümörü içeren görüntülerde segmentasyon başarıyla gerçekleştirildi. Çalışma ile tam otomatik tümör tespiti ve segmentasyonu yapılarak hastalık tedavisinin daha kolay planlanması amaçlanmıştır (Tas, M. O. vd, 2020).

Çizelge 5. Önerilen yöntem ile üç farklı performans karşılaştırılması

Yöntem	Doğruluk	Duyarlılık	F1 Puanı
Damadoran ve Raghavan (2015)	83.00%	100%	-
Akkuş ve diğerleri (2016)	87.70%	93.30%	-
Hussain ve diğerleri (2017)	-	82.00%	80.00%
Soltaninejad ve diğerleri (2018)	-	96.00%	89.00%
Thaha ve diğerleri (2019)	92.00%	90.00%	-
Önerilen yöntem	84.45%	95.04%	87.92%

Swati ve arkadaşlarının yapmış oldukları çalışmada, transfer öğrenme ve ince ayara dayalı beyin tümörü görüntü sınıflandırması için yeni bir yöntem önermektedir. Blok bazında ince ayar ile önerilen transfer öğrenme stratejisi, ayrı sınıflandırma yöntemini (k- en yakın komşular, Destek Vektör Makineleri, Güçlendirilmiş Ağaçlar, Karar Ağaçları ve Rastgele Orman). Aynı zamanda doğal görüntülerden tıbbi beyin MR görüntülerine öğrenmenin aktarılabilişliğini de gösterir. Önerilen yöntem, diğer vücut organ MRI görüntüleri ve MRI , PET ve CT gibi diğer tıbbi görüntüleme alanları için sınıflandırma sistemi iyileştirmek için kullanılmaktadır. Swati ve arkadaşları önerdikleri Yöntemdaha geneldir çünkü 2D MR görüntüleri için az ön işleme ile yapılır ve el yapımı özellikler kullanmaz. Yapılan Deneysel sonuçlarda, önerilen yöntemin yalnızca son teknoloji ürünü geleneksel makine öğrenme yönteminden daha iyi performans göstermediğini, aynı zamanda aynı CE-MRI veri kümesinde son teknoloji CNNs algoritmalarından daha iyi sonuç verdiğini gözlemlenmiştir (Swati, Z. N. K. vd ,2019).

Çizelge 6. Test veri setinde önerilen yöntemin ortalama beş kat genel sınıflandırma performansı.

Fine-tuning	Geri çağırma	Özgüllük	Kesinlik	F1 puanı	Doğruluk
FT: B1-B6	94.25	94.69	89.52	91.73	94.82
FT: B2-B6	94.26	94.56	89.20	91.52	94.66
FT: B3-B6	94.04	94.21	88.23	90.93	94.26
FT: B4-B6	93.38	93.7	87.47	90.19	93.78
FT: B5-B6	91.50	91.85	83.99	87.40	91.92
FT: B6	84.76	86.35	76.10	79.18	86.81

Soltaninejad ve arkadaşları, Çok modlu MRI beyin görüntülerinde tümörün segmentasyonu için denetimli eğitim temelli bir yöntem önermişlerdir. Süpervokseller, multimodal MRI görüntülerinden bilgi tümleştirme yöntemi kullanılarak hesaplamıştır. Farklı boyutlu ve yönlere bir dizi 3B Gabor'un sahip olduğu hesaplanan yeni bir texton histogramı, farklı MRI modellerinden her bir süpervoksel üzerinde denenmiştir. Rastgele orman sınıflandırıcı daha sonra her bir süpervoeli tümör veya normal kullanım olarak kullanılırk için. Texton, 3B alanlardaki çeşitli desenleri ayırt etmek için önemli bilgiler sağlamanın avantajlarını gösterir ve multimodal MRI görüntülerinden özellikler eklemek, manuel olarak tanımlanan altın standarda göre süpervoksellerin sınıflandırma doğruluğunu büyük ölçüde arttırmaktadır. BRATS 2013 veri seti elde edilen iyi performansla göre yöntemin başarı bir şekilde sonuç verdiğini göstermektedir (Soltaninejad,M. vd, 2018).

Çizelge 7. BRATS 2013 veri setini kullanan diğer yöntemlerle karşılaştırma

Çalışma	Tümör (dice)%	Tüm tümör (dice) %
Tutison vd	0.78	0.87
Reza vd	0.91	0.92
Festa vd	0.79	0.62
Bauer vd	0.68	0.48
Geremia vd	0.83	0.62
Önerilen Yöntem	0.80	0.89

Citak-er ve arkadaşları, beyin tümörlerinin çok sınıflı sınıflandırması için önerilen transfer önermektedir. yapılan çalışmada, çok bölgeli ve çok parametrik MRG verilerine dayalı makine öğreniminin, bu sınırlı hasta versetinde glial tümörleri doğru bir şekilde çalışmaktadır. çalışmada AlexNet, ESA modelleri VGG16 ve VGG19'u kullandı. Deneysel çalışmalarda AlexNet, VGG16 ve VGG19 modellerinde sırasıyla %89,95, %94,65 ve %94,82 doğruluk oranları elde edilmiştir (citak. F. vd , 2018).

Swati ve arkadaşları yapmış olduğu çalışmada, transfer öğrenme ve ince ayara dayalı beyin tümörü görüntüleri sınıflandırmak için yeni bir yöntem önerdiler. Blok bazında ince ayar ile önerilen transfer öğrenme stratejisi, önceden eğitilmiş CNN algoritmayı, ayrı sınıflandırma yöntemini eğiten kullanıma hazır özellik çıkarıcı olarak kullanmaktan farklı olan alternatif bir seçenek önermektedir. Aynı zamanda doğal görüntülerden beyin MR görüntülerine öğrenmenin a transeferedebildiğini de göstermektedir. Önerilen yöntem, diğer vücut organ MRI görüntüleri ve X-ışınları, PET ve CT gibi diğer tıbbi görüntüleme alanları için sınıflandırma sistemi geliştirmek için kullanılmıştır. Deneysel sonuçlar, önerilen yöntemin yalnızca son teknoloji ürünü geleneksel makine öğrenme yönteminden daha iyi performans göstermediğini, aynı zamanda aynı CE-MRI veri kümesinde son teknoloji CNN yöntemlerinden daha iyi performans verdiğini gözlenmiştir. çalışma sonucu olarak beyin tümörlerini tespitinde doğruluk oranı %93'tür (Khan Swati, Z. N, vd ,2019).

Çizelge 8. CEMRI veri setinde önerilen ve en son yöntemler arasında doğruluk karşılaştırması

Metod	Cheng vd (2015)	Paul vd (2017)	Abiwinanda vd (2019)	Önerilen yöntem
Doğruluk	91.28	90.26	84.18	94.82

Abiwinada N. Ve değerleri yapmış olduklar çalışmada, en yaygın üç beyin tümörü tipini, yani Glioma, Meningioma ve Hipofizi otomatik olarak sınıflandırmak için bölge bazlı ön işleme adımları gerektirmeden CNN'yi kullanıldı. 2 kat evrişim, aktivasyon (ReLU) ve maxpool ve ardından 64 nörondan oluşan bir gizli katmandan oluşan optimal bir CNN mimarisi belirledik. Mimaride, dönem sayısı arttıkça doğrulama kaybında sürekli olarak azalan bir model gösteren ve beş mimarinin tümü arasında en yüksek doğrulama veren tek

mimaridir. Mimaride eğitim ve doğrulama doğruluğu en iyi ihtimalle sırasıyla %98,51 ve %84,19'dur. Bu rakamlar, biraz daha düşük olmasına rağmen, bölge tabanlı ön işlemeye sahip geleneksel algoritmaların doğruluklarıyla karşılaştırılabilir ve bu oran %71,39-94,68'dir.

Aslan M. yapmış olduğu çalışmada, MRI görüntüler vesetini kullanarak beyin tümörü yerini belirlenmesi için bir yöntem önerdiler. Yöntem, MobileNetV2 ESA modelinden transfer öğrenmeye dayalı olarak derin öznitelik çıkarımı ve bu özniteliklerin k-EYK sınıflandırmasını içeren bir yaklaşımla sunulmaktadır. Öznitelik çıkarmada verimliliği artırmak için beş farklı yöntem deneyerek veri setindeki görüntü sayısı çoğaltılmıştır. Deneysel sonuçlar, ayrı bir sınıflandırıcı kullanmadan %92,88'lik bir sınıflandırma doğruluk oranı elilmiştir. K-EYK sınıflandırıcı ile sınıflandırma doğruluğu %3,56 artırılmış ve sınıflandırma doğruluğu %96,44 olmuştur. Ayrıca önceden eğitilmiş bir derin öğrenme modeli kullanıldığından öğrenilebilir parametrelerin optimizasyon süresi azalmaktadır. Böylece yaklaşık 3 dakikada eğitim ve özellik çıkarma işlemi bitmiştir. ek olarak, benzer yöntemlerle karşılaştırıldığında daha yüksek bir sınıflandırma oranı elde edilmiştir (Aslan, M. 2022).

Ramteke ve arkadaşları yaptıkları çalışmada, normal ve malign beyin manyetik rezonans görüntüleme bulgularının istatistiksel doku özellikleri için bir sınıflandırma algoritması olarak en yakın komşu sınıflandırıcıyı kullanmış ve %80 sınıflandırma doğruluğu elde etmiştir (Ramteke, R. vd 2012). Benzer şekilde, Gadpayleand ve arkadaşları çalışmalarında normal ve malign beyin MR görüntülerini doku özelliklerine göre sınıflandırmış ve bir sinir ağı sınıflandırıcısı ile %72,5 doğruluk elde etmiştir (Gadpayleand, P. vd 2013).

Abidin ve arkadaşları, metastazları ve glioblastoma tümörlerini saptamak için AdaBoost sınıflandırma algoritmasını kullandı ve 0,71'lik bir doğruluk elde edilmiştir.(Abidin, A. Z. vd, 2019) Başka bir çalışmada Anaraki ve ark., beyin tümörü görüntülerini konvolüsyonel sinir ağlarına (CNN) ve genetik Algoritmalara dayalı olarak sınıflandırmak için iki kombine yeniden düzenlemeden oluşan bir model önerdi ve üç glioma derecesini sınıflandırmada %90.9 doğruluk oranı elde edilmiştir (Anaraki, A.K., vd 2019).

