
GAZİ ÜNİVERSİTESİ
Gazi
1926

BEYİN TÜMÖR TESPİTİ İÇİN DERİN ÖĞRENME TEMELLİ BİLGİSAYAR DESTEKLİ TANI SİSTEMİ

Tarıkcan DOĞANAY

YÜKSEK LİSANS TEZİ
SAĞLIK BİLİŞİM ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ

HAZİRAN 2022

Tarıkcan DOĞANAY tarafından hazırlanan "BEYİN TÜMÖR TESPİTİ İÇİN DERİN ÖĞRENME TEMELLİ BİLGİSAYAR DESTEKLİ TANI SİSTEMİ" adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ / OY ÇOKLUĞU ile Gazi Üniversitesi Sağlık Bilişimi Ana Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç.Dr.Oktay YILDIZ

Bilgisayar Mühendisliği Bölümü, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum. ...……

Başkan: Prof.Dr.Serdar KULA

Çocuk Sağlığı ve Hastalıkları Anabilimdalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum. ……...

Üye: Doç.Dr. Mustafa SERT

Bilgisayar Mühendisliği Bölümü, Başkent Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum. ……...

Tez Savunma Tarihi: 08/06/2022

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

…….…….

Prof. Dr. Aslıhan TÜFEKCİ

Bilişim Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Bilişim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Tarıkcan DOĞANAY

...../……/……

BEYIN TÜMÖR TESPİTİ İÇİN DERİN ÖĞRENME TEMELLİ BİLGİSAYAR DESTEKLİ TANI SİSTEMİ

(Yüksek Lisans Tezi)

Tarıkcan DOĞANAY

GAZİ ÜNİVERSİTESİ

BİLİŞİM ENSTİTÜSÜ

Haziran 2022

ÖZET

Beyin tümörü, insan vücudunun sinir sistemini etkileyen en tehlikeli kanser türlerinden birisidir. Tümör hastalığı durumunda beyin hücrelerinin yenilenmesi çok zor bir durumdur. Kötü ve iyi huylu olmak üzere iki tür beyin tümörü sınıflandırılması yapılır. İyi huylu tümör büyük ölçüde diğer hücrelere ve beyine yayılmaz. Doğru tedavi ile hastalık atlatılabilir. Kötü huylu tümör çok tehlikelidir. Doğru tedavi yapılmaz ise diğer hücrelere ve beyine çok hızlı bir şekilde yayılabilir. Beyin tümörünün teşhisi hassas ve karmaşık bir işlemdir. Beyin MRG segmentasyonu klinik uygulamalarda önem arz etmektedir. Beyin analizi çeşitli yaklaşımlarla bulgular ve anatomik bölgelerin doğru segmentasyonuna dayanır. Beyin MRG analizi, epilepsi, şizofreni, Alzheimer, kanser ve bulaşıcı dejeneratif hastalıklar gibi beyin bozukluklarının tedavisi için yaygın bir şekilde kullanılmaktadır. Hasta MRG doktorlar tarafından manuel segmentasyonu görüntülerin dilim dilim ana hatlarının çıkarılmasını gerektirir. Ancak manuel segmentasyonun uzman görüşü ve teknolojik kısıtları nedeniyle bazı dezavantajları vardır. Bununla birlikte görüntü yorumlama son derece zaman alan bir işlemdir. Tecrübeye bağlı olarak hata yapma oranı da yüksektir. Bu çalışmada, beyin MRG otomatik tümör tespiti için uçtan uca Çok Ölçekli Çok Düzeyli Ağ (Multi-Scale Multi-Level Network MM-Network) modeli önerilmiştir. Gerçekleştirilen çalışmada, Unet'teki evrişimli ağ seviyesinde çoklu uzamsal ölçeklerin küresel bağlamsal özelliklerini birleştirerek, ağlar boyunca özellik haritalarının boyutuna bağlı olarak alıcı alanın farklı oranlarda genişlemesini sağlayan genişletilmiş evrişim modülünden yararlanılmıştır. Yapılan deneysel çalışmalarda önerilen model ile yüksek doğrulukta tümör tespiti sağlanmıştır.

Bilim Kodu	:	93008
Anahtar Kelimeler	:	Derin öğrenme, bilgisayar destekli tanı sistemi, segmentasyon
Sayfa Adedi	:	61
Danışman	:	Doç.Dr. Oktay YILDIZ

DEEP LEARNING BASED COMPUTER AIDED DIAGNOSTIC SYSTEM FOR BRAIN TUMOR DETECTION

(M. Sc. Thesis)

Tarıkcan DOGANAY

GAZİ UNIVERSITY

INFORMATICS INSTITUTE

June 2022

ABSTRACT

Brain tumor is one of the most dangerous types of cancer that affects the nervous system of the human body. Regeneration of brain cells in the case of tumor disease is a very difficult situation. There are two types of brain tumors classified as malignant and benign. The benign tumor largely does not spread to other cells or to the brain. With the right treatment, the disease can be overcome. A malignant tumor is very dangerous. If not treated properly, it can spread to other cells and the brain very quickly. Diagnosing a brain tumor is a delicate and complex process. Brain MRI segmentation is important in many clinical applications. Brain analysis is based on various approaches, findings, and correct segmentation of anatomical regions. Brain MRI quantitative analysis has been used commonly for the characterization of brain disorders such as epilepsy, schizophrenia, Alzheimer's disease, cancer, and infectious degenerative diseases. In this study, an end-to-end deep learning segmentation method called Multi-Scale Multi-Level Network MM-Network has been developed. The main idea is to combine the global contextual features of multiple spatial scales at the convolutional network level in Unet. In addition, the extended convolution module is used, which allows the receptive field to expand at different rates depending on the size of the feature maps throughout the networks. The MM-Network model applied in this study was used for tumor segmentation in brain MRI images, and successful results were obtained.

Science Code	:	93008
Key Words	:	Deep learning, computer aided diagnosis system, segmentation
Page Number	:	61
Supervisor	:	Assoc. Prof. Dr. Oktay YILDIZ

TEŞEKKÜR

Bu çalışmanın hazırlanmasında desteklerini esirgemeyen başta değerli danışman hocam Doç. Dr. Oktay YILDIZ'a, saygıdeğer bölüm başkanım Prof. Dr. Serdar KULA ve Op. Dr. Hülya KULA'ya, saygıdeğer hocam Doç. Dr. Mustafa SERT'e teşekkür ederim. Ayrıca çalışmalarım boyunca büyük bir sabırla ve manevi destekleri ile yanımda olan aileme minnettarım.

İÇİNDEKİLER

Sayfa

ÖZET iv
ABSTRACT v
TEŞEKKÜR vi
İÇİNDEKİLER vii
ÇİZELGELERİN LİSTESİ ix
ŞEKİLLERİN LİSTESİ x
SİMGELER VE KISALTMALAR xv
1. GİRİŞ 1
2. LİTERATÜR TARAMASI 7
3. GENEL KAVRAMLAR 11
3.1. Tıbbi Görüntüleme Teknikleri 11
3.1.1. Röntgen (X-ray) görüntüleme 11
3.1.2. Bilgisayar tomografi (BT) 13
3.1.3. Manyetik rezonans görüntüleme (MRG) 15
3.1.4. Ultrason görüntüleme 17
3.2. Yapay Zeka ve Veriden Öğrenme 19
3.2.1. Makine öğrenmesi 20
3.2.2. Derin öğrenme 22
3.3. Python İle Derin Öğrenme 30
3.3.1. Keras ve tensorflow kütüphanesi 30
3.3.2. Optimizasyon algoritmaları 31
3.4. Model Performansının Değerlendirilmesi 34
4. DERİN ÖĞRENME TEMELLİ BEYİN TÜMÖR TESPİTİ 37
4.1. Veri Kümesi 37
4.2. Önerilen Unet Tabanlı Derin Öğrenme Mimarisi 40
4.3. Kodlama Bloğu (Encoder) 43
4.4. Piramit Havuzlama (PPM) 43
4.5. Kod Çözücü (Decoder) 44
4.6. Softmax 45

Sayfa

5. DENEYSEL ÇALIŞMA ve BULGULAR 47
6. SONUÇ VE DEĞERLENDİRME 51
KAYNAKLAR 55
ÖZGEÇMİŞ 61

ÇİZELGELERİN LİSTESİ

Çizelge **Sayfa**

Çizelge 5.1. Parametre karşılaştırma..... 47

Çizelge 5.2. Optimizer karşılaştırma..... 47

Çizelge 5.3. Karışıklık matris sonucu 48

Çizelge 6.1. Tümör segmentasyon performansı..... 51

ŞEKİLLERİN LİSTESİ

Şekil **Sayfa**

Şekil 3.1. X-ray radyografik tıbbi görüntüleme 12
Şekil 3.2. X-ray görüntü örnekleri 12
Şekil 3.3. BT görüntüleme 14
Şekil 3.4. BT tarama örnekleri 14
Şekil 3.5. Manyetik rezonans sistem 16
Şekil 3.6. MRG tarama örnekleri 16
Şekil 3.7. Ultrason makine 18
Şekil 3.8. Ultrason tarama örneği 18
Şekil 3.9. Yapay zeka kapsamı 20
Şekil 3.10. Evrişimsel sinir ağı çalışma prensibi 23
Şekil 3.11. 3D Görüntü girdisi matris 24
Şekil 3.12. Maksimum örnekleme işlemi 25
Şekil 3.13. Alexnet model 26
Şekil 3.14. ResNet50 model 27
Şekil 3.15. GoogleNet model 28
Şekil 3.16. Unet mimarisi 29
Şekil 3.17. Karışıklık matrisi 34
Şekil 4.1. Koronal kesit 37
Şekil 4.2. Sagital kesit 38
Şekil 4.3. Aksiyal kesit 38
Şekil 4.4. Tümör hücresi içeren ve içermeyen örnek beyin MRG görüntüsü 39
Şekil 4.5. MRG Flair, T2 ve T1ce kesitleri 39

Şekil **Sayfa**

Şekil 4.6. MRG Flair ve T2 kesitlerinin birleştirilmiş görüntüsü 40

Şekil 4.7. Blok diyagram 41

Şekil 4.8. Önerilen modelin alt yapı mimarisi. 42

Şekil 4.9. Kodlayıcı blok kısmı..... 43

Şekil 4.10. Kod çözücü blok kısmı 44

Şekil 4.11. Softmax aktivasyon fonksiyon grafiği..... 45

Şekil 5.1. Tümör segmentasyon..... 48

Şekil 5.2. Zar benzerlik katsayısı grafiği 49

Şekil 5.3. Hata oranı..... 50

Şekil 6.1. Önerilen model ile diğer modellerin duyarlılık karşılaştırılması..... 51

Şekil 6.2. Önerilen model ile diğer modellerin özgüllük karşılaştırılması 53

Şekil 6.3. Önerilen model ile diğer modellerin doğruluk karşılaştırılması..... 54

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	**Açıklamalar**
KeV	Kiloelektron-volt
kHz	Kilohertz
MHz	Megahertz
m^2	Metrekare

Kısaltmalar	**Açıklamalar**
DSÖ	Dünya Sağlık Örgütü
YRG	Yüksek riskli glioma
DRG	Düşük riskli glioma
MRG	Manyetik rezonans görüntüleme
fMRG	Fonksiyonel manyetik rezonans görüntüleme
BT	Bilgisayar tomografi
BDOST	Bilgisayar destekli otomatik tespit sistemi
BDT	Bilgisayar destekli tanı
ESA	Evrişimsel sinir ağı
CNN	Convolutional neural network
PSPNET	Piramit ayrıştırma ağı
UNET	Biyomedikal için evrişimli ağ
BESA	Bölgesel evrişimsel sinir ağı
BDTS	Bilgisayar destekli tanı sistemi
BDT	Bilgisayar destekli tanı
HPU-NET	Hibrit piramit unet
HTTU-Net	Hibrit iki kanallı unet
X-RAY	Röntgen
RF	Radyo frekans

Kısaltmalar	Açıklamalar
TSA	Tekrarlayan sinir ağı
MÖ	Makine Öğrenmesi
YSA	Yapay sinir ağı
DÖ	Derin öğrenme
GP	Gerçek pozitif
YP	Yanlış pozitif
GN	Gerçek negatif
YN	Yanlış negatif
PPM	Piramit havuzlama modülü

1. GİRİŞ

Beyin tümörü, kanser enfeksiyonlarının en ölümcül ve etkili türlerinden birisidir. Hücrelerin anormal ve hızlı bir şekilde çoğalması tümör olasılığını yüksek oranda artırır. Beyin tümörlerinin oluşması sadece beyin hücrelerinde değil, beyin etrafındaki zar, sinir ve bezlerde de oluşmaktadır. Tümör, beyin hücrelerine doğrudan zarar verip birçok hastalığa neden olur [1].

Beyin tümörü, beyindeki biyolojik hücrelerin bir kitlesi ve birikimidir. Bu hücreler, tedavi edilen beyin hücrelerinden farklı olarak anormal hücreler olarak sınıflandırılır. Bu hücreler, beyni çevreleyen sert kafatasının içinde büyür ve boyut olarak artar. Beyin tümörleri farklı şekillerde, yaygın olarak birincil ve ikincil veya iyi ve kötü huylu tümörler olarak sınıflandırılmaktadır. Birincil tümör, beyin hücrelerinde, beyin dokularında veya beynin herhangi bir yerinde meydana gelen tümör olarak adlandırılmaktadır. Vücudun herhangi bir yerinde konumlanarak beyin dokularına kadar ulaşan tümör tipine ikincil tümör olarak adlandırılır [2].

Beyin tümörleri iyi ve kötü huylu olarak iki farklı şekilde sınıflandırıldıkları için yapıları birbirinden farklıdır. İyi huylu tümörler aynı yapılara sahiptir ve büyümeleri yavaştır. İyi huylu tümörlerde hayati risk en alt seviyededir. Erken ve doğru teşhis ile tümör hücreleri, beyin ve vücudun diğer hücrelerine yayılması engellenebilir. Fakat kötü huylu tümörler daha tehlikelidir ve hayati risk taşımaktadır.