III.METODLAR VE MATERYERLER

A. Beyin

İnsan beyni, zeka, yaratıcılık, duygu ve hafıza dahil olmak üzere vücudun tüm fonksiyonlarını kontrol eden organdır. Beyin, kafatası içinde korunur ve serebrum, beyincik ve beyin sapından oluşur. Beyin sapı ile omuriliğe bağlanmaktadır. (Mayfield Brain ve Spine 1999).

Beynin en büyük kısmı sağ ve sol hemisferlerden oluşan serebrumdur. Dokunma, görme ve işitme gibi hayati işlevleri yerine getirmekte ve konuşma, akıl yürütme, duygular, öğrenme ve hareketin hassas kontrol etmektedir. Serebrumun altında var olan beyincik, kas hareketlerini kontrol sağlamaktadır, ayrıca duruş ve dengeyi kormaktadır. Orta beyin, pons ve medulladan oluşan beyin sapı, serebrum ve serebellumu omuriliğe bağlayan bir aktarma merkezi olarak çalışmaktadır (Mayfield Brain ve Spine 1999).


Serebrum yüzey dokusuna serebral korteks denir; serebrumun en yüzeysel tabakasıdır. Serebral korteks gri ve kıvrımlıdır ve beynin 100 milyar sinir hücresinin yaklaşık %70'ini içerir. Ayrıca beyin, nöronlar arasında ve korteksin altında akson adı verilen ve beyaz maddeyi oluşturan uzun bağlantı sinir liflerine sahiptir (Miller ve ark. 2010).

B. Beyin Tümörü

Beyin tümörü, beynin içinde veya etrafında büyüyen bir grup anormal hücrelerdir. Bir beyin tümörü bulunduğu hücreleri etkilemekle kalmamaktadır, aynı zamanda iltihaplanmaya neden olarak çevresindeki hücrelere de zarar vermektedir (Rachana,R, vd 2013).

Beyin tümörler iyi huylu (benign) ve kötü huylu (malign) olarak iki tem guruba bölünmektedir. İyi huylu bir beyin tümöründe kanser hücresi bulunmamaktadır ve beynin içinde net bir limitle yavaş yavaş büyümektedir.

Kötü huylu beyin tümörleri, iyi huylu tümörlerden daha saldırgandır, sınırları olmayan kanser hücrelerine sahiptir. Bu model tümör süratle büyüyebilir ve çevredeki beyin dokularını etki etmektedir. Ek olarak, beyin tümörü, tümör hücrelerinin başladığı yere bağlı olarak birincil ve ikincil olarak ayrılabilir. Birincil beyin tümörleri beyin hücrelerinden kaynaklanır ve beynin diğer bölgelerine yayılırken, ikincil beyin tümörleri beyin dışındaki dokulardan kaynaklanır ve beyne yayılır. İkincil beyin tümörleri, birincil beyin tümörlerinden daha yaygındır ve tedavisi, tümörün başladığı orijinal dokuya bağlıdır (Glass-Macenska, D. vd. ,2013).



Şekil 2. MR görüntülerinde beyin tümörlerinin türleri: a) kötü huylu tümör; b) iyi huylu tümör

Bazı tümör çeşitlerine bir derece verilmektedir (Al-Tamimi, M.S.H. ve Sulong, G., 2014), bu derece tümör hücrelerinin büyüme ve yayılma hızını göstermektedir (Glass-Macenska, D. vd. ,2013). Derece seviyeleri Derece I'den (daha az kötü huylu) Derece IV'e (en kötü huylu) kadar başlamaktadır (Louis D.N., vd., 2007) Beyin tümörleri, tümörün tipine, derecesine ve boyutuna bağlı olarak “ameliyat, radyasyon tedavisi veya kemoterapi” kullanılarak tedavi edilmektedir (Al-Tamimi, M.S.H. ve Sulong, G., 2014). Dünya Sağlık Örgütü'ne (WHO) göre 120'den fazla beyin ve merkezi sinir sistemi tümörü çeşidi vardır. En yaygın çeşitleri (Glass-Macenska, D. vd., 2013) anlatılmıştır.

1. Glioma

Glioma tümörü yetişkinlerin sık teşhis edilen primer tümörlerdir. Beyindeki glial hücrelerden başlar ve çevre dokuya yayılmaktadır (Menze, B.H., vd., 2015). Bu tip tümör, heterojen doku bölgesi, azalmış sinyal yoğunluğu ve parlak tümör sınırına sahip bir bölge olarak ortaya çıkmaktadır (Bauer ,S., vd. 2013).

2. Meningiom tümörü

Meningiom, beyni kaplayan kabuktan meydana gelen ve kafatasının altında yer alan iyi huylu bir tümördür. Yetişkinlerde, bu tip tümör beyin tümörlerinin üçte biri olarak kabul edilir ve tipik olarak beynin içinde yavaş büyümektedir (Glass-Macenska, D. vd., 2013).

3. Hipofiz Tümörü (Pituitary Tumor)

Hipofiz bezi, yumurtalıklar, adrenal bezler, tiroidler gibi bedendeki diğer bezleri kontrol eden hormonların üretilmesinden sorumludur. Hipofiz tümörü, hipofiz bezine saldıran ve bu nedenle diğer bezlerin fonksiyonelliğini bozan iyi huylu bir tümördür. Tümörün büyümesini sınırlamaya yardımcı olan ve diğer beyin dokularına yayılmasını önleyen ilaçlarla tedavi edilmektedir (Glass-Macenska, D. vd., 2013).

4. Sinir Kılıfı Tümörleri (Schwannomalar)

Schwannomalar iyi huylu tümörler şeklinde kabul edilmektedir ve sinir hücrelerini destek veren vestibüler schwannoma veya akustik nöroma hücrelerinden gelmektedir. Bu tümör tipi için ameliyat zor olduğu için tedavi için en iyi yol radyasyondur (Glass-Macenska, D. vd., 2013).

5. Merkezi Sinir Sistemi (MSS) lenfoma

Bu tip tümör kötü huyludur, CNS Lenfoma, lenfosit hücrelerinden kaynaklanmaktadır. Radyasyon veya kemoterapi ile tedavi edilmektedir (Glass-Macenska, D. vd., 2013).

C. Tıbbi Görüntüleme Teknikleri

Bir beyin tümörünü teşhis etmenin ve konumunu belirlemenin ilk adımı, beyin ve omuriliğin bilgisayarlı bir görüntüsünü oluşturmaktır, bu işleme tarama veya görüntüleme yöntemidir. Yaygın olarak kullanılan görüntüleme yöntemleri arasında bilgisayarlı aksiyal tomografi (CT taraması), manyetik rezonans görüntüleme (MRI), manyetik rezonans spektroskopisi (MRI SPECT veya MRS), perfüzyon MRI, fonksiyonel MRI (fMRI) ve pozitron emisyon tomografisi (PET) bulunur (Glass-Macenska, D. vd., 2013).

MRG, birçok sebepten dolayı en yaygın kullanılan görüntüleme yöntemidir. İlk olarak, doku suyundaki lokal değişikliklere karşı oldukça hassastır. İkincisi, özellikle yumuşak dokuların ayırt edilmesinde yüksek çözünürlüğe sahiptir. Üçüncüsü, aynı dokuyu incelerken değişik kontrast görselleştirmeleri ile birden fazla görüntü oluşturabilmesi, bu şekilde doktorların ve radyologların taranan dokuyu daha hassas bir şekilde incelemesine yardımcı olmaktadır. Son olarak, beyin ve omurilik gibi farklı organların anatomisi üzerine ayrıntılı bilgi sağlamak için ekstenel, sagittal ve koronal olmak üzere üç görsel düzlem oluşturma yeteneğine sahiptir (Nabizadeh N., 2015). Beyin tümörlerinin görüntülenmesinde zıtlık madde kullanma avantajı, beyin neoplazmalarının saptanmasını ve tespit etmesini geliştirmesidir (Drevelegas, A. ve Papanikolaou, N. 2011).

Bir beyin tümörünü teşhis etmek için aşağıdaki yöntemler kullanılabilir (Drevelegas, A. ve Papanikolaou, N. 2011):

1. MRG: bu, tümörler ve enfeksiyonlar gibi beyin anormalliklerini tespit edebilen ayrıntılı görüntüler sağlar. Bu teknik, tümörleri tespit etmede ve kapsamını tanımlamak için çevredeki alanı değerlendirmede yüksek hassasiyete sahiptir.
2. FMRI veya fonksiyonel MRG: Bu, beynin aktif bir bölümünde meydana gelen küçük metabolik değişiklikleri ölçmek için kullanılır. Tarama, beyindeki dil ve kas hareketi ile ilgili alanları değerlendirmek için kullanılmaktadır. Ayrıca tümörlerin büyümesini ve işlevini izlemek ve cerrahi veya diğer invaziv tedavilerin potansiyel risklerini değerlendirmek için kullanılmaktadır.

3. BT: Bu, beyin tümörlerini tespit etmektedir ve radyasyon tedavisinin kullanımını planlamaya yardımcı olmaktadır. BT ayrıca beyindeki kanamayı veya şişmeyi de ortaya çıkarmaktadır.
4. PET ve PET/BT: bir pozitron emisyon tomografisi (PET) taraması, birçok hastalıkların ciddiyetini tanı koymak ve tespit etmek için izleyici olarak az miktarda radyoaktif malzeme kullanan bir tanı testidir. Bir PET/CT birleşik muayenesi, beynin hem anatomisini (CT taramasından) hem de işlevini (PET taramasından) tespit etmek için bir PET ve CT taramasından alınan görüntüleri birlikte sağlamaktadır. Bu test, beyin tümörünün glikoz kullanımının ölçümüne bağlıdır.


BU çalışmada kullanılan görüntüleme yöntemi, geleneksel MRI taramasıdır ve MRI aracılığıyla elde edilen çeşitli veri kümelerini kullanılmıştır.

1. Magnetic Resonance Imaging

Manyetik Rezonans Görüntüleme (MRI), vücudun iç yapısındaki detayları tespit etmek ve görselleştirmek için kullanılan modern bir klinik görüntüleme tekniğidir (Hassan,E. ve Aboshgifa, A.,2015). Bu teknik, yirminci yüzyılın başlarından beri araştırılan Nükleer Manyetik Rezonansın (NMR) temel ilkelerinden yararlanmaktadır. MRI, X-ışınlarını kullanmaz; bunun yerine güçlü bir mıknatıs kullanır ve vücuda radyo dalgaları göndermektedir. Görüntüler daha sonra bir bilgisayar ekranında veya filmde görünmektedir. MRG'nin BT'den çok daha fazla kontrastı vardır, bu da onu özellikle nörolojik hastalıklar için faydalı kılar. MRG'nin diğer tıbbi görüntüleme tekniklerine göre başlıca avantajları, non-invaziv doğası, çok yönlülüğü, mükemmel doku kontrastı ve akış ve difüzyona duyarlılığıdır.

MRI, atom çekirdeği ve bunların manyetizasyon özellikleri üzerinde çalışmaktadır. Test edilecek dokuya düzgün bir dış ve güçlü manyetik alan uygulanmaktadır. Bu hizalama işlemi manyetizasyon olarak bilinir ve dokulardaki su çekirdeklerinin protonlarını hizalamak için gerçekleştirmektedir. Bu protonlar çekirdek içinde random yönlendirmektedir. Harici radyo frekansı (RF) enerjisi nedeniyle manyetizasyon kararsız hale gelmektedir. Çekirdekler, çeşitli gevşeme süreçleri yoluyla dinlenme hizalarına geri döner ve bunun sonucunda RF enerjisi yayılmaktadır. Bir süre sonra yayılan sinyaller ölçmektedir. Görüntülenen her bir

düzlem alanından gelen sinyaller, bir Fourier dönüşümünün uygulanmasıyla karşılık gelen yoğunluk seviyelerine dönüştürülen frekans bilgisinden oluşmaktadır. Ondan sonra, bir piksel matrisi üzerinde gri tonlarında görünmektedir. Uygulanan ve toplanan RF darbelerinin sırasını değiştirerek birkaç farklı görüntü türü oluşmaktadır.




Şekil 3. Atom çekirdeğinin manyetik momenti

Kaynak: (Westbrook, C., ve Talbot, J. 2018)

2. Manyetik Rezonans

Rezonans, tüm MR prosedürlerinin temelidir; B_0 manyetik alanına 90 derecelik bir açıyla işleyen hidrojen çekirdekleriyle aynı enerjide bir radyo frekansı (RF) darbesi uygulandığında meydana gelmektedir. Rezonans, birçok nesne ve cihaz tarafından enerjinin emilmesi ve yayılması için gereklidir. Harici bir manyetik alanın uygulanmasının bir sonucu olarak, spin-up ve spin-down çekirdeklerinin sayısı eşittir. Net manyetizasyon vektörü (NMV) daha sonra "çevirme açısı" olarak bilinen enine (X-Y) düzleme 90°'de uzanacaktır. 90° ve 180° çevirme açısına sahip darbeler en yaygın olanıdır ancak daha küçük çevirme açısı darbeleri de gradyan eko görüntüleme gibi bazı görüntüleme yöntemlerinde kullanılır. Hidrojen çekirdekleri, yüksek enerjili (spin-down) çekirdeklerin sayısını artıran RF darbesinden enerji emer. Çevirme açısının büyüklüğü, RF darbesinin büyüklüğüne ve süresine bağlıdır. B_0 manyetik alanı arttıkça, rezonansı oluşturmak için gereken enerji de artar (Sprawls, P. 2000).

MRG sistemi Şekil 4'te belirtildiği gibi gradiyent sargılar, manyetik sargılar, radyo frekans sinyal alıcı ve verici, görüntülerin yeniden düzenlenmesi ve kontrol işlemleri için bir bilgisayardan oluşmaktadır (Sprawls 2000).



Şekil 4. MRG Temel parçaları

Kaynak: (Sprawls, P. 2000)

MR sinyali, bir numuneye veya hedef dokuya güçlü ve sabit bir manyetik alan uygulanarak üretmektedir. Sinyalin büyüklüğü, enine düzlemdeki manyetizasyon miktarına bağlıdır. Sinyalin frekansı, Larmor frekansıninkine eşittir. RF darbesi sonlandırıldığında, bu RF darbesinden elde edilen nükleer enerji kaybolacaktır; bu durumda, NMV, B0 harici manyetik alanıyla yeniden hizalanmaya çalışır. Boyuna düzlemdeki (üstel özelliklere sahip olan) manyetizasyon, geri kazanım olarak bilinen bir mertebede artmaktadır. Bununla beraber, enine düzlemdeki manyetizasyon, bozunma fazı olarak bilinen üstel olarak azamaktadır. Bunların sonucunda, alıcı bobin içindeki indüklenen voltajın büyüklüğü, serbest indüksiyon (FID) sinyali olarak adlandırılan bozulma sırasında azalmaktadır.

3. Gevşeme

Gevşeme, sinyallerin zaman içinde nasıl değiştiğini açıklamaktadır. Gevşeme aşamasında, hidrojen çekirdekleri, RF uygulandığında emilen uyarma enerjisini kaybetmektedir. Bu, NMV'nin başlangıçtaki B_0 'ye dönmesini sağlayarak hidrojen çekirdeklerinin manyetik momentlerinin tutarlılığını kaybetmesine sebeb olur. Hidrojen protonlarının gevşeme süresi değişebilir ve genellikle iki kez ölçülmektedir. T1 geri kazanımı olarak bilinen uzunlamasına gevşeme süresi ve T2 bozunması olarak bilinen enine gevşeme süresidir (Sprawls, P. 2000).

D. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme

1. Yapay Zeka

Yapay zeka (AI) ve uygulaması dermatolojik görüntülemelerde büyük bir görüntü teknolojisidir, ve bunlarla sınırlı olmamak üzere, görüntü elde etme, işleme, yorumlama, raporlama ve takip planlamasını içermektedir (Lakhani, P. Vd.,2018). Ayrıca, veri entegrasyonu, veri depolama ve veri madenciliğinin ek faydaları da vardır.

AI, genellikle insan zekâsı gerektiren görevleri yerine getiren sistemlerin oluşturulmasına adanmış bir bilgisayar bilimi alanını ifade etmektedir. Genel olarak insan zekâsının makinelere dahil edilmesidir (Chartrand, P. vd. 2017).

Yapay zekada makineler, öngörülen kurallara ve algoritmalara göre görevi tamamlanmaktadır. AI, insan zekâsının dokunuşuna sahip olan ve makine Öğrenmesi ML ve derin Öğrenme DL'yi kapsayan herhangi bir bilgisayar programı için bir şemsiye terimdir (Şekil 5.) (Pesapane F. vd.,2018).



Şekil 5. Yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi

2. Makine Öğrenmesi

Makine öğrenmesi (ML), makinelerin açıkça programlanmadan verilerden öğrenmesine olanak tanıyan tüm yaklaşımları içeren bir AI alt kümesidir. 5 Makine öğreniminin amacı, sağlanan verilere ve algoritmalara dayalı olarak makineleri eğitmektir. İşlenen verileri ve bilgileri kullanarak makineler nasıl karar vereceğini öğrenir.4 ML dinamikdir, yani daha fazla veriye maruz kaldığında kendini değiştirme yeteneğine sahiptir. ML'nin "öğrenme" yönü, ML algoritmalarının hataları en aza indirmeye ve tahminlerinin doğru olma olasılığını

en üst düzeye çıkarmaya çalıştığı anlamına gelir. Kısacası, ML basitçe AI gerçekleştirmek için bir tekniktir.

3. Tıbbi Görüntü Analizinde Makine Öğrenimi

Hem görüntüleme hem de bilgisayardaki ilerlemeler, risk değerlendirmesi, tespit, teşhis, prognoz ve tedavi yanıtı gibi çeşitli radyolojik görüntüleme görevlerinde ve ayrıca hızlı hastalık keşfinde yapay zekanın potansiyel kullanımında sinerjik bir şekilde hızlı bir artışa yol açmıştır. Bilgisayardan çıkarılan (radyo-mikrofon) özellikler, makine öğrenimi algoritmalarına (yani, belirlenmiş bir girdi verisi verilen belirlenmiş bir görevi "öğrenen" bilgisayar algoritmaları) girdi olarak hizmet etmektedir. Bu tür makine öğrenimi yöntemleriyle, birden fazla radyo-mikrofon özelliği, hastalık durumunun olasılığıyla ilişkili olabilecek tümör imzası gibi tek bir değerde birleştirmektedir (Choudhary, R.,ve Gianey, H. K. 2017).

4. Beyin Tümörü Segmentasyonu için Görüntü İşleme

MRI'dan beyin tümörü segmentasyonu, genellikle önemli miktarda veri içerdiğinden tıbbi görüntü işlemedeki en önemli görevlerden biridir. Ayrıca, tümörler yumuşak doku sınırları ile kötü tanımlanmış olabilir. Bu nedenle, insan beyninden tümörlerin doğru segmentasyonunu elde etmek çok kapsamlı bir iştir. Görüntü işleme, MRI görüntülerinin kalitesini iyileştirmeye ve ardından özellik çıkarma ve sınıflandırma gerçekleştirmeye yardımcı olur. Beyin tümörü segmentasyonu için görüntü işleme, kafatası soyma, ön işleme, tümör şekillendirme vb. gibi çeşitli adımları içermektedir.

5. Ön İşleme

Tıbbi görüntü işlemede, tıbbi görüntüler farklı gürültü türleriyle bozulur. Verilen uygulama için doğru gözlemleri kolaylaştırmak için kesin görüntüler elde etmek çok önemlidir. Ön işleme adımları filtreleme, morfolojik işlemler vb. içerir (Patel, N. Vd.,2014).

- **Filtreleme:**

Görüntü filtreleme, yumuşatma, keskinleştirme, parazit giderme ve kenar algılama gibi birçok uygulama için kullanışlıdır. Bir filtre, bir görüntü içindeki

her piksele ve komşularına uygulanan küçük bir dizi olan bir çekirdek tarafından tanımlanmaktadır. Bir görüntüye filtre uygulamak için kullanılan süreç evrişim olarak bilinir ve uzaysal veya frekans alanında uygulanmaktadır. Uzamsal alan filtreleme, çıktılarına göre yumuşatma ve bileme filtreleri olmak üzere iki tipte ayrılmaktadır.

- **Yumuşatma Filtresi(Smoothing):** Gürültü azaltma ve bulanıklaştırma işlemleri için yumuşatıcı uzamsal filtreler kullanılmaktadır.

1. **Kutu Filtreleme (Box Filtreing):** temel olarak, çevreleyen pikselin ortalaması olan bir görüntü filtreleme türüdür.

2. **Gauss bulanıklık filtreleme:** görüntüleri 'bulanıklaştırmak' ve ayrıntı ile paraziti ortadan kaldırmak için kullanılan bir 2B evrişim operatörüdür. Bu anlamda ortalama filtreye benzer, ancak Gauss ('çan şekilli') tümseğinin şeklini temsil eden farklı bir çekirdek kullanılmaktadır. Düzgünleştirme derecesi, Gauss'un standart sapması ile belirlenmektedir.