Dünya Sağlık Örgütü (DSÖ) (World Health Organization-WHO) tümör derecelendirme şemasına göre gliomalar, iki gruba ayrılmaktadır. Birincisi Yüksek Riskli Glioma (YRG) diğeri Düşük Riskli Glioma (DRG)'dir. Yüksek Riskli Gliomalar, yetişkin insan hücrelerinde sık görülmektedir. Glioma, glial hücrelerinden oluşmaktadır. Yetişkin insanlarda sık görüldüğü için tıp camiasının odak noktası olmuştur. Beyin tümör hücrelerinin tedavisi için önemli faktörler göz önünde bulundurulmalıdır. Bu faktörler, hastanın genel durumu, yaşı, operasyon sırasında hastaya etki edebilecek ek problemlerin olup olmaması, tümörün şekli,yerleşim yeri ve tipidir. Kişiye özel bir tedavi uygulandığından dolayı zorlu bir tedavi sürecidir. Bu nedenle tedavi sürecinde doğru ve erken teşhis çok önemli faktördür [3].

Herhangi bir hastalık türünün erken tespiti, hastanın iyileşmesinde ve hayatta kalma olasılıklarını artıran kilit bir noktadır. Erken teşhis, hastaların hayati tehlikesini azaltır ve

tedavi olma umutlarını neredeyse %90'a çıkarır. Ancak tümörün erken tespiti, hastanın tüm değerlendirme süreçlerinde uzman kişilerin müdahalesini içeren bir süreçtir. Beyin tümörü tanısında radyoloji görüntüleme sistemi önemli rol oynamaktadır. Özellikle beyin tümörü hakkında ön bilgi olması için hastaya Manyetik Rezonans çekilmektedir. Sonrasında tümörün net bir şekilde anlaşılıp tanı koymak için ise hastaya patoloji laboratuvar incelemesi yapılır. Beyin tümörünün tanı ve tedavi planlaması açısından radyoloji görüntüleme yöntemleri son derece önemlidir [4].

Radyoloji görüntüleme cihazlarının semptomlara, incelenen bölgeye, kullanılabilirliğine ve maliyetine göre birçok çeşidi vardır. Tümör hücrelerinin tanısı için yaygın bir şekilde Manyetik Rezonans Görüntüleme (MRG) ve Bilgisayar Tomografi (BT) taramaları kullanılır [5].

Bilgisayarlı Tomografi, x-ışını kullanılarak hasta vücudunun belirli bir bölgesini kesitsel görüntüsünü oluşturmaya yönelik teşhis yöntemlerinden biridir. Normal görüntüyü tümörden ayırmak için BT taramalarında gri skala yöntemi kullanılır [5].

Manyetik Rezonans Görüntüleme, güçlü manyetik alan ve radyo frekans dalgalarını kullanarak hiçbir cerrahi işlem gerektirmeden yumuşak doku hakkında detaylı bilgi verir. Beyin MRG sistemi, tümörlerin tanı ve tedavi sonrası vücut takibinde günümüzde yaygın olarak kullanılır. Beyin ve çevresinde oluşan anormal sinyal hareketlerini, beyin manyetik rezonans görüntüleme sistemi kolaylıkla tespit edebilmektedir. Bu nedenle tümör tespitlerinde sıklıkla kullanılmaktadır [6].

Tek sekans ile çekim yapılan beyin MRG tümör hakkında net bilgi veremeyebilirler. Çünkü tümör hücreleri birçok biyolojik hücrelerden oluşur. Aynı zamanda tümörün komşu beyin yapılarında oluşturduğu etkiler de uygulanacak tedavi yöntemi açısından önemlidir. Bundan dolayı MRG'de aynı bölgeye ait üç farklı sekans çekimi yapılır. Bu çekimler T1 ağırlıklı, T2 ağırlıklı ve proton ağırlıklı çekimlerdir. Bu çekimlere göre radyolog hasta görüntüsü üzerinden tümör hücrelerini yorumlar. Radyolog tarafından tümör varlığı açısından negatif olarak yorumlanırsa, tümör riski güvenli bir şekilde dışlanır. Pozitif bir yorum olursa tümör yerini, şeklini ve derecesini tanımlar [7]. Bu tanımlamada, uzman yorumu çok etkin bir rol oynamaktadır. Dünya genelinde hasta sayısının yükselmesinden dolayı uzmanların iş yükü günden güne artmaktadır.

Dünya Sağlık Örgütü'nün raporlarına göre dünya genelinde her yıl beyin tümöründen etkilenen hastaların sayısı artmaktadır [8]. Uzmanların tümör tespit etme süreci tümörün farklı şekil, büyüklük ve farklı alanlarda olabilme ihtimalinden dolayı karmaşık duruma gelmektedir. Bu yüzden beyin tümör tespiti hataya açık ve zaman alıcı bir süreçtir. Uzmanın deneyimi, yeteneği ve bilgisi tümör tespit başarımını etkilemektedir. Hasta sayısının günden güne arttığı bir ortamda uzmanların, hasta görüntüsünün manuel olarak yorumlaması hata riskini ve iş yükünü artırabilir. Bu nedenle, beyin tümörünün otomatik olarak tespit edilmesi işlemine ihtiyaç duyulmaktadır. Bilgisayar Destekli Tanı Sistemi (BDTS) ile uzmanların tespit sürecinde harcadığı süreleri azaltmak ve doğru teşhis için sıklıkla kullanılan yöntemdir. Bu sistemin amacı, uzmanların hızlı, güvenilir ve doğru karar verebilmelerine destek olmaktır [9]. Yüksek doğruluk oranı bu tez çalışmasının ana hedefi ve odak noktasıdır. Bilgisayar destekli tanı sistemi yapılabilmesi için tıbbi görüntüleme cihazlarından alınan veriler son derece önemlidir.

Hekimler tarafından medikal görüntülerin manuel olarak sınıflandırılması, değerlendirilmesi ve analiz edilmesi hem zaman hem de maliyet yönünden olumsuz etkilenilmektedir. Hassas veri olarak da bilinen medikal görüntüler, analiz edilen kişiler tarafından yanlış bir yorum ya da değerlendirme yapılması hasta açısından hayati önem taşımaktadır. Bunun yanı sıra günden güne tıbbi bakım maliyetleri hızla artmaktadır. Bu yüzden hem zaman hem de maliyet açısından yeni teşhis yöntemlerine ihtiyaç duyulmaktadır. Teknolojinin gelişmesi ile birlikte bilgisayar destekli tanı (BDT), tıbbi görüntüleme ve tanısal radyoloji de çok sayıda önemli araştırma konularından biridir [10].

Hekimlerin muayene süresini ve maliyetini en aza indirmek, gereksiz biyopsi prosedürlerinden kaçınmak ve yüksek verimlilik ile teşhis etmek için yapay zeka ve tıbbi görüntüleme teknolojilerinin BDT yaklaşımı son derece olumludur. Bilgisayar destekli tanı, bilgisayarlı tomografi, manyetik rezonans, röntgen, mamografi gibi medikal görüntüler üzerinden birincil kanser teşhisi için uygun bir yöntemdir. Bilgisayar destekli tanı medikal görüntüler ile hekimler arasında ara katman görevi görmektedir. Bu kısımda dikkat edilmesi gereken nokta BDT sistemi son kararı vermemektedir. Sadece hekimlere karar destek veya referans sağlamaktadır. Örnek vermek gerekirse, kanser erken ve kesin tespitinde hekimlere yardımcı olmaktadır [11].

Bilgisayar sistemi görüntü tanıma ve analizi, dijital görüntü işleme, tıbbi bilgi işleme, yapay zeka gibi alanlarda birden fazla bilim dalı ile ilişkili olarak geliştirilebilmektedir. Bilgisayar destekli tanı sistemi genellikle beyin, meme, akciğer ve diğer kanser türlerinin tespiti için kullanılmaktadır. Bilgisayar destekli tanı teknolojinin gelişmesi ile birlikte literatürde birçok çalışma yapılmıştır. Özgüllük, hassasiyet ve mutlak tespit oranı gibi belirli parametreler çerçevesinde değerlendirilmektedir [12].

Tıbbi görüntüleme, vücudun iç kısımlarını görsel temsil oluşturarak tıbbi analiz ve müdahale için kullanılan tekniktir. Bu işlem, Manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT), X-Ray, Ultrason (US), endoskop, oftalmoskopi ve dermoskopi modaliteleri gibi noninvaziv olarak uygulanır. Görüntüleme modeliteleri hasta tanı, analizi, tedavi planı için önemlidir. BDT sistemi, radyolojik yorumlamalarda örneğin MRG beyin tümörü, tomografi görüntülerinde karaciğer nodülleri, mamografi görüntülerinde meme nodülleri gibi tıbbi görüntülerde var olan tümörlerin ortaya çıkmasını sağlar.

Tümör tanımlanmasına ulaşmak için BDT sistemleri üç ana aşamada gerçekleştirilir: Özellik çıkarma, seçim ve sınıflandırma. Bu üç adımın ayrı ayrı ele alınması ve ardından BDT performans ayarı için birlikte entegre edilmesi gerekir. Tespit aşaması görüntülerdeki şüpheli tümörleri belirlemek, segmentasyon aşaması ise tespit aşamasında belirlenen tümörlerin sınırlarını belirtmek için kullanılır. Görüntü analiz uygulamalarında tıbbi görüntü segmentasyonu BDT sistemi için ön adımdır.

Son zamanlarda tıbbi görüntüleme teknikleri, beyin tümörü, Alzheimer hastalığı ve hafif bilişsel bozukluk teşhisi için kullanılmıştır. Bu tür tıbbi uygulamaların manuel olarak yorumlanması, karmaşık bir organ anatomisi ön bilgisi gerektirdiğinden zorlu bir süreçtir [13]. Ayrıca öznel, hataya açık ve zaman alıcıdır. Daha doğru, hızlı analiz ve teşhis için klinik uygulamalarda otomatik segmentasyon algoritmalarına ihtiyaç duyulmaktadır. Son yıllarda daha düşük maliyet ve daha az kullanıcı müdahalesi ile otomatikleştirilmiş anlamsal bölümleme yöntemleri sağlamak için sayısız gelişmelere tanık olunsa da birçok tıbbi görüntüleme bölümleme görevinde hala zorluklar mevcuttur. Daha spesifik olarak düşük kontrast, karmaşık geometri, düzensiz sınırlar, yüksek sınıflar arası veya sınıf içi varyasyonların yanı sıra bazı görüntüleme modalitelerinde gürültü ve artefakt varlığı, biyomedikal segmentasyon görevlerine ekstra engeller ekler. Bu engelleri ortadan kaldırmak veya en aza indirmek için görüntü segmentasyon yöntemine hakim olmak gerekir [14].

İnsan gözü, görüntüleri bir bütün olarak algılar. Görüntünün arkasından bilgi çıkarımı yapmak doğal ve sezgisel görev olarak işlenir. Bilgisayar için ise görüntü sayılardan oluşan bir matristir. Görüntü segmentasyonu, bilgisayarla görme, uydu görüntüleri gibi alanlarda geniş ve aktif bir araştırma alanına sahiptir. Bilgisayar için amaç belirli bir kişi için görüntüyü anlamlı duruma getirmedir. Çeşitli yöntemler ve yaklaşımlar kullanılır. Belirli bir yöntemin seçimi, çözülecek problemin özelliklerine bağlıdır. Görüntü segmentasyonu, bir görüntünün veya bileşenlerinin tanımlanmasından, sınıflandırılmasında önemli bir adımdır. Diğer bir ifadeyle, piksellerin rengi, şekli, boyutu vb. olabilecek belirli özelliklere dayalı olarak gruplamaktır [15].

Biyomedikal görüntülerin segmentasyonu için birçok yöntem önerilmiştir. Fakat hangi yöntemin en iyisi olduğunu söylemek mümkün değildir. Çünkü yöntemlerin kullanılması segmente edilecek dokunun tipine bağlıdır. Aynı zamanda görüntülerin bileşenlerine,benzerliği olan yerel renk, doku ve diğer özelliklerine göre ayrıştırma işlemi yapılır. Ayrıştırılan görüntüler için farklı işlemler de yapılır. Bu işlemler nesne modellerinde, işaretlemede, görüntü yapılarındaki geometrik incelemelerde yapılır. Segmentasyon işlemi kendi içinde farklı metotlara sahiptir. Manuel, tam ve yarı otomatik gibi farklı metotlar geliştirilmiştir. Otomatik metotların manuel metotlarla kıyaslanması, gerçek hakkında bağımsız bilgi, metodun tekrarlanabilirliği ve subjektif değerlendirme ile ölçülür [16].

Medikal görüntülerin bileşenlerine ayrılması görüntü segmentasyon tekniği ile yapılması mümkündür. Ayrıca görüntü üzerinde anatomik alt yapıların işaretlenmesi ve belirlenmesi yapılmaktadır. Tıp dünyasında cerrahi ve anatomik incelemenin görüntü işlemede karşılığı segmentasyon tekniğidir. Segmentasyon görüntü üzerinde yoğunluk, doku, gradyan veya diğer birçok ölçülebilir özelliklerin birleşimine dayanan nesnel ve öznel metotlar ile elde edilir. Segmentasyon tekniğinin bir diğer önemli noktası, özellik çıkarma ve ayrıştırmaya dayanan istatistiksel örüntü modellemeler oluşturulmaktadır [17].

Literatürde yer alan ve çeşitli çalışmalar yapılan farklı segmentasyon çeşitleri bulunmaktadır. Kullanıcıya bağlı olarak manuel yöntemler, bilgisayar tabanlı yarı otomatik ve tamamen otomatik yöntemler olarak çeşitlendirilmiştir. Segmentasyon, bölge veya piksel (voksel) tabanlı olarak da kullanılmaktadır. Bölge tabanlı teknikler bağıntılı bölgeler bulurlar. Diğer bir ifade ile bir bölgenin karakteristik şekil, doku veya iyi tanımlanmış sınırlar, yoğunluk gibi ortak özellikleri olmalıdır. Piksel tabanlı teknikler bölgenin

karakteristik özelliğine bakılmaz. Her piksel farklı nesneleri ele alır ve ilişkilendirilir. Piksel tabanlı yöntemler grup içi ve gruplar arası farklılıkları incelemek için istatiksel araçlarla birlikte bazı ön işleme yöntemlerini kullanmaktadır. Bir görüntünün segmentasyonu, görüntüden çıkarılan özelliklere dayanır. Görüntünün yoğunluk değeri en belirleyici özelliklerden biridir. Görüntünün diğer özellik çıkarımları yoğunluk değerinden bulunabilir. [18].