3. **Medyan bulanıklık filtresi:** bir görüntüdeki gürültüyü azaltmak için kullanılmaktadır. Piksel değerini komşu piksel değerlerinin ortalamasıyla değiştirmek yerine, bu değerlerin medyanı ile değiştirir.

4. **İkili Filtre (Bilateral Filter):** görüntüler için doğrusal olmayan, kenar koruyucu ve gürültü azaltıcı bir yumuşatma filtresidir. Bu keskin kenarları korumaktadır.


- **Keskinleştirme (Sharpening) Filtresi:** Görüntülerdeki bulanıklığı giderir ve kenarları vurgular. Bileme filtreleri mekansal farklılaşmaya dayanır. Laplace filtresi, sobel filtresi, fark filtresi vb.

1. **Laplacian filtre:** görüntülerde hızlı değişim (kenar) alanlarını bulmak için kullanılan türev filtrelerdir.

2. **Sobel filtreleri:** genellikle kenar tespiti için kullanılır.

3. **Fark filtreleri:** seçilen maskeye özgü yönde ayrıntıları geliştirmektedir.

- **Matematiksel morfoloji (Morphological Operations):** Morfoloji, piksel şekline dayalı analiz anlamına gelir. Morfolojik işlemleri kullanmanın amacı, görüntünün yapısındaki kusurları ortadan kaldırmaktır. En temel morfolojik işlemler genişleme ve aşındırmadır. Genişletme, bir görüntüdeki nesnelerin sınırlarına pikseller eklerken, erozyon nesne sınırlarındaki pikselleri kaldırır. Morfolojik işlemler ayrıca açma, kapama, vurma ve ıskalama dönüşümü vb. içerir.
- **Segmentasyon:** Segmentasyon, görüntüyü farklı bölgelere bölmek ve nesneleri arka plandan ayırmak anlamına gelmektedir. Bir görüntüdeki ilgili nesnelerin doğru bir şekilde bölütlenmesi, bu nesnelerin daha fazla analizini büyük ölçüde kolaylaştırmaktadır. Kenar tabanlı, eşik tabanlı, bölge tabanlı, kümeleme tabanlı vb. gibi çeşitli segmentasyon algoritmaları bulunmaktadır. Şekil 6’da bir nesnenin arka planından segmentasyonunu gösterilmiştir.



Şekil 6. nesnenin arka plandan bölümlere ayrılması

- **Bulanık kümeleme(Fuzzy C-Means Clustering (FCM)):**
Bulanık kümeleme (FCM), bir verinin iki veya daha fazla kümeye ait olmasına izin veren bir kümeleme yöntemidir. Bu yöntem, görüntü tanımda sıklıkla kullanılmaktadır. En yaygın olarak kullanılan bulanık kümeleme algoritmalarından biri, Bulanık C-ortalamlar kümeleme (FCM) Algoritmasıdır.(URL-2, fuzzy-c-means-segmentation)
Şekil 7.’de bulanık kümeleme parçalara ayrılmış görüntüsünü gösterilmiştir.



Şekil 7. bulanık kümeleme parçalara ayrılmış görüntü

- **K-means Kümeleme:** K-Means kümeleme, bir tür denetimsiz öğrenmedir. Böylece, etiketlenmemiş verilerimiz olduğunda, K-Means Clustering'i kullanabilmektedir. K-ortalama kümeleme algoritması, verilerde açıkça etiketlenmemiş grupları bulmak için kullanılmaktadır. Bu algoritmanın amacı, K değişkeni tarafından temsil edilen grup sayısı ile verilerdeki grupları bulmaktır. (Ghosh, S., & Dubey, S. K. 2013)
- **Havza Segmentasyonu(Watershed Segmentation):** Watershed, segmentasyon için, yani bir görüntüdeki farklı nesneleri ayırmak için kullanılan klasik bir algoritmadır. Watershed, gri ölçekli görüntülerde bir dönüşümdür. Bu tekniğin amacı, tipik olarak iki ilgi alanı birbirine yakın olduğunda, yani kenarları birbirine dokunduğunda görüntüyü bölümlere ayırmaktır. Bu dönüştürme tekniği, görüntüyü her pikselin yoğunluğunun yüksekliği temsil ettiği bir topografik harita olarak ele almaktadır. Örnek olarak, karanlık alanlar sezgisel olarak yükseklik olarak "daha düşük" olarak kabul edilebilir ve çukurları temsil edebilir. Öte yandan, parlak alanlar, tepeler veya bir dağ sırtı gibi hareket eden 'daha yüksek' olarak kabul edilmektedir. (Mustaqeem, A., vd.,2012)

6. Makine Öğrenimi Sınıflandırma algoritmaları


Genel olarak bir sınıflandırma algoritması, çıktının bir sınıfı pozitif değerlere ve diğerini negatif değerlere ayırması için girdi özelliklerini tartan bir fonksiyondur.

a. K-En Yakın Komşu

KNN, denetimli öğrenme için mevcut en basit sınıflandırma algoritmalarından biridir. Buradaki amaç, özellik alanında test verilerinin en yakın eşleşmesini aramaktır. Tipik olarak nesne, çoğunluk oyu ile en yakın k komşusunun etiketlerine göre sınıflandırmaktadır. $k=1$ ise, nesne basitçe kendisine en yakın nesnenin sınıfı olarak sınıflandırmaktadır. Yalnızca iki sınıf olduğunda, k tek bir tam sayı olmalıdır. (1, 3,5,7) gibi tavsiye edilen tek rakam 3 veya 5'tir. Bununla birlikte, çok sınıflı sınıflandırma yapılırken k 'nin tek bir tam sayı olduğu zamanlar olabilmektedir (Moldagulova, A., & Sulaiman, R. B. 2017). Her görüntüyü gerçek sayılarla sabit uzunlukta bir vektöre dönüştürdükten sonra, KNN için en yaygın uzaklık fonksiyonu olan x ve y iki noktası arasındaki Öklid uzaklığı kullanılmış ve şöyle yazılabilir:

$$d(x, y) = |x - y| = \sqrt{(x - y) \cdot (x - y)} = \left(\sum_{i=1}^m (x_i - y_i)^2 \right)^{\frac{1}{2}} \quad (1)$$

Şekil 8'de Knn sınıflandırma algoritmasını gösterilmiştir



Şekil 8. . KNN algoritması

b. Lojistik regresyon


Tüm regresyon analizleri gibi, lojistik regresyon da tahmine dayalı bir analizdir. Lojistik regresyon, verileri tanımlamak ve bir bağımlı ikili değişken ile bir veya daha fazla nominal, sıra, aralık veya oran düzeyinde bağımsız değişken arasındaki ilişkiyi açıklamak için kullanılmaktadır. Lojistik regresyon, temsil olarak doğrusal regresyona çok benzeyen bir denklem kullanmaktadır. Girdi değerleri (x), bir çıktı değerini (y) tahmin etmek için ağırlıklar veya katsayı değerleri kullanılarak doğrusal olarak birleştirilir. Doğrusal regresyondan önemli

bir fark, modellenen çıktı değerinin sayısal bir değer yerine ikili değerler (0 veya 1) olmaktadır. Şekil 9’da lojistik regresyon gösterilmiştir.

lojistik regresyon denklemi(URL-3):

$$y = \frac{(e^{b_0+b_1x})}{1 + e^{(b_0+b_1x)}} \quad (2)$$

y, tahmin edilen çıktıdır, b_0 önyargı veya kesme terimidir ve b_1 tek giriş değeri (x) için katsayıdır.



Şekil 9. lojistik regresyon

c. Çok Katmanlı Algılayıcı (MLP)

Çok katmanlı algılayıcı (MLP), bir dizi girdiden bir dizi çıktı üreten ileri beslemeli bir yapay sinir ağıdır. Bir MLP, en az üç düğüm katmanından oluşmaktadır: bir giriş katmanı, bir gizli katman ve bir çıkış katmanıdır. Giriş düğümleri dışında, her düğüm, doğrusal olmayan bir aktivasyon işlevi kullanan bir nörondur. Bir MLP, giriş ve çıkış katmanları arasında yönlendirilmiş bir grafik olarak bağlanan birkaç giriş düğümü katmanı ile karakterize edilmektedir. MLP, ağı eğitmek için geri yayılımı kullanmaktadır. Çok katmanlı sinir ağlarının çoğu derin öğrenmeyi beklemektedir. Bir veya iki gizli katman kullanmaktadır (Askari, M., & Keynia, F. 2020).

d. Naive Bayes

Naive Bayes, sınıflandırma problemleri için bir makine öğrenme algoritmasıdır. Bilinmeyen veri kümesinin sınıfını tahmin etmek için Bayes'in olasılık teoremine dayanmaktadır. Verilen kaydın veya veri noktasının belirli bir

sınıfa ait olma olasılığı gibi her sınıf için üyelik olasılıklarını tahmin etmektedir. En yüksek olasılığa sahip sınıf, en olası sınıf olarak kabul edilmektedir (Vembandasamy, K. Vd. , 2015).

Bir makine öğrenimi sınıflandırma probleminde, birden fazla özellik ve sınıf vardır, $C_1, C_2, \dots, C_k$. Naive Bayes algoritmasındaki temel amaç, belirli bir C_i sınıfına ait $X_1, X_2, \dots, X_n$ öznelik vektörüne sahip bir nesnenin koşullu olasılığını hesaplamaktır. Ve denklem şu şekilde yazılabilir:

$$P(C_i|x_1, x_2, \dots, x_n) = \frac{P(x_1, x_2, \dots, x_n|C_i) * P(C_i)}{P(x_1, x_2, \dots, x_n)}, \text{ for } 1 \leq i < k \quad (3)$$

e. Random Forest (Rastgele Orman)

Rastgele orman, topluluk öğrenmesine dayalı bir tür denetimli makine öğrenimi algoritmasıdır. Toplu öğrenme, daha güçlü bir tahmin modeli oluşturmak için farklı türdeki algoritmaları veya aynı algoritmayı birden çok kez birleştirdiğinde bir öğrenme türüdür. Rastgele orman algoritması, aynı türden birden çok algoritmayı, yani birden çok karar ağacını birleştirmektedir.

Rastgele karar ormanları, karar ağaçlarının eğitim setlerine aşırı uyma alışkanlığını düzeltmektedir. Eğitim zamanında çok sayıda karar ağacı oluşturularak ve sınıfların modu (sınıflandırma) veya bireysel ağaçların ortalama tahmini (regresyon) olan sınıfın çıktısını alarak çalışmaktadır (Biau, G., & Scornet, E, 2016).

f. Destek Vektör Makinesi (SVM)

Destek vektör makineleri, sınıflandırma ve regresyon analizi için kullanılan verileri analiz eden ilişkili öğrenme algoritmalarına sahip denetimli öğrenme modelleridir. Her biri iki kategoriden birine veya diğerine ait olarak işaretlenmiş bir dizi eğitim örneği verildiğinde, bir SVM eğitim algoritması, bir kategoriye veya diğerine yeni örnekler atayan ve onu olasılıksal olmayan bir ikili doğrusal sınıflandırıcı yapan bir model oluşturmaktadır. Bir SVM modeli, örneklerin uzaydaki noktalar olarak temsilidir ve ayrı kategorilerin örneklerinin mümkün olduğu kadar geniş açık bir boşlukla bölünmesi için eşlenmektedir. Yeni örnekler daha sonra aynı alana eşlenir ve boşluğun hangi tarafına düştüklerine bağlı olarak bir kategoriye ait oldukları tahmin edilmektedir. Doğrusal sınıflandırma


gerçekleştirmeye ek olarak, SVM, girdilerini örtük olarak yüksek boyutlu özellik uzaylarına eşleyerek, çekirdek hilesi denilen şeyi kullanarak doğrusal olmayan bir sınıflandırmayı verimli bir şekilde gerçekleştirmektedir. (Vishwanathan, S. V. M., & Murty, M. N. 2002).

7. Derin Öğrenme

Derin Öğrenme, kalıpları tanımada çok iyi olan ancak genellikle çok sayıda veri gerektiren bir makine öğrenimi algoritmaları alt kümesidir. Derin öğrenme, her katmanın görüntünün bir veya daha fazla özelliğini çıkarmaktan sorumlu olduğu üç veya daha fazla yapay sinir ağı katmanını kullanarak uygulandığı için görüntülerdeki nesneleri tanımada üstündür.

a. Yapay Sinir Ağı

Derin öğrenme, insan beyninde bulunan benzer ağlar üzerinde modellenen yapay sinir ağlarından oluşmaktadır. Bu sinir ağları birden çok katmanda çalışmaktadır, bu nedenle bu tür makine öğrenimine derin öğrenme denmektedir. Yapay sinir ağları, eğitim verileri aracılığıyla tekrarlanan yinelemelerden hesaplanan ağırlıklı bağlantıları ("sinapslar") kullanarak bir girdiden (sınıflandırmadan) bir çıktı hesaplamasının bir yoludur. daha yüksek "doğruluk" (daha düşük hata oranı) ile çıktı. Yüz binlerce matris çarpımı yaparken çalışan bellek ve hızın birleşimi çok önemlidir. Şekil 10'da Basit Bir Yapay Sinir Ağı göstermektedir.




Şekil 10. Yapay sinir ağı

b. Evrişimsel Sinir Ağı (CNN)

Evrişimli sinir ağının katmanlarının ana uygulaması, taramaları veya görüntüleri sararak özellik haritalarını elde etmektir. Her katman, çekirdekler tarafından kendisinden önceki katmana bağlanmaktadır. Bazı girdi özelliklerini artırmak için eğitim aşamasında geri yayılım yöntemi yapılarak çekirdekler iyileştirilir. Özellik haritası katmanlarındaki bağlantı nedeniyle, yalnızca bazı ağırlıkların evrişim katmanlarında eğitilmesi gerekmektedir. Bu nedenle, bir Evrişimsel sinir ağının (CNN) eğitilmesi daha kolaydır. (LeCun, Y. vd., 2015).

• Convolutional Layer (Evrişim katmanı)

Görüntü verilerinden yararlı bilgileri çıkarmak için hesaplamaların gerçekleştiği CNN'nin yapı taşıdır bu yüzden cnn algoritmasının en önemli katmanıdır. Her evrişim katmanı, çekirdek olarak da bilinen öğrenilebilir filtrelerden oluşmaktadır. Renkli bir görüntü, üç boyutlu bir piksel matrisi olarak düşünülebilirken, filtre, bir özelliğin mevcut olup olmadığını belirlerken görüntünün alıcı alanları boyunca kaydırılan iki boyutlu bir ağırlık dizisidir. Filtre tipik olarak 3x3 matrisi (ancak boyut değişebilir) bir görüntüye uygulanır ve giriş pikseli ve filtre ağırlıkları için nokta ürün hesaplanmaktadır. Filtre daha sonra adım olarak da bilinen n piksel sayısı kadar kaydırılır ve giriş pikselleri ve filtre ağırlıkları için nokta çarpımı hesaplanmaktadır. Evrişim olarak da bilinen bu süreç, girdi matrisinin sonuna kadar devam eder. Her nokta ürününün çıktısı, aktivasyon haritası veya özellik haritası olarak bilinen bir matris oluşturur. Özellik haritası , belirli filtre kullanılarak görüntüden çıkarılan özellik bilgilerini içermektedir (şekil 11).




$$2 = 4*1 + 9*0 + 2*(-1) + 5*1 + 6*0 + 2*(-1) + 2*1 + 4*0 + 5*(-1)$$

Şekil 11. Özellik Haritası Çıkarma Adımı

- Pooling Layer (ortaklama)


Bu katman, parametre sayısını azaltarak girişte boyutsallık azaltmayı gerçekleştirir ve bu eylemi gerçekleştirmek için bir filtre de kullanmaktadır (şekil 12). Tek fark, evrişimli katmanların yaptığı gibi ağırlıklara sahip bir matris kullanmak yerine, havuz katmanlarının giriş piksellerinde toplama gerçekleştirmesidir. Bu işlem bazı verilerin kaybolmasına neden olsa da, havuzlama katmanlarını kullanmanın faydaları, özelliklerin karmaşıklığını azaltmak, onu fazla uydurmaya daha az eğilimli hale getirmek, hesaplamaları hızlandırmak ve CNN'nin verimliliğini artırmaktır.



Şekil 12. Max Pooling işlemi örnek uygulaması

- **Fully-Connected Layer (tam bağlantı):**


Özellik haritasının giriş görüntüsündeki her piksel değerine bağlanmadığını görebildiğimiz için evrişim katmanı kısmen bağlantılıdır. Yalnızca filtrenin uygulandığı alt matrise bağlıdır. Ancak, her düğümün önceki tüm düğümlere bağlı olduğu, tam bağlantılı katman olarak bilinmektedir. Diğer iki katmandan çıktı olarak elde edilen özellik haritaları üç boyutlu vektörlerdir. Nihai sınıflandırma görevi için bu tam bağlantılı katmanlara geçirilen tek boyutlu bir vektör oluşturmak için düzleştirme işlemi yapılması gerekmektedir (şekil 13).



Şekil 13. Tam bağlantı katmanı yapısı

c. R-CNN


Rcnn cnn algoritmasında farkı bir layer daha eklemiştir. Görüntüyü vnn algoritmasına vermeden önce seçici arama yöntemi kullanarak görüntüden 2000 parça çıkarmaktadır. Çıkarılan 2000 parçayı ayrı ayrı cnn algoritmasına işlem yapmaktadır. Görüntüde nesne bulunma olasılığı olan bazı bölge vardır. Seçici arama ile 2000 tane parça çıkarılıp ayrı ayrı işlem yapmaktadır. Doğrudan bir görüntünün tamamını vermek yerine belirli bir bölge verip tespit işlemi yapılmaktadır (şekil 14).



Şekil 14. R-CNN Çalışma Yapısı

d. Fast R-CNN


Fast R-CNN R-CNN algoritmasına benzer. Ancak, bölge önerilerini CNN'ye beslemek yerine, bir evrişimli özellik haritası oluşturmak için girdi görüntüsünü CNN'ye beslenmektedir. Evrişimsel özellik haritasından, teklif bölgesini belirler ve bunları karelere çarparız ve bir RoI havuzlama katmanı kullanarak bunları tamamen bağlı bir katmana beslenebilmesi için sabit bir boyuta yeniden şekillendirmektedir. RoI özellik vektöründen, önerilen bölgenin sınıfını ve ayrıca sınırlayıcı kutu için offset değerlerini tahmin etmek için bir softmax katmanı kullanmaktadır (şekil 15).



Şekil 15. Fast R-CNN Çalışma Yapısı

e. Faster R-CNN

Faster R-CNN Fast R-CNN'ye benzer şekilde görüntü, bir evrişimsel özellik haritası sağlayan bir evrişimli ağa girdi olarak sağlanmaktadır. Bölge önerilerini belirlemek için özellik haritası üzerinde seçici arama algoritması kullanmak yerine, bölge önerilerini tahmin etmek için ayrı bir ağ kullanmaktadır. Tahmin edilen bölge önerileri daha sonra görüntüyü önerilen bölge içinde sınıflandırmak ve sınırlayıcı kutular için ofset değerlerini tahmin etmek için kullanılan bir RoI havuzlama katmanı kullanılarak yeniden şekillendirmektedir (şekil 16).




Şekil 16. Faster R-CNN Çalışma Yapısı

f. Mask R-CNN (Bölgesel tabanlı Evrişimsel Sinir Ağı) :

Nesne alanlarını bağımsız olarak ele alarak evrişimsel ağı değerlendirmek ve nesne tespiti için bölge tabanlı CNN (R-CNN) yöntemi tanıtıldı (Girshick R.

vd.,2014). R-CNN genişletildi (Girshick R. 2015), RoIPool kullanan özellik haritalarında ROI'lerle ilgilenmeye izin vererek, hızlı hız ve daha iyi kesinlik sağladı. Daha hızlı R-CNN (Ren S., vd., 2015) yöntemi, Bölge Teklif Ağı'ndan (RPN) dikkat özelliklerine sahip olarak geleneksel R-CNN'den ileri düzeydedir.

Daha hızlı R-CNN, her nesne, etiket ve ofset için iki çıktı içermektedir. Mask-RCNN'de, nesne maskesinin çıktısını almak için kullanılan üçüncü kısım eklenmektedir. Bu maske çıktısı, nesne ve sınıftan elde edilen çıktılardan tamamen farklıdır. Bu nedenle, daha iyi bir nesne düzeni gerektirmektedir. Pikselden piksele hizalama, önceki R-CNN yöntemlerinde mevcut olmayan R-CNN maskesinin ana unsurudur. İki aşamalı bir süreci, RPN olan Faster R-CNN'nin aynı ilk adımıyla Maske R-CNN izler. Sonraki adımda, her RoI için Mask R-CNN, kutu ofseti ve sınıf ile ikili maskenin çıktılarını vermektedir. Mask R-CNN'de Maske tahmini, sınıflandırma için önemli bir unsurdur.