Gerçekleştirilen bu tez çalışmasında, ağlar boyunca özellik haritalarının boyutuna bağlı olarak farklı oranlarda alıcı alanın genişlemesini sağlayan genişletilmiş evrişim modülü kullanılmıştır. Bu da minimum çözünürlük kaybıyla çok ölçekli bağlamsal bilgilerin yoğun tahminlerini üretmeyi sağlar. Literatürde birçok çalışma olmasına rağmen bu yöntem NIFTI formatındaki kaliteli, yüksek çözünürlüklü veriler ve 18750 veri sayısı ile segmentasyon açısından yüksek oranda doğruluk sağlanmıştır. Bu tez çalışmasında önerilen modelin bir diğer amacı, literatürde yapılan çalışmalar ile kıyaslama yapmak ve daha etkili bir çözüm önerisi ile literatüre katkı sağlamaktadır.

2. LİTERATÜR TARAMASI

Bilgisayar Destekli Tanı sistemleri yaygın olarak çalışılan bir araştırma alanıdır. Beyin tümör tespiti üzerine de literatürde birçok çalışma mevcuttur. Bu çalışmalar farklı modeller ve veriler üzerinde çalışılmıştır. Bilgisayar destekli tanı sistemi ile sadece MRG üzerinde değil diğer radyoloji görüntüler üzerinde de birçok çalışma yapılmıştır.

Mohammed A. Al-masni ve arkadaşları [19], çalışmalarında meme kitlelerin otomatik tespiti ve sınıflandırılması yapılarak radyologlara karar destek sistemi geliştirmişlerdir. Bu çalışmada ilgi bölge tabanlı evrişimsel sinir ağı uygulanarak tümör tespiti ve sınıflandırılma yapılmıştır.

Zhao ve arkadaşları [20] yapmış oldukları çalışma ile literatürde yapılan diğer çalışmaları karşılaştırmışlar ve önerilen PSPNET ile doğruluk oranı %99,38 olan yüksek bir başarım elde etmişlerdir. Al-Masni ve Dong-Hyun Kim tarafından yapılan çalışmada [21], CMM-Ağ mimarisi ile dermoskopi görüntülerinden cilt lezyonları, retinal kan damarları segmentasyonu ve BraTS 2018 MRG taramalarından beyin glioma segmentasyonu gerçekleştirilmiş, yapılan deneysel çalışmalarda Unet, DeepLabv3+, Ce-Net, Unet++ algoritmaları ile karşılaştırma yapılmış ve birçok kriterde yüksek performans elde etmişlerdir.

Yıldız 2019 [22] yılında yapmış olduğu çalışmasında cilt kanseri türü olan melanom için otomatik tanı koyabilecek bir sistem önermiş, melanom tanısı için tasarlanan C4Net derin sinir ağ modeli ile beraber literatürde ön plana çıkmış AlexNet, GoogLeNet, ResNet, VGGNet derin öğrenme modelleri ve Yapay sinir ağları, En yakın komşu algoritması ve Destek vektör makinesi gibi geleneksel makine öğrenme yöntemlerini de kapsayan detaylı bir deneysel çalışma yapmıştır. Çalışmada önerilen C4Net derin sinir ağ modeli ile %96,94 doğrulukta melanom tanısı konulabilmiştir.

Harun Bingöl ve Bilal Alataş [23] çalışmalarında derin öğrenme tekniklerinde sık kullanılan Alexnet, GoogleNet ve Resnet50 mimarilerini kullanmışlar, Resnet50 mimarisi ile %85,71 başarı oranı elde etmişlerdir. Ali Arı ve Davut Albay [24] yaptıkları çalışmada, derin öğrenme algoritmalarından biri olan Bölgesel tabanlı evrişimsel sinir ağı (BESA) altyapısını kullanarak beyin MRG tümörün tanısını ve yerini analiz edip uzmanlara karar destek sistemi

sağlayan sistem geliştirilmiştir. Bölgesel tabanlı evrişimsel sinir ağı, evrişimsel sinir ağını esas alan bir yapıdır. Bu yapı, mimarinin giriş görüntüsüne ek olarak tümör çıkarımı yapılan bölgenin de giriş olarak kullanıldığı bir sistem olarak düşünülebilir. Önerilen bu algoritma ile Harvard, Benchmark, Rembredant veri setleri üzerinde test işlemleri yapılmıştır. Bu test işlemleri sonucunda Benchmark veri seti %99,10 en yüksek doğruluk değeri elde etmişlerdir.

M.Usman Saeed ve çalışma arkadaşları [25] tarafından yapılan çalışmada beyin tümörlerini doğru bir şekilde segmentlere ayırabilen otomatik ve güvenilir uçtan uca beyin tümörü segmentasyonu elde etmek için hibrit bir derin öğrenme modeli RMU-Net önermişlerdir. MobileNetV2'nin mimarisi, derinlemesine özellikleri öğrenmek için artık bloklar eklenerek değiştirilir. Bu değiştirilmiş Mobile Net V2, önerilen ağda bir kodlayıcı olarak kullanmışlardır. U-Net'in üst örnekleme katmanları, kod çözücü parçası olarak değerlendirmişlerdir.

L. Kong ve Y. Zhang [26] yaptıkları çalışmada, MRG her modunun farklılığına göre, yavaş yavaş beyin tümörü bölgelerinin kabadan inceye segmentasyonunu tamamlayan kademeli bir ağ mimarisi oluşturmuşlardır. Temel segmentasyon ağı, 3D U-Net'e dayanmaktadır ve ağ eğitimi sürecinde gradyan bozulma problemini çözmek için derin kalıntı modülü eklenilmiştir. Önerilen ağın tüm tümör, tümör çekirdeği ve güçlendirilmiş tümördeki zar benzerlik katsayılarının sırasıyla 0,883; 0,834; 0,746 sonuçlar elde etmişlerdir.

A. Arora ve çalışma arkadaşları [27] tarafından yapılan çalışmada, U-Net tabanlı bir derin öğrenme modeli kullanılarak ameliyat öncesi MRG taramalarında gliomaların segmentasyonu görevini yerine getirmek için tam otomatik bir metodoloji geliştirilmiştir. Çeşitli tekniklerle daha fazla işlenen girdi görüntü verilerini dönüştürmektir. Alt küme bölme, dar nesne bölgesi, kategori beyin dilimleme, havza algoritması ve özellik ölçekleme yapılmıştır. Tüm bu adımlar, U-Net Derin öğrenme modeline veri girmeden önce ima edilir. U-Net Derin öğrenme modeli, segment tümör bölgesinde piksel etiketi segmentasyonu gerçekleştirmek için kullanılır. Önerilen model, sırasıyla HGG-1, HGG-2, HGG-3 ve LGG-1 setleri için test veri setinde 0,98; 0,98; 0,98 ve 0,99'luk zar benzerlik katsayısı sonuçları elde etmişlerdir. Kong ve çalışma arkadaşları çalışmalarında [28], Unet mimarisini altyapısını kullanarak Hibrit Piramit Unet (HPU-Net) modelini önermişlerdir. Bu model, bölge bağlamı birleştiren küresel bağlam bilgisini araştıran bir mimariyi içermektedir.

Tümör segmentasyon işleminde kaliteli sonuçlar üretmek için HPU-Unet mimarisi piksel düzeyinde iyi bir çerçeve sağlayarak tahmin olasılık düzeyini yüksek değerde sağlar. Qamar ve çalışma arkadaşları çalışmalarında [29], hiper yoğun başlangıç 3 boyutlu U-net (HINet) mimarisini önermişlerdir. Bu mimari 3 boyutlu ağırlıklı evrişimli katmanların çarpanlara ayrılmasını koruyarak çok ölçekli bilgileri yakalayabilmektedir. Bu durum beyin tümör segmentasyon performansını arttırmaktadır. Aboelenein ve çalışma arkadaşları çalışmalarında [30], beyin tümörü segmentasyonu için bir Hibrit İki Kanallı U-net (HTTU-Net) mimarisi önermişlerdir. Bu mimari, Leaky Relu aktivasyonunu ve toplu normalizasyonu kullanmaktadır. Duyarlılık, özgüllük oranlarını sırasıyla %88,30 ve %99,90 olarak bulmuşlardır.

Chen ve çalışma arkadaşları [31] tarafından yapılan çalışmada nesne sınırları boyunca segmentasyon sonuçlarını iyileştirmek için etkili kod çözücü modülü eklemişlerdir. Doğruluk oranını %99,03 olarak bulmuşlardır.

Z.Gu ve çalışma arkadaşları [32] tarafından yapılan çalışmada, iki boyutlu tıbbi görüntü segmentasyonu için daha yüksek seviyeli bilgi yakalamak ve uzamsal bilgiyi korumak için kodlayıcı ağı olarak tanımlanan CE-Net modelini önermişlerdir. CE-Net temel olarak üç ana bileşen içerir; bir özellik kodlayıcı modülü, bir bağlam çıkarıcı ve bir özellik kod çözücü modülü. Çalışma sonucunda doğruluk oranını %99,11 olarak bulmuşlardır.

Yapılan literatür araştırmasında görülmüştür ki Bilgisayar Destekli Tanı sistemlerinde yaygın olarak Unet tabanlı model yöntemleri kullanılmıştır. Çalışmalarda veri sayısının büyüklüğü ve eğitimde kullanılan yöntemler başarıyı önemli ölçüde etkilemiştir.

3. GENEL KAVRAMLAR

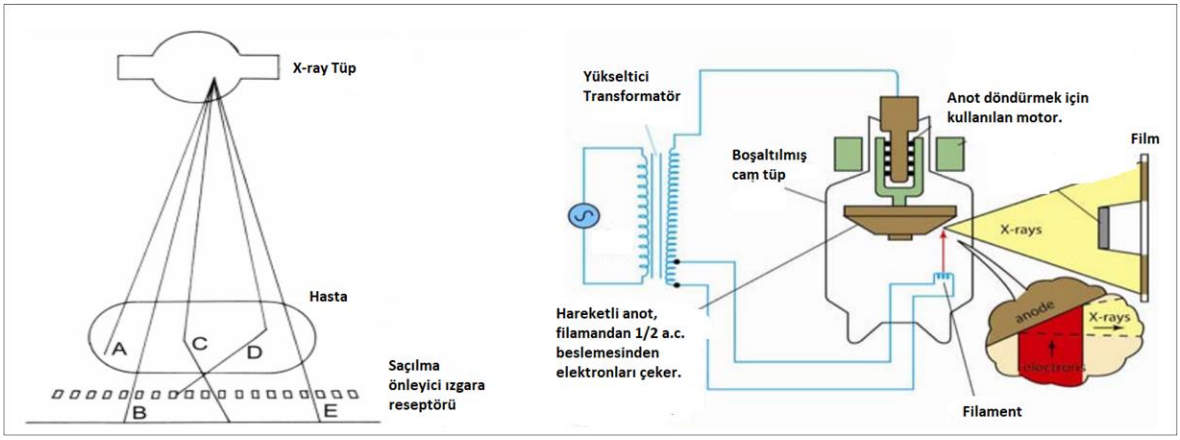
Bu bölümde, tıbbi görüntüleme teknikleri, makine ve derin öğrenme, evrişimsel sinir ağı, görüntü segmentasyonu, model değerlendirne, bilgisayar destekli tanı sistemi, derin öğrenmede sık kullanılan kütüphaneler ve optimizasyon algoritmaları ile ilgili bilgilere yer verilmiştir.

3.1. Tıbbi Görüntüleme Teknikleri

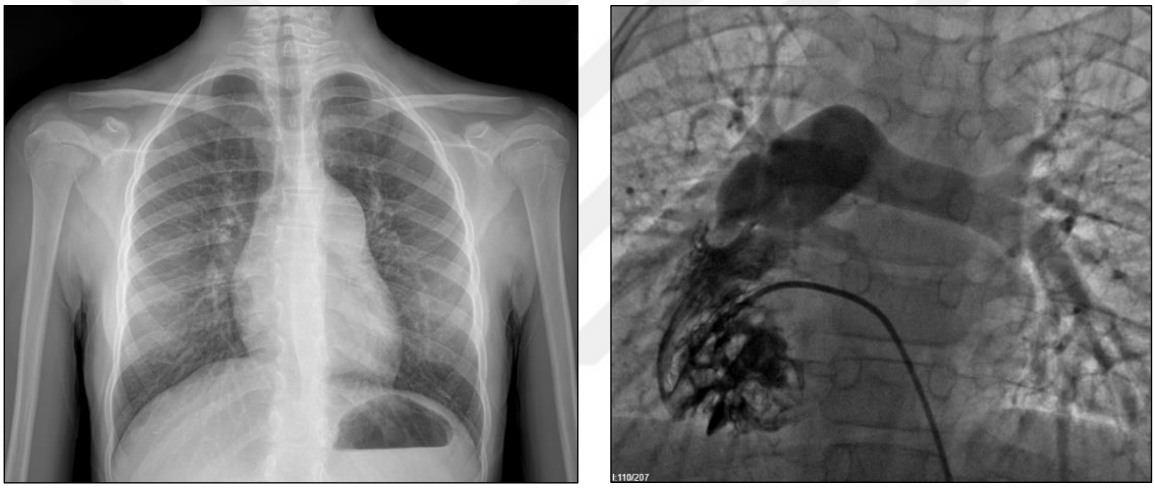
Tıbbi görüntüleme sistemi, hastalıkların tedavisinde ve tanısında kullanılan önemli bir teknolojidir. Bu teknoloji sayesinde biyomedikal görüntüleme teknolojisi, hastaların vücut dokularına ve hücrelerine zarar vermeyen yöntemlerle yüksek çözünürlüklü görüntülenmesini sağlar. Manyetik Rezonans Görüntüleme (MRG), Röntgen (X-ray), Bilgisayar Tomografi (BT) ve Ultrason cihazları tanı ve tedavi için kullanılan en yaygın teknolojilerdir.