Şekil 17. Maske R-CNN'nin Genel Yapısı

IV. YÖNTEM

Şekil 17'de gösterilen giriş görüntüsü evrişim katmanlarından geçirilerek özellik haritası elde edilmekte ve bu özellik haritası RPN'nin girişi olarak kullanılmaktadır. RPN ise farklı konumlardaki farklı boyuttaki tanımlama çerçevelerini, farklı boyut ve en boy oranlarındaki ankrajları kullanarak algılar ve kayan pencere yöntemiyle nesne olabilecek alanları algılanmaktadır. Bu şekilde nesneleri içerebilen çapalar seçilmektedir. Birden fazla ankraj üst üste gelirse, Intersection over Union (IoU) değeri en yüksek olan seçilmektedir. Bu işleme maksimum olmayan bastırma denir. Bu işlem sayesinde kesişim bölgeleri (Region of Interest, RoI) elde edilmektedir.

Önerilen ROI ve özellik haritasını girdi olarak alınmaktadır (Şekil 11). RPN'den farklı olarak, bu ağ daha derindir ve ROI'leri tümör/tümör olmayan gibi belirli bir sınıfa göre sınıflandırır ve sınırlayıcı kutunun boyutunu daha da iyileştirir. BBR, tümör bölgesini tamamen kapsüllemek için sınırlayıcı kutunun konumunu ve boyutunu iyileştirmeyi amaçlar. Özellik haritası, orijinal görüntünün boyutunun k katı büyüklüğünde altörneklendiği için, genellikle ROI'nin sınırları, özellik haritasının ayrıntı düzeyiyle örtüşmez.

Özellik haritalarını yeniden boyutlandırmak için, isteğe bağlı boyuttaki aday bölgeler için sabit uzunluklu özellik vektörlerini çıkarmak için ROI hizalama katmanı uygulanması gerekmektedir.

Mask R-CNN loss fonksiyonu aşağıdaki gibi hesaplanır:


$$LOSS = L_{class} + L_{reg} + L_{mask} \quad (4)$$

Burada L_{class} her sınıflandırma sonucunun kayıp fonksiyonudur, L_{reg} sınırlayıcı kutuyu belirlemek için kullanılan regresyon sürecinin kayıp fonksiyonudur ve ikili görüntü ile her görüntüde tanımlanan etiket arasındaki farkın karelerinin toplamını göstermektedir, L_{mask} , segmentasyon sonucunun kayıp fonksiyonuna karşılık gelmektedir.

Data seti: Kaggle sitesinden alınan veri seti, tümör hastalarının MR görüntülerinden oluşmakta ve 98 tümörsüz ve 155 tümörlü olmak üzere toplam 253 görüntü veri setinden oluşmaktadır.

Önerilen yöntem olarak MaskR-CNN algoritması bahsi geçen veri seti için uygundur ve algoritma görüntüler üzerindeki pikselleri tarayarak tümörün yerini belirlemeye çalışır ve tümörün doğru tespiti durumunda tümörün yeri kırmızı bir alanda belirlenmektedir.

MR görüntülerine maske R-Cnn uygulamadan önce, bu görüntülerdeki tümörlerin konumunu doğru bir şekilde tahmin etmek için bir veri ön işleme adımı gerçekleştirilmiştir (Şekil 18). Bu şekilde veriler RPN için hazırlanmıştır. Nesnenin varlığı tespit edilirse 1 doğruluk değerini alır ve görsel RPN'de regresyon katmanına geçer. Regresyon katmanında, nesnenin etrafına bir sınırlayıcı kutu çizilir. Bir sonraki adım, RoIAalign katmanına geçmektir. RoIAalign katmanında, her nesne ek olarak uzamsal düzenlemelerine göre maskelenir.




Şekil 18. VIA görüntü açıklayıcı yazılımı ile bir görüntü için gerçek referans maskesi oluşturma.

V.DENEYSEL SONUÇLAR


Bu çalışmada iki farklı deneysel çalışma yapılmıştır. İlk çalışma CNN algoritması ile beyin tümörü sınıflandırması işlemidir. İkinci çalışma ise Mask R-CNN algoritması ile beyin MR görüntülerinde tümörlü olan görüntülerin yer tespitinin yapılmasıdır.

CNN algoritması ile beyin MR görüntüleri kullanılarak iki sınıflı bir sınıflandırma işlemi yapılmıştır. Bu işlem yapılırken 1500 tümörlü 1500 tümörsüz olmak üzere toplamda 3000 adet beyin MR görüntüsü veri olarak kullanılmıştır.



Şekil 19. CNN Algoritmasında kullanılan örnek veri rerimleri

CNN algoritması ile yapılan sınıflandırmada (şelik 19) 0.1273'lük bir kayıp oranı ile 0.9689 oranında başarılı bir doğruluk sonucu elde edilmiştir (şekil 20).



Şekil 20. CNN Algoritması ile elde edilen loss ve accuary değerlerinin grafikleri

Beyin tümörlerinin tespiti için önerilen yöntemde, Mask R-cnn algoritması (Maskeli B-ESA) mimarisini kullanan bir açık kaynak kodu (kaggle\brain-tomur-segmentation) kullanarak MR beyin tümörü tümör var veya tümör yok sınıflandırması ve segmentasyonu yapan derin sınır ağı incelenmiştir.

Çalışmada Mask R CNN mimari omurgası olarak COCO (Lin vd. 2014) ve ImageNet veri setleriyle eğitilmiş mimarileri kullanılmıştır. Model eğitimi için görüntüler el yordamıyla VIA ile GT referansında etiketlenmiş ve her görüntünün sınıf ve segmentasyon bilgisi “.json” formatlı bir dosyada kaydedilmiştir.

A. Veri Seti Hazırlama

Önerilen çalışmada açık kaynak kodu (kaggle\brain-tomur-segmentatio) beyin MR veriseti görüntüleri Kullanılmıştır. Çizelge 9’da görüldüğü gibi tümörlü MR görüntüleri sayısı (155 tümör) tümörsüz MR görüntüleri (tümörsüz 98) gönüntülerden oluşmaktadır. Veri seti kaggle web sitesinde png formatıyla mevcuttur(<https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection>)

Çizelge 9. Önerilen çalışmada kullanılan Veri seti

Tümör	Tümörsüz
155	98

Öncelikle python program dili ile veri seti elde elip “.jpeg” formatında kaydedildi, daha sonra VIA ile el yolu ile tümör doğru bir şekilde istenmiştir.

Verilerin daha verimli olması için MR tümör görüntüleri farklı renkle boyanmıştır sonra kenarları VIA yöntemi ile çizilmiştir (şekil 21) .

Toplamda 255 MR Tümör görüntüsü bulduran veri seti %70'i eğitim, %30'ü test olarak 2 set ayrılmıştır. Bu iki tane setten üzerine bu çalışmada önerilen yöntemi için kullanılacaktır.



Şekil 21. VIA aracı ile kenar belirleme


Temel mimari olarak RESNET101 kullanılırken, eğitim için COCO [26] veri seti ile önceden eğitilmiş bir model kullanılır. MaskR-CNN algoritmasının doğru sonuçlar üretebilmesi için dönem numarasının doğru belirlenmesi çok önemlidir. Burada epoch sayısı veri seti üzerinde uygulanan eğitim sürecinin kümülatif yineleme sayısını ifade etmektedir. Önerilen yöntemde epoch sayısı 15 olarak kullanılmış ve doğruluk oranı %88 ile %94 arasındadır.

Bu çalışmada önerilen yönetim için Epoch sayısı değiştirilerek iki kere deneme segmentasyon işlem yapılmış ve aşağıdaki gibi sonucu vermiştir.

Epoch sayısı 10 ilken; Şekil 22'de loss değerler gösterilmiştir. Şekil 23'te epoch sayıları göre ana loss değeri ve maskrcnn loss değerler göstermektedir.


	val_loss	val_rpn_class_loss	val_rpn_bbox_loss	val_mrcnn_class_loss	val_mrcnn_bbox_loss	val_mrcnn_mask_loss	loss	rpn_class_loss	rpn_bbox_loss	mrcnn_class_loss	mrcnn_bbox_loss	mrcnn_mask_loss
1	0.808066	0.012231	0.298577	0.020535	0.255046	0.221668	1.509480	0.016828	0.429059	0.058002	0.548143	0.457439
2	0.678224	0.008184	0.203095	0.028256	0.232102	0.206579	0.617622	0.006268	0.145680	0.023747	0.229072	0.212848
3	0.505238	0.003835	0.129051	0.027918	0.167628	0.176797	0.677863	0.007571	0.179296	0.028054	0.220223	0.242711
4	0.697039	0.008255	0.263147	0.048955	0.148088	0.168586	0.407842	0.004329	0.107697	0.015829	0.111563	0.168417
5	0.450212	0.003535	0.164885	0.006554	0.094926	0.180305	0.499780	0.005393	0.139566	0.023965	0.133251	0.197598
6	0.421338	0.004434	0.088756	0.035176	0.117475	0.175490	0.383700	0.003204	0.100322	0.016566	0.096770	0.166830
7	0.631814	0.008761	0.166774	0.029964	0.161805	0.264502	0.341238	0.003630	0.082161	0.017483	0.086246	0.151709
8	0.437227	0.003922	0.127684	0.015357	0.130162	0.160095	0.268363	0.002123	0.063834	0.009244	0.053054	0.140101
9	0.496028	0.005283	0.145258	0.038250	0.123921	0.183308	0.282987	0.002034	0.076257	0.007709	0.059591	0.137389
10	0.323976	0.002464	0.082465	0.016555	0.069889	0.152395	0.236550	0.001744	0.052500	0.009147	0.042556	0.130595

Şekil 22. Loss değerleri



Şekil 23. loss değerin grafiği

Epoch sayısı 10 yapıldığı zaman şekilde 23'te her eğitim sonunda bir değer verilmiştir. 10 eğitim den sonra şekil 23. Grafiği elde edilmiştir.