3.1.1. Röntgen (X-ray) görüntüleme

Radyografi, nesneleri görüntülemek için x-ışını gibi iyonlaştırıcı elektromanyetik radyasyonunu kullanan bir görüntüleme yöntemidir. X-ışını, katılara nüfuz edebilen ve gazı iyonize edebilen yüksek enerjili bir elektromanyetik radyasyondur; 0.01 ile 10 manometre arasında dalga boyuna sahiptir. Tıbbi görüntüleme için, x-ışını vücuttan geçer, farklı dokuların yoğunluğuna ve atom numarasına göre farklı seviyelerde emilir veya zayıflatılır, bir profil oluşturur [33]. X-ışını profili, Şekil 3.1'de gösterildiği gibi bir görüntü oluşturan, bir dedektöre kaydedilir. Filament tel, bir elektrik akımıyla ısıtıldığında elektronlar yayılır. Dönen bir metal anot, filament telinde alternatif bir akım sağlayan elektronları çeker. X-ışınının çıktığı anodun alanı yayılan odak noktası olarak adlandırılır. Kullanılan foton enerjileri 17-150 KeV arasında değişmektedir. Belirli bir uygulama veya doku araştırması için seçim, kabul edilebilir radyasyon dozu ve ulaşılabilir görüntü kontrastı arasında bir dengedir [34] . Şekil 3.2'de çeşitli röntgen örnekleri verilmiştir.



Şekil 3.1. X-ray radyografik tıbbi görüntüleme [34]



Şekil 3.2 X-ray görüntü örnekleri

<u>Röntgen görüntüleme yönteminin avantajları şöyle sıralanabilir:</u>

- Cerrahi işlem gerektirmez
- Hızlı ve ağrısızdır
- Tıbbi ve cerrahi tedavi planlamasını desteklenir
- Tümör tedavisi veya kan pıhtılarını gidermek için tıbbi personel rehberliğinde vücuda kateter ve stent yerleştirilebilir [34]

<u>Röntgen görüntüleme riskleri şunlardır:</u>

- İyonlaştırıcı radyasyona maruz kalındığı için yaşamın ilerleyen dönemlerinde kanser riski olasılığı artar

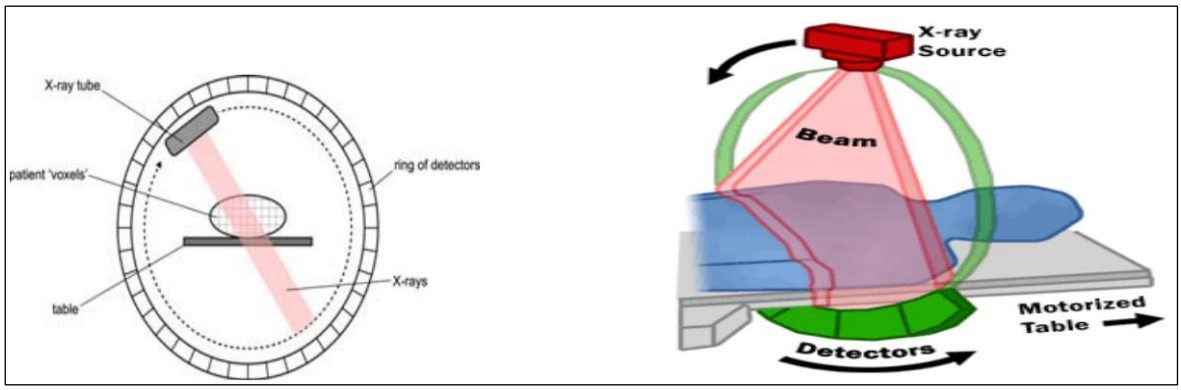
- Nispeten yüksek radyasyona maruz kalma seviyelerinde katarakt, cilt kızarması ve saç dökülmesi gibi doku etkileri görülebilir [34]

Röntgen görüntülemenin yaygın uygulama alanları şunlardır:

- Mide, bağırsak ve kolon gibi organların vücuttaki hareketlerini göstermek için kullanılan floroskopi radyografisi olarak kullanılır
- Kalbin ve beynin kan damarlarını incelemek için de kullanılır
- Bir kırığın tipini ve derecesini belirlemek için kullanılır
- Akciğerlerdeki patolojik değişiklikleri tespit etmek için ve mide ve bağırsakların yapısını görselleştirmek için kullanılır
- Kemik mineral içeriğini ve yoğunluğunu ölçmek için kemik dansitometrisi amacıyla kullanılır
- Eklem içini görmek için artrografi kullanılır [34]

3.1.2. Bilgisayar tomografi (BT)

Bilgisayarlı Tomografi (BT), insan vücudunun enine kesitlerinin görüntülerini üretmek için x-ışını ekipmanını bir bilgisayar ve bir katot ışın tüpü ekranıyla birleştiren bir tanı teknolojisidir [35]. Radyografik film, X-ışını profilini ölçen bir dedektör ile değiştirilir. Bilgisayar tomografi tarayıcının içinde, bir tarafında x-ışını tüpü, diğer tarafında dedektör monte edilmiş döner bir çerçeve vardır. Dönen bir çerçeve, x-ışını tüpünü ve dedektörü Şekil 3.3'te gösterildiği gibi hastanın etrafında döndürdüğünde bir x-ışını üretilir. X-ışını tüpü ve dedektör her tam bir dönüş yaptığında, bir görüntü veya kesit elde edilir. X-ışını tüpü ve dedektör bu dönüşü gerçekleştirirken, dedektör, zayıflatılmış x-ışını demetinin sayısız profilini alır. Her profil, bilgisayar tarafından taranan dilimin iki boyutlu görüntüsü yeniden oluşturulur. Üç boyutlu (3B) BT, spiral BT kullanılarak elde edilebilir. Spiral BT, hasta anatomisinin tümü tek bir konumdayken bir veri hacmi elde eder. Bu hacim veri seti daha sonra karmaşık yapıların 3B görüntülerini sağlamak için bilgisayarda yeniden yapılandırılabilir. Elde edilen 3B BT görüntüleri, tümör kitlelerinin 3B olarak görüntülenmesine yardımcı olur [35]. Son zamanlarda, solunum hareketlerinin neden olduğu sorunların üstesinden gelmek için dört boyutlu (4B) BT tanıtıldı.Dört boyutlu BT, organ hareketliliği hakkında hem mekansal hem de zamansal bilgi üretir. Bilgisayar tomografi taramalarının bazı örnekleri Şekil 3.4'te gösterilmiştir.



Şekil 3.3 BT görüntüleme [36]



Şekil 3.4 BT tarama örnekleri [36]

Bilgisayar tomografi görüntüleme yönteminin avantajları şöyle sıralanabilir:

- Cerrahi işlem gerektirmez
- Hızlı ve ağrısız
- Uzamsal yüksek çözünürlük
- Damarların küresel görünümü
- Fiziksel yoğunluktaki küçük farklılıklar kolaylıkla ayırt edilir [36]

Bilgisayar tomografi görüntüleme riskleri şunlardır:

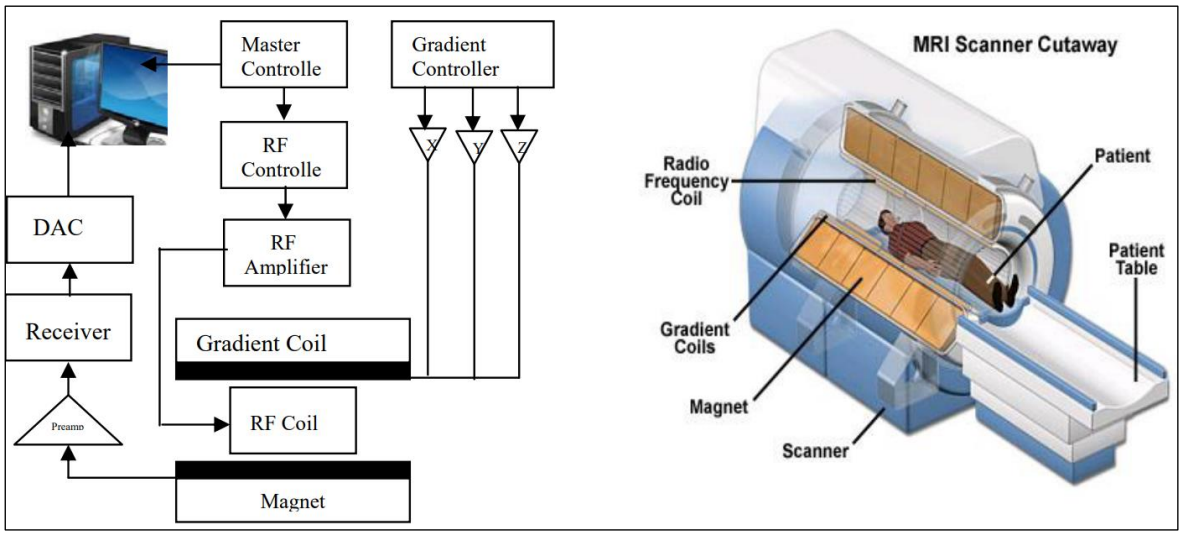
- İyonlaştırıcı radyasyona maruz kalındığı için yaşamın ilerleyen dönemlerinde kanser riski olasılığını artırır
- İntralüminal anormallikleri tespit edemez
- Kontrastsız yapılamaz (alerji, toksisite)
- Yumuşak doku kontrastının düşük olduğu durumlarda kontrast çözünürlüğü düşüktür [36]

Bilgisayar tomografi görüntülemenin yaygın uygulama alanları şunlardır:

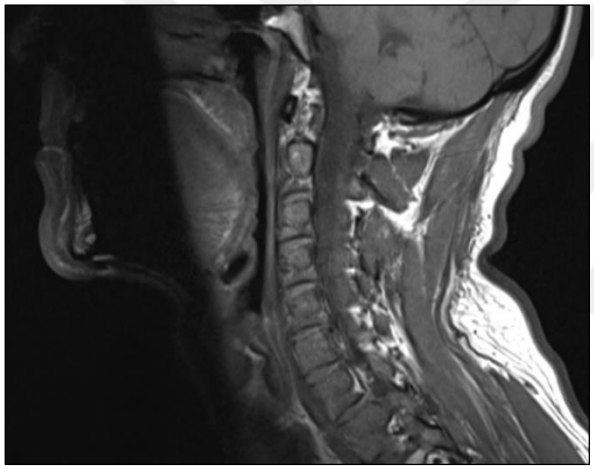
- İnsan vücudunun birçok bölümünün incelenmesi; beyin, sinüs, yüz kemikleri, diş, servikal, eller, bilek, dirsek, omuz, kalça, diz, ayak bileği, üriner sistem
- Hastalık, travma ve anormallik teşhisi
- Girişimsel veya terapötik prosedürleri planlamak ve yönlendirmek
- Tedavinin etkinliğinin izlenmesi (kanser tedavisi)

3.1.3. Manyetik rezonans görüntüleme (MRG)

MRG, vücut dokularını görüntülemek ve vücut kimyasını izlemek için manyetik ve radyo frekansı alanlarını kullanan bir tanı teknolojisidir. Morfolojik değişiklikleri görselleştirmek için kullanılan MRG, hastalıklı doku tarafından sunulan ortamın karakteristiği olan proton yoğunluğu ve manyetik dönüş gevşeme sürelerindeki değişiklikleri tespit etme yeteneğine dayanır [37]. Manyetik görüntüleme cihazı üç ana bileşenden oluşur; ana mıknatıs, manyetik alan gradyan sistemi ve radyo frekansı (RF) sistemi. Şekil 3.5'te manyetik görüntüleme sistemi bileşenleri verilmiştir. Ana mıknatıs, bir manyetik alan oluşturan kalıcı bir mıknatıstır. Manyetik alan gradyan sistemi normalde sinyal lokalizasyonu için gerekli olan üç ortogonal gradyan bobinden oluşur. Radyo frekansı, bir döndürme sistemini harekete geçirmek için dönen bir manyetik alan oluşturabilen bir verici bobinden ve Şekil 3.5'te gösterildiği gibi, devam eden bir manyetizasyonu elektrik sinyallerine dönüştüren bir alıcı bobinden oluşur. Sinyaller MRG cihazı tarafından ölçülür ve dijital bilgisayar bu sinyalleri görüntülere dönüştürür. MRG örnekleri Şekil 3.6'da gösterilmiştir. Son zamanlarda, fonksiyonel manyetik rezonans görüntüleme (fMRG) adı verilen beynin aktif bir bölümünde meydana gelen küçük metabolik değişiklikleri ölçmek için MRG kullanılmaktadır [38].



Şekil 3.5 Manyetik rezonans sistem [38]



Şekil 3.6 MRG tarama örneği

Manyetik rezonans görüntüleme yönteminin avantajları şöyle sıralanabilir:

- Cerrahi işlem gerektirmeyen ve ağrısız
- İyonlaştırıcı radyasyon olmadan çekim yapılmaktadır
- Yüksek çözünürlüklü çekimler yapılır
- Kontrastsız yapılabilir (hamilelik alerjisi)
- Yumuşak doku kontrastı yüksek seviyedir [38]

Manyetik rezonans görüntüleme riskleri şunlardır:

- Diğer cihazlar ile oranla düşük hassasiyet
- Tarama ve işlem süresi uzundur

- İntralüminal anormallikleri tespit edemez
- Bazı insanları uzun süre kapalı alanda kalındığı için klostrofobik hissettirebilir
- Yerinde duramayan küçük çocuklar için sedasyon gerekebilir
- Nispeten diğer cihazlar ile karşılaştırıldığında maliyeti yüksektir [38]

Manyetik rezonans görüntülemenin yaygın uygulama alanları şunlardır:

- Beyin ve omurilik anormalliklerinin incelenmesi
- Vücudun çeşitli bölgelerindeki tümör, kist ve diğer anormallikler incelenir
- Eklemlerin yaralanmalarını veya anormalliklerini incelenir
- Karaciğer ve diğer karın organlarının hastalıkları incelenir
- Kadınlarda meydana gelen pelvik ağrının nedenleri incelenir
- Yapılan çekime göre ameliyat planı oluşturulur [38]

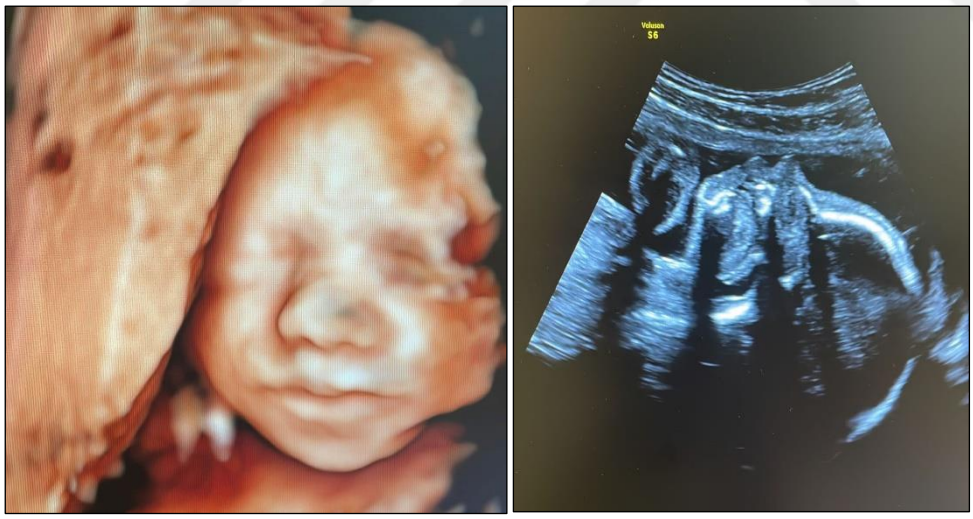
3.1.4. Ultrason görüntüleme

Ultrasonografi, tıbbi görüntüler üretmek için doku tarafından değişen derecelerde yansıtılan megahertz aralığında yüksek frekanslı geniş bant ses dalgalarını kullanan bir tanı teknolojisidir [39]. Tıbbi ultrason 30 kHz ile 500 MHz frekans aralığındadır.

Ultrason makinesiyle birlikte kullanılan dönüştürücülerin görevi, insan vücudunun iç görüntülerini üretmektedir. Dönüştürücü, vücuda nüfuz eden ve içindeki organlardan yansıyan yüksek frekanslı ses dalgaları akışı üretir. Dönüştürücü, ses dalgalarını organların içyapılarından yankılanırken algılar. Farklı dokular bu ses dalgalarını farklı şekilde yansıtarak ölçülebilen ve görüntüye dönüştürülebilen işaret oluşturur. Bu dalgalar ultrason makinesi tarafından alınır ve canlı resimlere dönüştürülür. Gerçek zamanlı bu hareketli görüntü, birçok ciddi hastalığı netleştiren biyopsi işlemine rehberlik etmek için kullanılır [40]. Şekil 3.7'de farklı tipte ultrason makinesi ve Şekil 3.8'de ultrason görüntülerine bazı örnekler görülmektedir.



Şekil 3.7 Ultrason makine



Şekil 3.8 Ultrason tarama örneği

Ultrason görüntüleme yönteminin avantajları şöyle sıralanabilir:

- Cerrahi işlem gerektirmez ve ağrısızdır.
- İyonlaştırıcı radyasyon kullanılmamaktadır
- Yüksek çözünürlük
- Gerçek zamanlı bilgi
- Akış değişiklikleri, intra ve ekstra luminal anormallikleri saptamak için hassastır

- Solunum aşamaları kontrol edilir [39]

Ultrason görüntüleme riskleri şunlardır:

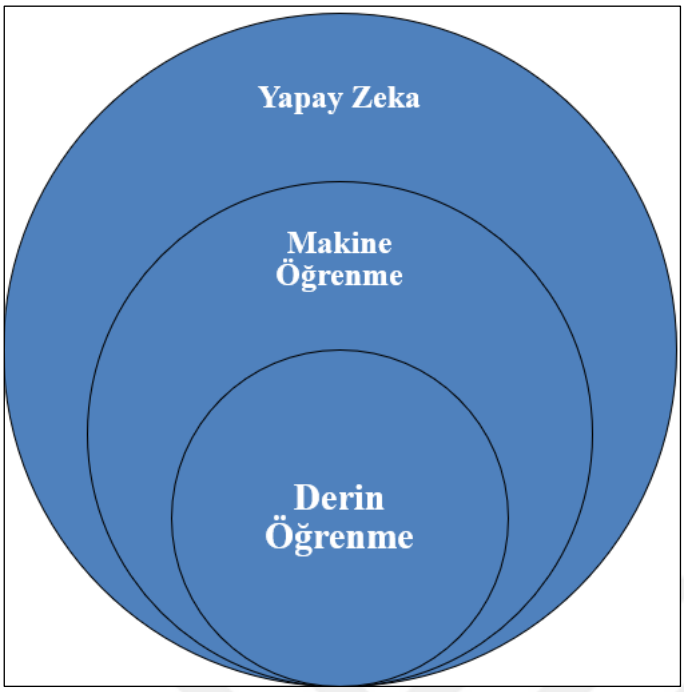
- Standartlaştırılmış yönergeler bulunmamaktadır.
- Operatöre bağlı bir şekilde çekim alınır.
- Damarların genel görünümü yapılamaz [39].

Ultrason görüntülemenin yaygın uygulama alanları şunlardır:

- Hamilelik sırasında fetüsün gelişiminin kontrol edilir
- Tiroid ve paratiroid bezleri, lenf düğümleri ve tükürük bezleri dahil olmak üzere baş ve boyundaki çoğu yapının görüntülenmesi yapılır
- Karın bölgesindeki katı organların görüntülenmesi; pankreas, aort, alt vena, karaciğer, safra kesesi, safra kanalları, böbrekler ve dalak yapılır
- Sinirlere yakın lokal anestezik solüsyonlar yerleştirirken iğnelerin enjekte edilmesine rehberlik eder [39]

3.2. Yapay Zeka ve Veriden Öğrenme

Yapay zeka, bilgisayarla görü uygulamasında araştırmacıların ilgi duyduğu günümüzün tercih edilen araştırmasıdır. Hem makine öğrenmesi hem de derin öğrenme, geniş kapsamlı yapay zeka sınıfına girer. Bu sınıfı tanımlayan ifade Şekil 3.9'da gösterilmiştir.



Şekil 3.9 Yapay zeka kapsamı

İlk yapay zeka araştırmaları, öncelikle, bir bilgisayarın mantıksal çıkarım kurallarına dayanarak otomatik olarak akıl yürütebileceği resmi dillerdeki sabit kodlanmış ifadelere odaklanmıştır. Bu aynı zamanda bilgi tabanı yaklaşımı olarak da bilinir [41]. Genellikle yapay zeka olarak adlandırılan bu tür sistemlerin gelişmiş problem çözme kapasitesi, tahminler, kurallar, cevaplar, öneriler veya benzer sonuçlar üreten analitik modellere dayanır.

3.2.1. Makine öğrenmesi

Makine öğrenmesi (MÖ), verilerin matematiksel ve istatiksel analizine odaklanıp aynı zamanda algoritmanın doğruluğunu kademeli olarak artırarak insan öğrenme şekillerini taklit etmek için kullanılan yapay zeka dalıdır. Makine öğrenmesi görüntüler, videolar, nesneler, sahneler vb. verileri sınıflandırmak ve tanımlamak için makinelerin otomatik öğrenmesidir. Makine öğrenmesi, ham verileri analiz etmek, öğrenmek ve karar vermek için algoritmalardan yararlanır [44]. Geleneksel makine öğrenmesi tekniklerinin, verileri orijinal formlarında işleme kapasitesi sınırlıdır. Bu yöntemler, temsil için önemli ölçüde anlayış ve uzmanlık yani özelliklerin seçimi dikkatli mühendislik gerektirir. Bir sisteme veri seti ile giriş yapılmasına izin veren bir dizi algoritmayı ifade eder. Karar verme, algılama veya sınıflandırma için gerekli temsilleri otomatik olarak gerçekleştirir [44]. Bilgiyi bilgisayarlara kodlamak yerine, Makine öğrenmesi, örneklerden ve gözlemlerden anlamlı ilişkileri ve

kalıpları otomatik olarak öğrenmeye çalışır [44]. Analitik modeller oluşturmaya yönelik ilk girişimler, bilinen ilişkileri, prosedürleri ve karar mantığını el yapımı kurallar (örneğin, tıbbi teşhisler için uzman sistemler) aracılığıyla akıllı sistemlere açıkça programlamaya dayanır [45]. Makine öğrenmesindeki ilerlemeler, iş ve kişisel yaşamımıza nüfuz eden ve elektronik pazarlardaki ağ bağlantılı etkileşimleri akla gelebilecek her şekilde şekillendiren, insan benzeri bilişsel kapasiteye sahip akıllı sistemlerin son zamanlarda yükselişini mümkün kılar. Şirketler, üretkenlik, katılım ve çalışan için karar vermeyi artırır. Bireysel kullanıcı tercihlerine uyum sağlayan eğitilebilir yardımcı sistemler ve geleneksel finans acenteleri bu yöntemleri sıklıkla kullanır [45].

Makine öğrenmesi, denetimli, denetimsiz ve pekiştirmeli öğrenme olmak üzere üç tür öğrenme metodolojisi kullanır. Denetimli öğrenme, sıklıkla verilerin regresyon ve sınıflandırma işlemi için kullanılan etiketleme işlemidir. İlk olarak sınıflandırma işlemi yapılırken tüm nesneler sisteme tanıtılmalıdır. Bu işlem sisteme kategorize şeklinde aktarılır. Kategorize şeklinde sisteme aktarılan nesneler bir sonraki süreçte algoritmanın öğrenilen işlevleri doğruluma kümesi oluşturularak kontrol edilir. Daha sonra istenilen doğruluk seviyesi noktasına ulaşıncaya kadar model çalıştırılır. Buradaki model eğitiminin amacı, nesneler tanıtılarak bilgisayara otomatik sınıflandırma yapmanın öğretilmesi daha sonra gösterilen örneklerin hangi sınıfa ait olduğunu tespit edilmesidir. Regresyon işlemi yapılırken, girdi olan verilerin sonuçlarına göre süreklilik gösteren lineer bir grafik oluşturulur. Bu grafiğe göre, eski verilerin sonuçları temel alınarak yeni verilerin sonuçları tahmin ettirilir. Denetimli öğrenme sürecinde, girdi etiketlerinin fazla olması model performansını üst seviyeye çıkartır [46]. Denetimsiz öğrenmede ise durum farklıdır ve verilerin etiketi olmamaktadır. Veriler benzerlik türüne göre gruplara ayrılır ve kümelenme oluştururlar. Denetimsiz öğrenmede kümelenme işlemi sayesinde verilerin analizi ve büyük sayısal verilen işlenmesi sağlanmaktadır. Bu yöntem günümüzde sıklıkla kullanılan Youtube, Spotify, Netflix platformlardaki öneri sistemlerinde kullanılır. Kullanıcıların yapmış olduğu tercihlere göre ilgili olduğu alanları analiz ederek ilgi alanına girebilecek yeni öneriler sunmaktadır. Günlük hayatta kullandığımız birçok uygulamalarda ve platformlarda MÖ sistemi kullanılmaktadır [46]. Pekiştirmeli öğrenme diğer öğrenme türlerine göre farklılık göstermektedir. Pekiştirmeli öğrenme türü amaç odaklı ve davranış psikolojinden esinlenerek oluşturulan bir öğrenme yaklaşımıdır. Bu yüzden diğer öğrenme türleri genelde daha çok tercih edilir [47].

Makine öğrenmesi, geçmişten gelen öğrenme yetenekleri ve akıllı kararlar vermesi nedeniyle çeşitli uygulama alanlarında popüler hale gelmektedir. Makine öğrenmesi, hastalık tahmini, tıbbi bilgi çıkarma, verilerdeki düzenlilikleri tespit etme, hasta yönetimi vb. gibi çeşitli tıbbi alanlardaki teşhis ve prognostik sorunları çözmeye yardımcı olmaktadır.

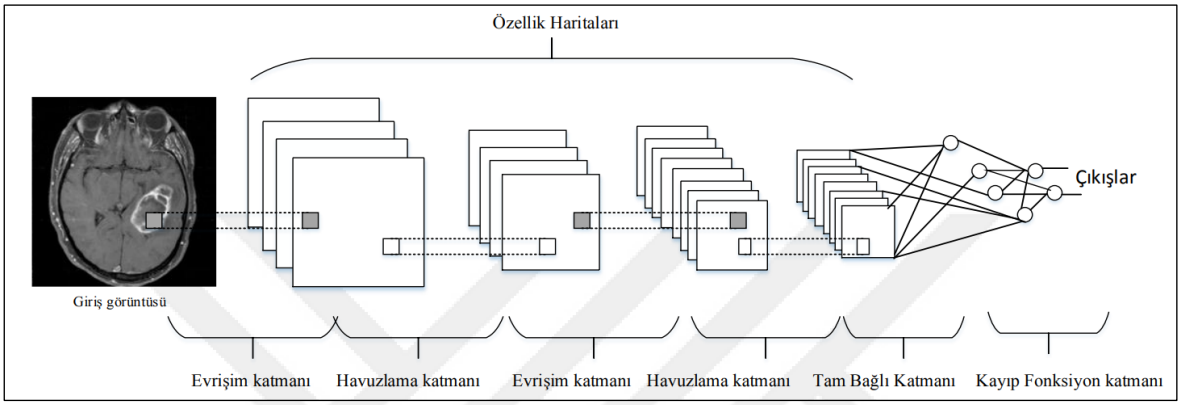
3.2.2. Derin öğrenme

Derin öğrenme, makine öğrenmesinin bir alt alanıdır. Derin öğrenme, bilgisayar verilerinden yararlı bilgileri otomatik olarak çıkarmasını, analiz etmesini ve anlamasını sağlamak için kullanılan gelişmiş bir makine öğrenmesi yaklaşımıdır. Derin öğrenmeden elde edilen sonuçlar, geleneksel makine öğrenmesi yaklaşımından çok daha başarılıdır [51].

Derin sinir ağı, sistemin girdi ve çıktı arasındaki karmaşık ilişkiyi öğrenmesini sağlayan doğrusal olmayan çoklu gizli katman mimarisi modelini kullanır. Derin öğrenmenin avantajı, makine öğrenmesinde olduğu gibi manuel olarak çıkarılmış özellikler gerektirmemesidir. Derin öğrenme, ham verilerden özellikleri otomatik olarak çıkarır, işler ve buna göre karar verir [52]. Derin öğrenme yaklaşımları, orijinal verileri karar verme için daha yüksek soyut seviyelere dönüştüren doğrusal olmayan modeli kullanarak çoklu soyutlama seviyelerine sahiptir. Bu, karmaşık ve doğrusal olmayan fonksiyonların çözümünü bulmayı kolaylaştırır [53]. Derin öğrenme, modülerlik ve transfer öğrenimi sağlayan özelliklerin otomatik olarak öğrenilmesine dayanır. Geleneksel makine öğrenmesinden farklı olarak, derin öğrenme, bir ağı eğitmek için büyük miktarda veri gerektirir [54].