Şekil 24. a

Şekil 24. b


Şekil 24. Eğitim sayısı 10'iken İki farklı görüntünün maskrcnn beyin tümör tespiti ve tahmin değeri

Şekil 24'de mask R-CNN tümör tespit yapılmıştır ve tahmin değeri %88 ile %94 arasında tahmin değeri elde edilmiştir. Epoch sayısı 15 ilken; Şekil 25'te loss değeriler gösterilmiştir.

	val_loss	val_rpn_class_loss	val_rpn_bbox_loss	val_mrcnn_class_loss	val_mrcnn_bbox_loss	val_mrcnn_mask_loss	loss	rpn_class_loss	rpn_bbox_loss	mrcnn_class_loss	mrcnn_bbox_loss	mrcnn_mask_loss
1	0.624136	0.003812	0.199214	0.012113	0.228206	0.180784	1.067947	0.011998	0.222276	0.061386	0.445175	0.327105
2	0.627775	0.003765	0.171778	0.015734	0.232317	0.204174	0.596271	0.005048	0.137886	0.023505	0.196365	0.233459
3	0.360303	0.003083	0.098533	0.011567	0.093035	0.154078	0.465970	0.005773	0.141379	0.020792	0.121623	0.176396
4	0.537905	0.005383	0.215452	0.014752	0.134839	0.167470	0.386069	0.003295	0.086100	0.018563	0.103667	0.174437
5	0.389848	0.002171	0.100739	0.019135	0.106134	0.161661	0.402097	0.004101	0.096285	0.012996	0.101808	0.186899
6	0.379847	0.002899	0.101829	0.013286	0.080833	0.180994	0.275499	0.001265	0.056793	0.015927	0.065643	0.135863
7	0.543418	0.007838	0.148558	0.037331	0.158830	0.190852	0.249631	0.001573	0.043545	0.013544	0.055877	0.135084
8	0.583830	0.010802	0.183072	0.073555	0.129420	0.186974	0.276184	0.001726	0.059957	0.009321	0.061887	0.143285
9	0.393188	0.002734	0.131654	0.004886	0.094071	0.159835	0.181429	0.001075	0.034651	0.005550	0.030769	0.109377
10	0.353410	0.001936	0.086738	0.019111	0.097801	0.147816	0.198179	0.001558	0.033062	0.006716	0.036230	0.120605
11	0.288929	0.000646	0.061713	0.005565	0.059717	0.161280	0.171434	0.000870	0.033751	0.006251	0.027879	0.102676
12	0.589089	0.016109	0.150896	0.063065	0.134960	0.224050	0.158871	0.000782	0.028597	0.004176	0.021887	0.103422
13	0.418830	0.005078	0.167566	0.030232	0.057868	0.158077	0.159735	0.000522	0.029453	0.004013	0.025191	0.100348
14	0.595204	0.011043	0.199447	0.041487	0.125749	0.217470	0.137116	0.000568	0.025385	0.003548	0.018955	0.088652
15	0.352817	0.008969	0.059399	0.032291	0.074838	0.177312	0.137104	0.000583	0.020675	0.004214	0.017795	0.093829


Şekil 25. Loss değerleri

Epoch sayısı 10 yapıldığı zaman şekilde 25'te her eğitim sonunda bir değer verilmiştir. 10 eğitim den sonra şekil 26. Grafiği elde edilmiştir.



Şekil 26. loss değerini grafiği

Şekil 27'te mask R-CNN tümör tespit yapılmıştır ve tahmin değeri %88 ile %95 arasında tahmin değeri elde edilmiştir.



Şekil 27. a

şekil 27. b

Şekil 27. Eğitim sayısı 15'iken İki farklı görüntünün maskrcnn beyin tümör tespiti ve tahmin değeri

VI.GELECEKTE YAPILABİLECEK ÇALIŞMALAR

Beyin tümörü tespiti ve segmentasyonu uzun süredir devam eden bir çalışmadır. Ancak keşfedilen yeni teknolojilerle birlikte, bilim insanlarının ana gündemi, daha ucuz araçlarla tespit süresini olabildiğince kısaltmak. Ayrıca, bu yazıda önerilen modelin temel amacı, hesaplama süresini azaltmak ve maliyeti azaltmaktır.

farklı yaklaşımların yardımıyla. Ana unsur olarak GPU'yu kullanmadan beyin tümörü tespit modelini çalıştırmanın bazı yolları vardır. Modelin doğrudan CPU üzerinde çalışabileceği Intel UP Squared* AI Vision X geliştirici kiti aracı gibi bazı donanım araçları vardır. Bu araçlar GPU'dan daha ucuz olduğundan ve hesaplama süresini azaltmak için CPU ile birlikte çalıştığından, gelecekteki çalışmaların odak noktası bu olacaktır.

VII. SONUÇ

Bu çalışmada, MaskR-CNN algoritması kullanılarak tümör görüntülerinde tümör lokasyonunun belirlenmesi amaçlanmıştır. Tespit için 3*3 çekirdek oluşturulur ve görüntü boyunca soldan sağa doğru hareket ettirilir. maskR-Cnn, belirtilen niteliklere göre sınıflandırarak tümörün yerini tespit eder. Bu kapsamda elde edilen doğruluk oranı %88 ile %94 arasındadır. Algoritmalar python 3 ile uygulanmaktadır, ve 12 GB belleğe sahip 2.59 GHz Intel i7 altıncı nesil CPU ve NVIDIA GeForce GTX 950m grafik kartına sahip bir platformda çalışıyor. Bu çalışmada kullanılan MR görüntüleri, araştırma amacıyla <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection> adresinde ücretsiz olarak mevcuttur.

VIII. KAYNAKÇA

MAKALELER

- ABDEL-MAKSoud, E., AL-AWADİ, R. & ELMOGY, M., (2015). “Brain Tumor Segmentation Based On A Hybrid Clustering Technique”. **Egyptian Informatics Journal**, 16(1), 71-81.
- ABİDİN, A. Z., DAR, I., D'SOUZA, A. M., LİN, E. P., & WISMÜLLER, A. (2019). “Investigating A Quantitative Radiomics Approach For Brain Tumor Classification”. In **Medical Imaging 2019: Biomedical Applications in Molecular, Structural, and Functional Imaging**, (Vol. 10953, pp. 36-45). SPIE.
- ABİWİNANDA, N., HANİF, M., HESAPUTRA, S.T., HANDAYANİ, A., MENGKO, T.R., (2019). “Brain Tumor Classification Using Convolutional Neural Network”. **World Congress on Medical Physics and Biomedical Engineering 2018**, Springer, pp. 183–189.
- ABU-BAKAR, S. A. R. MOUSAVİ, S. M., & NAGHSH, A., (2015). “A Heuristic Automatic And Robust ROI Detection Method For Medical Image Watermarking”. **Journal of digital imaging**, 28(4), 417-427.
- AFSHAR, P., MOHAMMADİ, A., & PLATANİOTİS, K. N. (2018). “Brain Tumor Type Classification Via Capsule Networks”. **IEEE international conference on image processing (ICIP)** (pp. 3129-3133).
- AFSHAR, P., MOHAMMADİ, A., & PLATANİOTİS, K. N. (2018). “Brain Tumor Type Classification Via Capsule Networks”. **IEEE international conference on image processing (ICIP)**. (pp. 3129-3133). IEEE.
- AKKUS, Z., ALİ, I., SEDLAR, J., KLİNE, T. L., AGRAWAL, J. P., PARNEY, I. F., ... ERİCKSON, B. J. (2016). “Predicting 1p19q Chromosomal Deletion Of Low-Grade Gliomas From MR Images Using Deep Learning”. **arXiv preprint arXiv:1611.06939**.

- AL-TAMİMİ, M. S. H., & SULONG, G. (2014). "Tumor Brain Detection Through Mr Images: A Review Of Literature". **Journal of Theoretical & Applied Information Technology**, 62(2).
- ANARAKİ, A. K., AYATİ, M., & KAZEMİ, F. (2019). "Magnetic Resonance Imaging-Based Brain Tumor Grades Classification And Grading Via Convolutional Neural Networks And Genetic Algorithms". **biocybernetics and biomedical engineering**, 39(1), 63-74.
- ASKARİ, M., & KEYNİA, F. (2020). "Mid- Term Electricity Load Forecasting By A New Composite Method Based On Optimal Learning MLP Algorithm". **IET Generation, Transmission & Distribution**, 14(5), 845-852.
- ASLAN, M. (2022). "Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti". **Fırat Üniversitesi Mühendislik Bilimleri Dergisi**, 34(1), 399-407.
- BAUER, S. et al. (2013). "Integrated Segmentation Of Brain Tumor Images For Radiotherapy And Neurosurgery". **International Journal of Imaging Systems and Technology**, 23(1), pp. 59–63.
- BAUER, S., WIEST, R., NOLTE, L. P., & REYES, M. (2013). "A Survey Of MRI-Based Medical Image Analysis For Brain Tumor Studies". **Physics in Medicine & Biology**, 58(13), R97.
- BHANOTHU, Y., KAMALAKANNAN, A., & RAJAMANICKAM, G. (2020). "Detection And Classification Of Brain Tumor In MRI Images Using Deep Convolutional Network". In **2020 6th international conference on advanced computing and communication systems (ICACCS)**, (pp. 248-252). IEEE.
- BİSHT, R., VIJAY, R., & SINGH, S. (2018). "Comparative Analysis of Fixed Valued Impulse Noise Removal Techniques for Image Enhancement". **International Conference on Advances in Computing and Data Sciences**, (pp. 175-184). Springer, Singapore.
- BRUNESE, L., MERCALDO, F., REGINELLI, A., & SANTONE, A. (2020). "An Ensemble Learning Approach For Brain Cancer Detection Exploiting Radiomic Features". **Computer methods and programs in biomedicine**, 185, 105134.
- BULUT, F., KILIÇ, İ., & İNCE, İ. F. (2018). "Beyin Tümörü Tespitinde Görüntü Bölütleme Yöntemlerine Ait Başarımların Karşılaştırılması Ve