Evrişimsel Sinir Ağı – ESA (Convolutional Neural Network), yapay sinir ağı tabanlı derin öğrenme modelidir. Evrişimsel Sinir Ağı şu anda nesne tanıma, nesne izleme, metin tanıma ve algılama, görsel algılama, poz tahmini, sahne etiketleme ve çeşitli diğer uygulamalarda yaygın olarak kullanılmaktadır. Evrişimsel Sinir Ağı, düşükten yüksek seviyeli modellere kadar özelliklerin uzamsal hiyerarşilerini otomatik ve uyarlanabilir bir şekilde öğrenmek için tasarlanmıştır. Evrişimsel Sinir Ağı, tipik olarak üç tür katmandan oluşan matematiksel bir yapıdır: Evrişim, Havuzlama ve Tam bağlantılı katmanlar. İlk ikisi, evrişim ve havuzlama katmanları, öznitelik çıkarma işlemini gerçekleştirirken, tamamen bağlantılı bir katman olan üçüncüsü, çıkarılan öznitelikleri sınıflandırma gibi nihai çıktıya eşler. Evrişimli Sinir Ağı, sinir ağından farklı olarak, nöronların gizli katmanları, yalnızca nöronların alt kümesini

içeren önceki katmanla bağlantılıdır. Bu tür seyrek bağlantı, sistemin örtük olarak özellikleri öğrenmesini sağlar. Evrişimli Sinir Ağı katmanının her bölümü, katmanın girişi ile birlikte kıvrılan iki veya daha fazla boyutlu filtre içerir. Derin evrişimli ağ, özelliğin hiyerarşik olarak çıkarılmasıyla sonuçlanır [56]. Evrişimli Sinir Ağı mimarisinin çalışma prensibi Şekil 3.10'da gösterilmiştir.

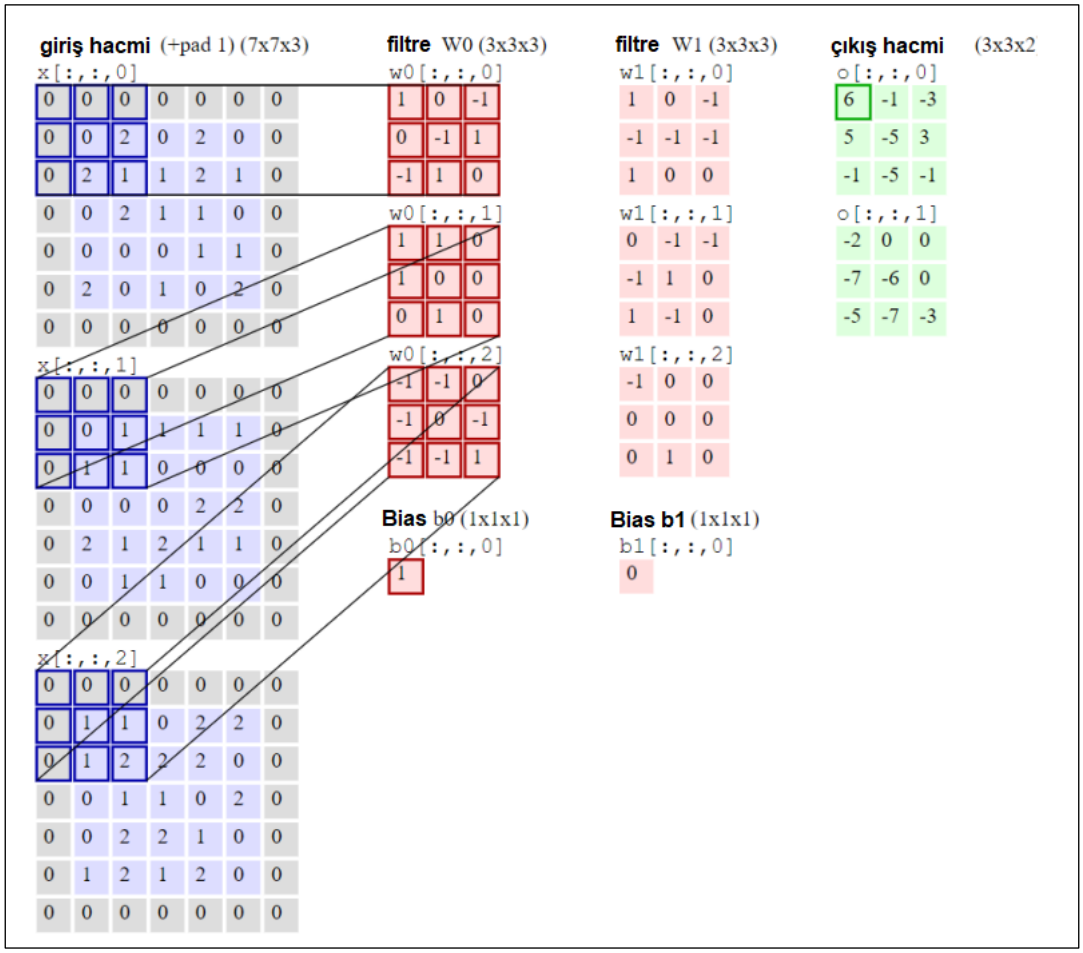


Şekil 3.10 Evrişimsel Sinir Ağı çalışma prensibi [56]

Görüntü değer taşıyan piksellerden oluşur. Belirli değerler taşıyan matris içermektedirler. Evrişimli katmanın görevi görüntülerin matris değerleri ile belirli özelliklerini elde etmeleridir. Evrişimsel Sinir Ağı mimarisi birbirini izleyen birçok katmandan oluşabilir ve bu katmanların arasında havuzlama katmanı yer almaktadır. Havuzlama katmanının görevi ise görüntü piksel değeri ve boyutları büyük olduğunda parametre sayısını azaltarak boyutu küçültmektir. Bu işlemi gerçekleştirirken görüntü bilgilerini koruyarak görüntü bilgileri kaybolmaz. İki çeşit havuzlama yöntemi vardır. Ortalama ve maksimum havuzlama yöntemidir. Genel olarak tercih edilen maksimum havuzlama yöntemidir. Maksimum havuzlama yöntemi, evrişimsel katmandan sonra kullanılır. Giriş verisinin uzamsal boyutunu azaltır. Tek katman olarak kullanılmaz iki evrişimsel katman arasında kullanılır. Aynı zamanda bu yöntem konumsal ve rotasyonel olarak değişmeden genişlik ve yükseklik azaltır. Modelin etkili şekilde eğitilmesi için baskın özellikler çıkarılır. Mimarinin bir katmandaki bütün düğüm ve nöronların bir sonraki katmana bağlandığı yapay sinir ağ türü tam bağlantı katmanıdır. Bu ağ türü hesaplama açısından karmaşık olmasının yanı sıra aşırı yüklenmeye meyillidir. Elde edilen verilere uygulanan Düzleştirme (Flattening) işleminden sonra sinir ağları ile öğrenme işlemi uygulanır. Bu katmanda evrişimli ve havuzlama katmanlarından geçen matris halindeki veriler düz bir vektör haline getirilir.

Evrişim katmanı

Evrişim katmanı, çoğu hesaplamanın gerçekleştirildiği ESA'nın birincil birimidir. Bu katmanın temel amacı girdi görüntüsünde özellik haritasını oluşturmaktır. Her bir harita girdi görüntüsünde belirli bir özelliği tanır. Evrişim katmanın birinci ESA katmanı olmasının nedeni paylaşılan ağırlıkları (çekirdek veya filtre) ve yanlılığını kullanarak evriştirir. Filtreleme matrisi Şekil 3.11'de gösterilmiştir [57].

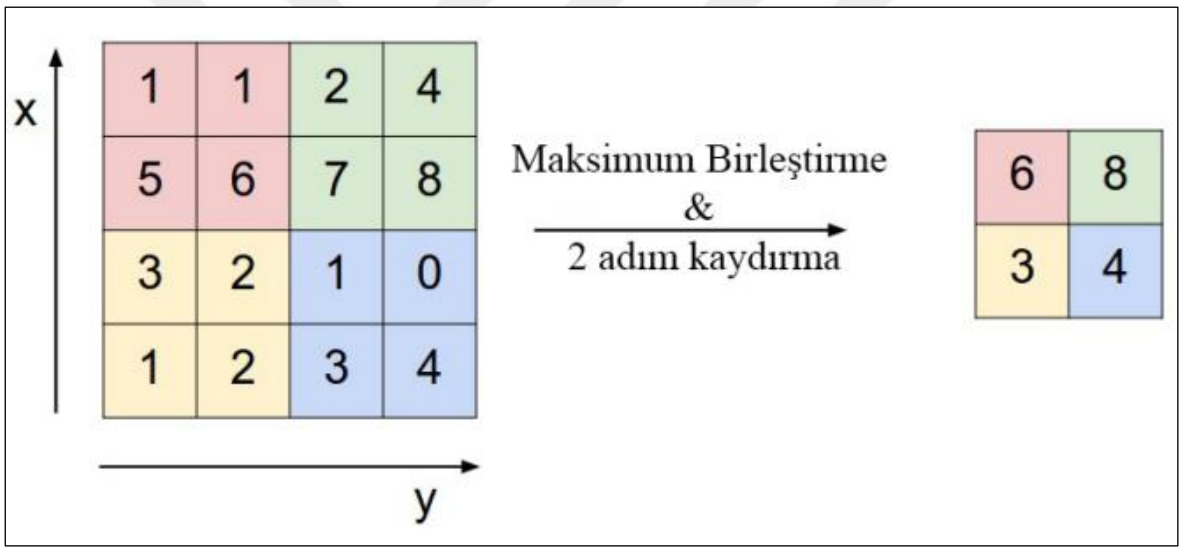


Şekil 3.11 3D görüntü girdisi (7,7,3) (3,3,2) matris elde ederek evrişen 3D filtre [58]

Filtre, kayan pencere yoluyla görüntü verisi boyunca uygulanan küçük bir birimdir. Girdi kanalları ile filtrenin derinliği aynıdır. Evrişim işlemi, görüntüdeki filtre elemanına göre filtre ürününü aldıktan sonra bu değerleri her bir kayma işlemi için toplar.İki boyutlu matris, renkli görüntülü 3B filtreli evrişim çıktısıdır. Evrişimli Sinir Ağı, uzaysal olarak ters çevrilmiş filtrelerle evrişim işlemini içeren geri yayılım tarafından eğitilir. Bu katmanlar, filtreleme ile birlikte evrişimli işlem uygular ve sonucu sonraki katmanlara iletir [58].

Alt örnekleme katmanı

Evrişimsel katmanı her zaman alt örnekleme katmanı takip eder. Alt örnekleme katmanının özellik haritalarının sayısı, evrişim katmanın her haritasının bir sonraki alt örnekleme katmanındaki eşleşen özellik haritasına bir girdi olarak kullanıldığı evrişimsel katman haritaları ile eşdeğerdir.Alt örnekleme katmanında üretilen görüntü boyutu tanımlaması "Eş. 3.1","Eş. 3.2","Eş. 3.3","Eş. 3.4" verilmiştir. Alt örnekleme katmanları, görüntü aktivasyon haritalarının uzamsal boyutunu azaltmak için kullanılır ve herhangi bir bilgi kaybı olmaksızın özelliklerin sayısı genel hesaplama karmaşıklığında azalma ile sonuçlanır. Alt örnekleme işlemi Şekil 3.12'de gösterilmektedir [57].



Şekil 3.12 Maksimum örnekleme işlemi [58]

$$\text{Üretilen Görüntünün Boyutu} = G_2 \times Y_2 \times D_2 \quad (3.1)$$

$$G_2 = (G_1 - F)/A + 1 \quad (3.2)$$

$$Y_2 = (H_1 - F)/A + 1 \quad (3.3)$$

$$D_2 = D_1 \quad (3.4)$$

G1= Giriş görüntü boyutunun genişlik değeri

Y1= Giriş görüntü boyutunun yükseklik değeri

D1= Giriş görüntü boyutunun derinlik değeri

F=Filtre boyutu

A=Adım sayısı
Havuzlama işleminde çoğunlukla F=2 ve A=2 olarak seçilir.

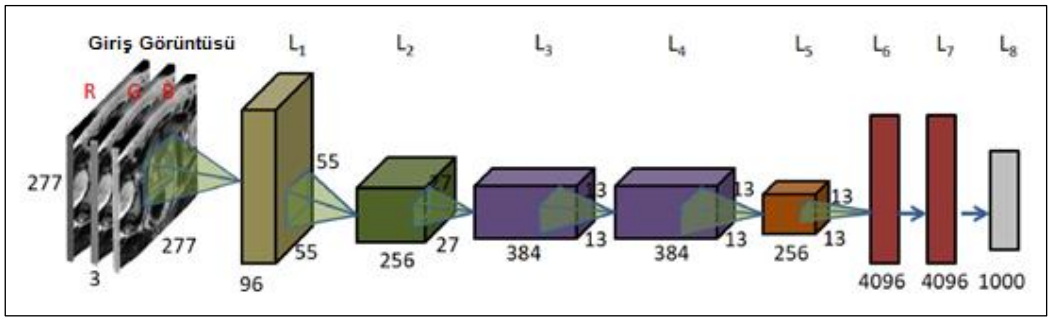
Ağdaki son katmana kadar alt örnekleme ve evrişimli katman ağın derinliğine kadar birbirini takip eder. Havuzlama katmanında bulunan veriler filtrelenir. “Max pooling” havuzlama yöntemi kullanılarak matris içindekilerden en büyüğü alınır [57].

Tam bağlantılı katman

Tam bağlantılı katmandaki nöronlar, önceki katmandaki tüm nöronlara normal yapay sinir ağlarında olduğu gibi bağlamaktadır. Tam bağlantılı katman ile evrişimsel katmanlar arasında temel fark, evrişimsel katmanlar girdinin lokal alanına katılır tam bağlantılı katman ise özellik haritalarını alır ve bir boyutlu vektör olarak çıktısını alır [59].

3.2.2.1. AlexNet

AlexNet ağ yapısı, Krizhevsky tarafından önerilmiştir. Temelinde LeNet modeline benzemektedir. Bu benzerliğin temel nedeni, birbirini takip eden evrişim ve alt örneklem katmanlarının olmasıdır. Bu mimaride yaklaşık 60 milyon parametre hesaplanır. AlexNet'in özel yapısı Şekil 3.13'de gösterilmektedir [60].

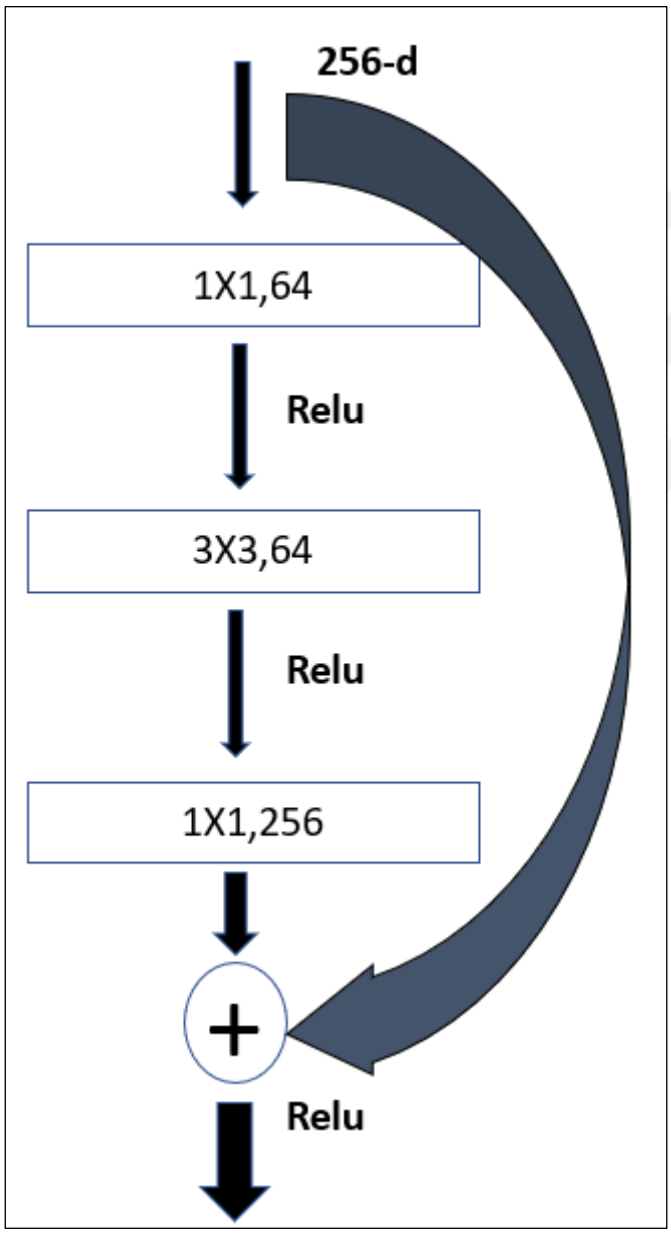


Şekil 3.13 AlexNet model [60]

Veri kaynağının giriş formatı 227 × 227 × 3 pikseldir, burada 227 piksel giriş görüntüsünün genişliğini ve yüksekliğini, 3 veri kaynağının üç kanallı bir RGB modunu temsil eder. Bu nedenle yaygın olarak kullanılan formatlardaki renkli resimleri desteklemektedir [60].

3.2.2.2. ResNet50

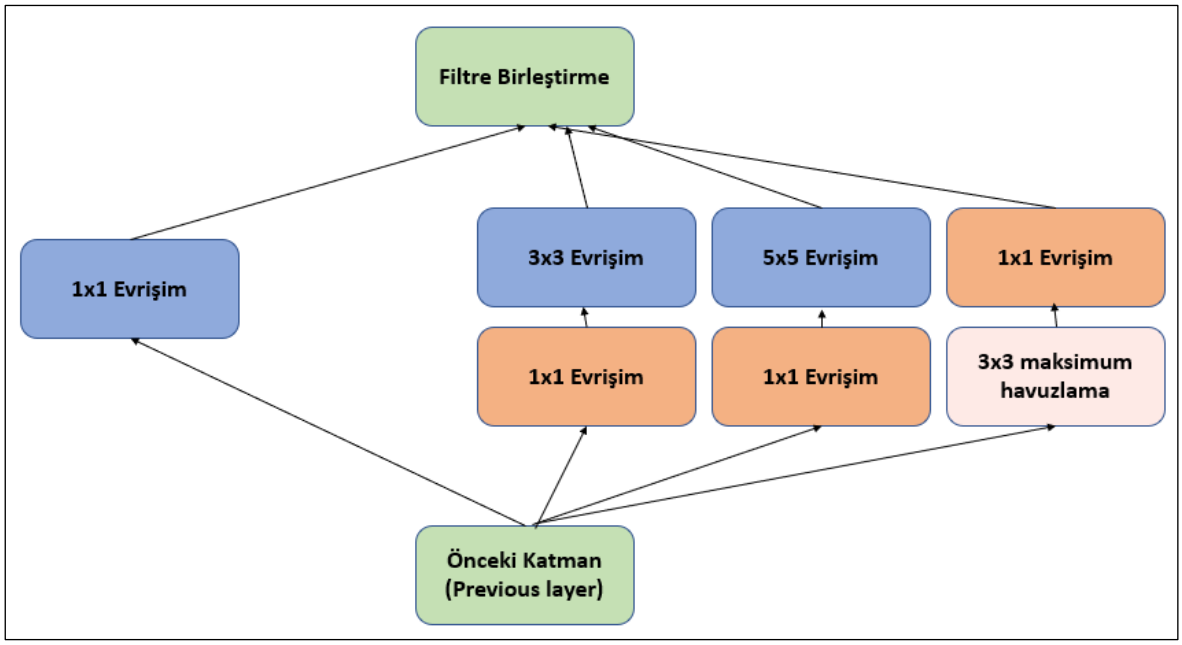
ResNet50 ağ mimarisi, 2015 yılında He Kaiming tarafından önerilmiştir. ResNet, mimari modele değerlerin ve blokların eklenmesi ile oluşmaktadır. ResNet mimarisi, derinliğini artırırken modelin performansını korumuştur. Hesaplama karmaşıklığında bir faktör olan parametre sayısı, bu modelde azaltılmıştır [61]. ResNet50 modeli Şekil 3.14'de verilmiştir.



Şekil 3.14 ResNet50 model

3.2.2.3. GoogleNet

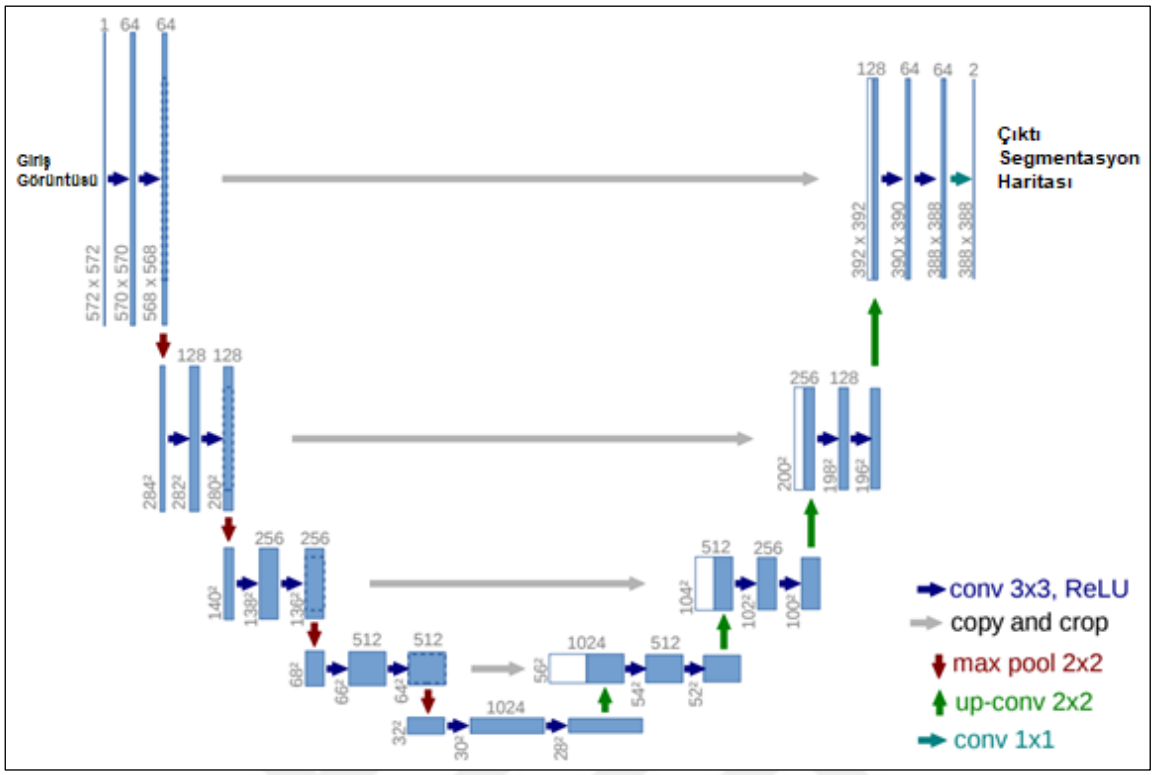
GoogleNet ağ yapısı, 2015 yılında Christian Szegedy tarafından önerilmiştir. GoogleNet, optimize edilmiş hiperparametrelere sahip derin öğrenme mimarisidir. Bu model 22 katmandan oluşmaktadır. Ayrıca yaklaşık 5 milyon parametre hesaplanmaktadır [62]. GoogleNet mimarisi Şekil 3.15'de verilmiştir.



Şekil 3.15 GoogleNet model [62]

3.2.2.4. Unet

Unet, geliştirilmiş tam evrişimli bir ağ modeli ve yapısı U şekline benzer. Şekil 3.16'da Unet mimari şekli verilmiştir. Diğer evrişimli sinir ağları ile karşılaştırıldığında, Unet daha az eğitim seti gerektirir ve daha yüksek segmentasyon doğruluğuna sahiptir. Ara katmanın simetri ekseni ile simetrik olan kodlayıcı ve kod çözücüden oluşur [64]. Kodlayıcı, görüntü özelliklerini evrişimli alt örnekleme havuzlama (down-sampling pooling) katmanları aracılığıyla çıkarır. Karşılaştırıldığında, kod çözücü özellik görüntülerinin yukarı örnekleme (up-sampling) katmanı ile gerçekleştirir ve karşılık gelen kodlayıcı ve kod çözücü katmanları arasında üst örnekleme katmanı, görüntünün ayrıntılarını kurtarmasına yardımcı olabilecek çapraz katman (cross- layer) bağlantıları vardır.



Şekil 3.16 Unet mimarisi [17]

Genişletilmiş evrim modülü, ardışık havuzlama katmanları kullanmak yerine çok ölçekli bağlamsal özellikleri bir araya getirebilen dalgacık ayrıştırmasından esinlenmiştir. Filtrelerin alıcı alanını genişleterek bilgilerin çözümlenmesini kontrol eder. F[x]'in ayrık bir girdi ve w [x]'in ayrık bir filtre olduğu düşünülürse [21]; Standart uzaysal evrişim "Eş. 3.5" gibi tanımlanır:

$$f[x] * w[x] = \sum_{k=-\infty}^{+\infty} f[k].w[-k]. \tag{3.5}$$

Burada '$*$' ve '$\cdot$' sırasıyla evrişim ve çarpma işlemlerini gösterir. Daha sonra, genişleme oranı r olan genişlemiş evrişim "Eş. 3.6" gibi tanımlanır:

$$f[x] *_r w[x] = \sum_{k=-\infty}^{+\infty} f[k].w[r(x-k)]. \tag{3.6}$$

Genişleme hızı arttığında, sonuçtaki alıcı alanın katlanarak genişlediğine dikkat edilmelidir. Bu ilişki şu şekilde formüle edilebilir: $(2^{r+1}-1) \times (2^{r+1}-1)$, r=1 olduğunda standart

evrişim ile aynı hale gelir. Böylece, genişletilmiş evrişim, öğrenme parametrelerinin sayısının doğrusal olarak arttığı bağlamsal bilginin çözünürlüğünü kontrol edilir [21].

3.3. Python İle Derin Öğrenme

Son yıllarda derin öğrenme çalışmaları önemli ölçüde gelişme göstermektedir. Literatür çalışmalarına bakıldığında her sektörde derin öğrenme algoritmaları kullanılmaya başlanmıştır. Özellikle görüntü sınıflandırma alanında birçok geliştirme ve çalışma yapılmaktadır. Derin öğrenme çalışmalarında sıklıkla kullanılan python yazılımsal dilidir. Bu tez çalışmasında da python yazılım dili kullanılmıştır.

3.3.1. Keras ve tensorflow kütüphanesi

Makine ve derin öğrenme algoritmalarına uyumlu birçok kütüphane vardır. Bu kütüphaneler çalışılacak konuya göre tercih edilir ve kolaylık sağlar. Her kütüphanenin farklı işlevi vardır. Bu işlevler yapılacak uygulamayı basitleştirir ve zaman kazandırır. Bu kütüphaneler genel olarak Python programlama dilinde yer alır ve kullanılır [64]. Bu çalışmada ise derin öğrenme yöntemlerinde sık ve sorunsuz şekilde kullanılan TensorFlow ve Keras kütüphanelerine yer verilmiştir.

Keras kütüphanesi ilk olarak 2015 yılında yazılmış olup 2018 yılında farklı versiyonlar çıkartarak güncellenmiştir. Python dilinde yazılan açık kaynaklı sinir ağ kütüphanesidir. Aynı zamanda üst düzey bir Uygulama Programlama Arabirimidir. Bilgisayar donanımları üzerinde GPU'ları ve CPU'ları problemsiz şekilde uygulayabilmektedir [65].