- Analizi”. **Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi**, 20(58), 173-186.
- CHARTRAND, G., CHENG, P. M., VORONTSOV, E., DROZDZAL, M., TURCOTTE, S., PAL, C. J., ... & TANG, A. (2017). “Deep Learning: A Primer For Radiologists”. **Radiographics**, 37(7), 2113-2131.
- CHENG, J., HUANG, W., CAO, S., YANG, R., YANG, W., YUN, Z., WANG, Z., FENG, Q., (2015). “Enhanced Performance Of Brain Tumor Classification Via Tumor Region Augmentation And Partition”. **PLoS One** **10**, e0140381.
- CHOUDHARY, R., & GIANEY, H. K. (2017). “Comprehensive Review On Supervised Machine Learning Algorithms. **2017 International Conference on Machine Learning and Data Science (MLDS)**, (pp. 37-43). IEEE.
- DAMODHARAN, S. and RAGHAVAN, D. (2015). “Combining Tissue Segmentation and Neural Network for Brain Tumor Detection”. **International Arab Journal of Information Technology (IAJIT)**, 12(1), 42-52.
- DREVELEGAS, A., & PAPANIKOLAOU, N. (2011). “Imaging Modalities In Brain Tumors. In Imaging Of Brain Tumors With Histological Correlations” **Springer, Berlin, Heidelberg**. (pp. 13-33).
- GHOSH, S., & DUBEY, S. K. (2013). “Comparative Analysis Of K-Means And Fuzzy C-Means Algorithms”. **International Journal of Advanced Computer Science and Applications**, 4(4).
- GIRSHICK, R., DONAHUE, J., DARRELL, T., & MALIK, J. (2014). “Rich Feature Hierarchies For Accurate Object Detection And Semantic Segmentation”. **IEEE conference on computer vision and pattern recognition**, (pp. 580-587).
- HASSAN, E. and ABOSHGİFA, A. (2015). “Detecting Brain Tumour From MR Image Using Matlab GUI Programme”. **International Journal of Computer Science & Engineering Survey** 6(6), pp. 47–60.
- Hays, A. et al. (2013), “Tumor Types: Understanding Brain Tumors”, **Frankly Speaking About Cancer Series, Cancer Support Community**.
- HE, K., GKİOXARİ, G., DOLLÁR, P., & GİRSHİCK, R. (2017). “Mask R-Cnn. **IEEE international conference on computer vision** (pp. 2961-2969).

- HUSSAIN, S., ANWAR, S. M., MAJID, M. (2017). "Brain Tumor Segmentation Using Cascaded Deep Convolutional Neural Network". In **39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**, pp. 1998-2001, 11-15 July, South Korea.
- IBRAHIM, W. H., OSMAN, A., and MOHAMED Y. I., (2013). "MRI Brain Image Classification Using Neural Networks" **IEEE International Conference on Computing, Electrical and Electronics Engineering, ICCEEE**.
- LAKHANI, P., PRATER, A. B., HUTSON, R. K., ANDRIÖLE, K. P., DREYER, K. J., MOREY, J., ... & HAWKINS, C. M. (2018). "Machine Learning In Radiology: Applications Beyond Image Interpretation". **Journal of the American College of Radiology**, 15(2), 350-359.
- LECUN, Y., BENGIO, Y., & HINTON, G. (2015). "Deep Learning". **nature**, 521(7553), 436-444.
- LIN, T.-Y., MAIRE, M., BELONGIE, S., HAYS, J., PERONA, P., RAMANAN, D., ZITNICK, C. L. (2014). "Microsoft Coco: Common Objects In Context". **the European conference on computer vision**. (pp. 740-755). Springer, Cham.
- LOUIS, D. N., OHGAKI, H., WIESTLER, O. D., CAVENEE, W. K., BURGER, P. C., JOUVET, A., ... & KLEIHUES, P. (2007). "The 2007 WHO Classification Of Tumours Of The Central Nervous System". **Acta neuropathologica**, 114(2), 97-109.
- MENZE, B. H., JAKAB, A., BAUER, S., KALPATHY-CRAMER, J., FARAHANI, K., KIRBY, J., ... & Van LEEMPUT, K. (2014). "The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS)". **IEEE transactions on medical imaging**, 34(10), 1993-2024.
- MILLER, K., WITTEK, A., & JOLDES, G. (2010). "Biomechanics Of The Brain For Computer-Integrated Surgery". **Acta of Bioengineering and Biomechanics**, 12(2), 25-37.
- MOLDAGULOVA, A., & SULAIMAN, R. B. (2017). "Using KNN Algorithm For Classification Of Textual Documents". In **2017 8th international conference on information technology (ICIT)**, (pp. 665-671). IEEE.
- MUHAMMAD, K., AHMAD, J., Lv, Z., BELLAVISTA, P., YANG, P., & BAIK, S. W. (2018). "Efficient Deep CNN-Based Fire Detection And Localization

- In Video Surveillance Applications”. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, 49(7), 1419-1434.
- MUSTAQUEEM, A., JAVED, A., & FATİMA, T. (2012). “An Efficient Brain Tumor Detection Algorithm Using Watershed & Thresholding Based Segmentation”. **International Journal of Image, Graphics and Signal Processing**, 4(10), 34.
- NABİZADEH, N. (2015). “Automated Brain Lesion Detection And Segmentation Using Magnetic Resonance Images”. **University of Miami**.
- PATEL, N., SHAH, A., MİSTRY, M., & DANGARWALA, K. (2014). “A Study Of Digital Image Filtering Techniques In Spatial Image Processing”. **2014 International Conference on Convergence of Technology**, (I2CT) (pp. 1-6).7
- PAUL, J. S., PLASSARD, A. J., LANDMAN, B. A., & FABBRI, D. (2017). “Deep Learning For Brain Tumor Classification”. **In Medical Imaging 2017: Biomedical Applications in Molecular, Structural, and Functional Imaging** (Vol. 10137, pp. 253-268). SPIE.
- PEDAPATİ, P.ve TANNEDİ, R.V. (2018). “Brain Tumour Detection Using HOG by SVM”, **IEEE Transactions on Medical Imaging** 35(5), pp. 1240–1251.
- PESAPANE, F., CODARİ, M., & SARDANELLI, F. (2018). “Artificial Intelligence In Medical Imaging: Threat Or Opportunity? Radiologists Again At The Forefront Of Innovation In Medicine”. **European radiology experimental**, 2(1), 1-10.
- RAMTEKE, R. J., & MONALI, K. Y. (2012). “Automatic Medical Image Classification And Abnormality Detection Using K-Nearest Neighbour”. **International Journal of Advanced Computer Research**, 2(4), 190.
- RANA, R., BHADAURİA, H. S., & SİNGH, A. (2013). “Study Of Various Methods For Brain Tumour Segmentation From MRI Images”. **International Journal of Emerging Technology and Advanced Engineering**, 3(2), 338-342.
- REN, S., HE, K., GİRSHİCK, R., & SUN, J. (2015). “Faster R-Cnn: Towards Real-Time Object Detection With Region Proposal Networks”. **neural information processing systems**, 28.
- SAJJAD, M., KHAN, S., MUHAMMAD, K., WU, W., ULLAH, A., & BAİK, S. W. (2019). “Multi-Grade Brain Tumor Classification Using Deep CNN With

- Extensive Data Augmentation”. **Journal of computational science**, 30, 174-182.
- SOLTANİNEJAD, M., YANG, G., LAMBROU, T., ALLİNSON, N., JONES, T. L., BARRİCK, T. R., ... Ye, X. (2018). “Supervised Learning Based Multimodal MRI Brain Tumour Segmentation Using Texture Features From Supervoxels”. **Computer methods and programs in biomedicine**, 157, 69-84.
- SWATİ, Z. N. K., ZHAO, Q., KABİR, M., ALİ, F., ALİ, Z., AHMED, S., & LU, J. (2019). “Brain Tumor Classification For MR İmages Using Transfer Learning And Fine-Tuning”. **Computerized Medical Imaging and Graphics**, 75, 34-46.
- TAS, M. O., & ERGİN, S. (2020). “Detection of the Brain Tumor Existance Using a Traditional Deep Learning Technique and Determination of Exact Tumor Locations Using K-Means Segmentation in MR Images”. **İleri Mühendislik Çalışmaları ve Teknolojileri Dergisi**, 1(2), 91-97.
- THAHA, M. M., KUMAR, K. P. M., MURUGAN, B. S., DHANASEKERAN, S., VİJAYAKARTHİCK, P., SELVİ, A. S. (2019). “Brain Tumor Segmentation Using Convolutional Neural Networks İn MRI İmages”. **Journal of medical systems**, 43(9), 294.
- VEMBANDASAMY, K., SASİPRİYA, R., & DEEPA, E. (2015). “Heart Diseases Detection Using Naive Bayes Algorithm. International Journal Of Innovative Science”, **Engineering & Technology**, 2(9), 441-444.
- VİSHWANATHAN, S. V. M., & MURTY, M. N. (2002). SSVM: “A Simple SVM Algorithm. In Proceedings Of The 2002 International Joint Conference On Neural Networks”. **IJCNN'02**, (Cat. No. 02CH37290) (Vol. 3, pp. 2393-2398). IEEE.
- ZHANG, L., LİN, L., LİANG, X., & HE, K. (2016). “Is Faster R-CNN Doing Well For Pedestrian Detection?”. **European conference on computer vision** (pp. 443-457). Springer, Cham.
- ZİA, R., AKHTAR, P., & AZİZ, A. (2018). “A New Rectangular Window Based Image Cropping Method For Generalization Of Brain Neoplasm Classification Systems”. **International Journal of Imaging Systems and Technology**, 28(3), 153-162.

ELEKTRONİK KAYNAKLAR

- URL-1 “Mayfield Brain and Spine 1999. Anatomy of the Brain”,
<https://www.mayfieldclinic.com/pe-anatbrain.htm> , (Erişimi Tarihi: 14 Temmuz 2022).
- URL-2 “Fuzzy c-means segmentation”,
<https://www.mathworks.com/matlabcentral/fileexchange/25532-fuzzy-c-means-segmentation> , (Erişimi Tarihi: 15 Temmuz 2022).
- URL-3 “Logistic regression”, <https://www.medcalc.org/manual/logistic-regression.php> (Erişimi Tarihi: 15 Temmuz 2022).
- URL-4 “Brain MRI Images for Brain Tumor Detection”,
<https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection> (Erişimi Tarihi: 21 Temmuz 2022).

ÖZGEÇMİŞ

Ad- Soyad : Hasan BAŞYILDIZ

Öğrenim Durumu:

- **Lisans:** 2019, İstanbul Sabahattin Zaim Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği
- **Yüksek Lisans:** 2022, İstanbul Aydın Üniversitesi Bilgisayar Mühendisliği

TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- BASYILDIZ H. & SHAMS P. (2022), “Detection of Brain Tumors with Help of Mask R CNN”, International Journal of Advances in Engineering and Management (IJAEM) Volume 4 , Issue 7, July 2022 , pp : 890-894.