Keras'ın temel üstünlükleri aşağıda belirtilmiştir:

- Kolay ve hızlı prototipleme sağlar
- Hem konvolüsyonel ağları hem de tekrar eden ağları ve ikisinin kombinasyonlarını destekler
- Raslantısal bağlantı planlarını destekler
- CPU ve GPU üzerinde sorunsuz çalışır

Tensorflow ve Theano kütüphanelerin alt yapısında Keras kütüphanesi kullanılmıştır. Genel olarak tüm işletim sistemlerine uyumlu versiyonları bulunmaktadır. Makine ve derin

öğrenme algoritmalarını araştırmak ve kullanılmak istenen alanlarda geliştirme yapılması için tensorflow kütüphanesi kullanılmıştır. Daha sonra geliştirme yapılarak birçok alan ve sektörde kullanılmaya başlanmıştır [66].

3.3.2. Optimizasyon algoritmaları

Bir problem karşısında, belirli koşullar ve etkiler çerçevesinde mümkün olan birçok alternatif içerisinden en iyisini seçme durumu optimizasyon olarak tanımlanır. Makine ve derin öğrenme algoritmalarında hata payını en aza indirmek için sıklıkla uygun olan optimizasyon algoritmaları kullanılır. Genellikle kullanılan altı tane optimizasyon yöntemi vardır. Bunlar; Adam, Adadelta, Adagrad, RMSProp ve Stochastic Gradient Descent (SGD) optimizasyon yöntemleridir [67].

Adam optimizasyon

Yapay sinir ağlarında sıklıkla kullanılan optimizasyon yöntemidir. Adam optimizasyonu RMSprop ve ivme optimizasyonlarının birleşimidir. Gradyan tabanlı bir algoritmadır. Uyarlanabilir ve düşük dereceli tahminlere dayalıdır. Adam algoritmasının kullanımı hesaplama açısında etkili ve basittir. Aynı zamanda çok az bellek gereksinimi ihtiyaç duyar. Bu nedenden dolayı büyük veri, parametrelerin ve çok gürültülü veya seyrek gradyanlı problemler için kullanışlıdır. Hiper parametrelerin sezgisel yorumları olduğu için çok az ayarlamaya ihtiyaç duyar. Deneysel sonuçlar, Adam optimizasyonun pratikte etkili çalıştığını ve diğer stokastik optimizasyon yöntemleriyle olumlu bir şekilde karşılaştırıldığını göstermektedir [68]. "Eş. 3.7", "Eş. 3.8", "Eş. 3.9" adam optimizasyonun tanımlamaları verilmiştir.

$$w_{t+1} = w_t - \frac{a}{\sqrt{\frac{S_t}{1-\beta_2^t}+\in}} * \frac{V_t}{1-\beta_1^t} \tag{3.7}$$

$$V_t = \beta_1 V_{t-1} + (1-\beta_1) * \frac{\partial L}{\partial w_t} \tag{3.8}$$

$$S_t = \beta_2 S_{t-2} + (1-\beta_2) * \left[\frac{\partial L}{\partial w_t}\right]^2 \quad (3.9)$$

Burada S ve V başlangıç olarak 0, $\alpha = 0{,}001$, $\beta_1 = 0{,}9$, $\beta_2 = 0{,}999$ ve $\in$ ise $10-8$ olarak tercih edilmektedir [68].

Stochastic Gradient Descent optimizasyon

Literatürdeki birçok çalışmada gradient descent ismi ile kullanılmaktadır. Stochastic Gradient Descent, tüm gradient'ler yerine rastgele olmak üzere bir kısım gradient'le ağırlıkları güncellemektedir. Mevcut gradient'i $\partial L/\partial w_t$, öğrenme katsayısı (a) ile çarparak mevcut ağırlığı (w_t) güncellenmektedir [69]. "Eş. 3.10" SGD modelinin tanımlamaları verilmiştir.

$$w_{t+1} = w_t - a\frac{\partial L}{\partial w_t} \quad (3.10)$$

Adagrad optimizasyon

Stochastic Gradient Descent yöntemindeki sabit öğrenme katsayısı problemini ortadan kaldırmak için önerilmiştir. Her adımda farklı bir öğrenme katsayısı ile işlem yapmak için öğrenme katsayısını geçmiş gradientlerin karelerinin kümülatif toplamlarının karekökü ne bölmektedir [70]. "Eş. 3.11", "Eş. 3.12" adagrad modelinin tanımlamaları verilmiştir.

$$w_{t+1} = w_t - \frac{a}{\sqrt{S_t + \in}} * \frac{\partial L}{\partial w_t} \quad (3.11)$$

$$S_t = S_{t-1} + \left[\frac{\partial L}{\partial w_t}\right]^2 \quad (3.12)$$

Burada S başlangıçta 0, $\in$ ise işlemi sıfıra bölme hatasından kurtarmak için genelde çok küçük bir sayı olarak alınmaktadır [70].

RMSprop optimizasyon

RMSprop, Geoff Hinton tarafından yayınlanan uyarlanabilir bir öğrenme oranı yöntemidir. Adagrad'da olduğu gibi sabit öğrenme katsayısı problemini çözmek için önerilmiştir. Aralarındaki fark ise, Adagrad yöntemindeki gradientlerin karelerini almak yerine momentumlu gradientlerin karelerini almaktadır [71]. "Eş. 3.13","Eş. 3.14" RMSprop modelinin tanımlamaları verilmiştir.

$$w_{t+1} = w_t - \frac{a}{\sqrt{S_t + \epsilon}} * \frac{\partial L}{\partial w_t} \tag{3.13}$$

$$S_t = \beta S_{t-1} + (1-\beta) * \left[\frac{\partial L}{\partial w_t}\right]^2 \tag{3.14}$$

Burada S başlangıçta 0, $\alpha = 0{,}001$, $\beta = 0{,}9$ ve ϵ ise $10-6$ olarak tercih edilmektedir [71].

AdaDelta optimizasyon

Adadelta optimizasyonu farklı kişiler tarafından önerilmiştir. Bu optimizasyonun amacı sabit öğrenme problemlerini çözmeye yöneliktir. Adagrad ve RMSProp optimizasyonlarından farkı öğrenme katsayısı seçme zorunluluğu yoktur. Bunun yerine geçerli ve güncellenen ağırlıklar arasındaki farkı ifade eden delta değerlerinin karelerinin momentumlu toplamları kullanılmaktadır [72]. "Eş. 3.15","Eş. 3.16","Eş. 3.17","Eş. 3.18" AdaDelta modelinin tanımlamaları verilmiştir.

$$w_{t+1} = w_t - \frac{\sqrt{D_{t-1} - 1}}{\sqrt{S_t + \epsilon}} * \frac{\partial L}{\partial w_t} \tag{3.15}$$

$$D_t = \beta D_{t-1} + (1-\beta) * [\Delta w_t]^2 \tag{3.16}$$

$$S_t = \beta S_{t-1} + (1-\beta) * \left[\frac{\partial L}{\partial w_t}\right]^2 \tag{3.17}$$

$$\Delta w_t = w_t - w_{t-1} \tag{3.18}$$

Burada S ve D başlangıçta 0, $\beta = 0{,}95$ ve $\in$ ise $10-6$ olarak tercih edilmektedir [72].

3.4. Model Performansının Değerlendirilmesi

Farklı modellerin sonuçlarının değerlendirilmesi ve kıyaslanması son derece önemlidir. Aynı zamanda farklı modellerin gerçek ve tahmin edilen değerlerin veya modellerin hata değerlerin yorumlanması yapılır. İstatistiksel sınıflandırmada, verileri sonlu bir sınıflar kümesinde tahmin etmek veya sınıflandırmak için algoritmalar veya modeller oluşturulur. Modellerin hata pay oranları olduğu için bazı veri noktaları yanlış sınıflandırılacaktır. Karışıklık matrisi (Confusion Matrix) temel olarak modelin ne kadar iyi performans gösterdiğini gösteren tablo şeklinde bir özettir. Karışıklık matrisinin genel tablo görüntüsü Şekil 3.17'de verilmiştir. Bir boyutta, matris gerçek değerleri alır. Matris daha sonra bunları diğer boyuttaki tahmin edilen değerlere eşler. Gerçekte, matris bir histogram gibidir. Matristeki girişler sayıdır. Örneğin, gerçekte "yanlış" olduklarında kaç tane veri noktasının "doğru" olarak tahmin edildiğini kaydeder. Karışıklık matrisi hem ikili sınıflandırmada hem de çok sınıflı sınıflandırma problemlerinde kullanışlıdır. Matristen hesaplanabilecek birçok performans ölçütü vardır [73].

Karışıklık Matrisi (Confussion Matrix)		Gerçek(Actual) Sonuçlar	
		Pozitif (1)	Negatif (0)
Tahminlenen (Predicted) Sonuçlar	Pozitif (1)	TP [1,1] Doğru Pozitif (True Positive)	FP [1,0] Yanlış Pozitif (False Positive)
	Negatif (0)	FN [0,1] Yanlış Negatif (False Negative)	TN [0,0] Doğru Negatif (False Negative)

Şekil 3.17 Karışıklık matrisi [73]

Yukarıdaki tablo, ikili (binary) sınıflandırma için kurulmuş olan bir modelin çıktısının Karışıklık matrisidir. Bu matriste yer alan pozitif ve negatif terimleri doğruluk veya yanlışlığı değil ayrıştırılmak istenen sınıfları temsil etmektedir. Doğru Pozitif (True Positive), Yanlış Pozitif (False Positive), Doğru Negatif (False Negative) ve Yanlış Negatif (False Negative) aralarındaki oranlar ile ölçümler yapılır [81].

Doğru Pozitif (True Positive) = Gerçek ve tahmin pozitif bir değer.
Yanlış Pozitif (False Positive) = Tahmin pozitif ve sonuç yanlış. Tip 1 hatası olarak bilinir.
Yanlış Negatif (False Negative) = Tahmin negatif ve sonuç yanlış. Tip 2 hatası olarak bilinir.
Doğru Negatif (True Negative) = Gerçek ve tahmin negatif bir değer.

TP ve TN: Modelin doğru tahmin ettiği örnek sayısını verir.
FN ve FP: Modelin yanlış tahmin ettiği örnek sayısını verir.

Doğruluk (Accuracy)

Makine öğrenmesi sınıflandırma algoritmalarının testlerinde sıklıkla kullanılır. Modelin eksiksiz test veri kümesi için kaç doğru tahminde bulunduğunun bir ölçüsüdür. Doğruluk, modelin performansını ölçmek için temel bir ölçüdür. Doğruluk skoru aşağıdaki gibi hesaplanır. Doğruluk skoru 0 ve 1 arasında olup 1'e yaklaşan skorlarda model başarılı kabul edilir. Yüksek doğruluğa sahip bir test pozitif sonuç verir [74]. "Eş. 3.19" doğruluk ölçüsünün tanımlamaları verilmiştir.

$$Doğruluk(ACC) = \frac{TP + TN}{TP + FN + TN + FP} \tag{3.19}$$

Duyarlılık (Sensivity)

Model ile gerçek pozitif vakaların kaç tanesini doğru tahmin edebildiğimiz sonucuna ulaştırır. "Eş. 3.20" duyarlılık ölçüsünün tanımlamaları verilmiştir.

$$Duyarlılık(SEN) = \frac{TP}{TP + FN} \tag{3.20}$$

Bir testin duyarlılık oranının yüksek olması, o testin hastaları doğru olarak tanımlayabildiğini gösterir. Duyarlılığın yüksek olması yanlış negatif oranının düşük olmasıdır [74].

Kesinlik (Precision)

Kesinlik değeri özellikle yanlış positif tahminlemenin maliyeti yüksek olduğu durumlarda önemlidir. "Eş. 3.21" kesinlik ölçüsünün tanımlamaları verilmiştir [75].

$$Kesinlik(Precision) = \frac{TP}{TP + FN} \tag{3.21}$$

F1 Score

“F1 Score” değeri kesinlik ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir. "Eş. 3.22" kesinlik ölçüsünün tanımlamaları verilmiştir [75].

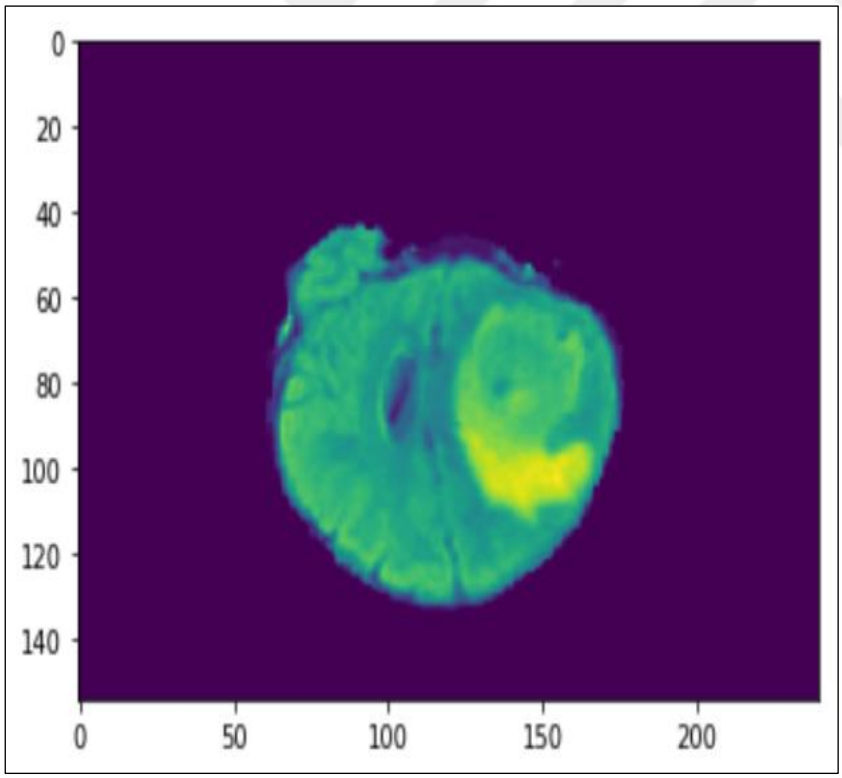
$$F1 - Score = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \tag{3.22}$$

4. DERİN ÖĞRENME TEMELLİ BEYİN TÜMÖR TESPİTİ

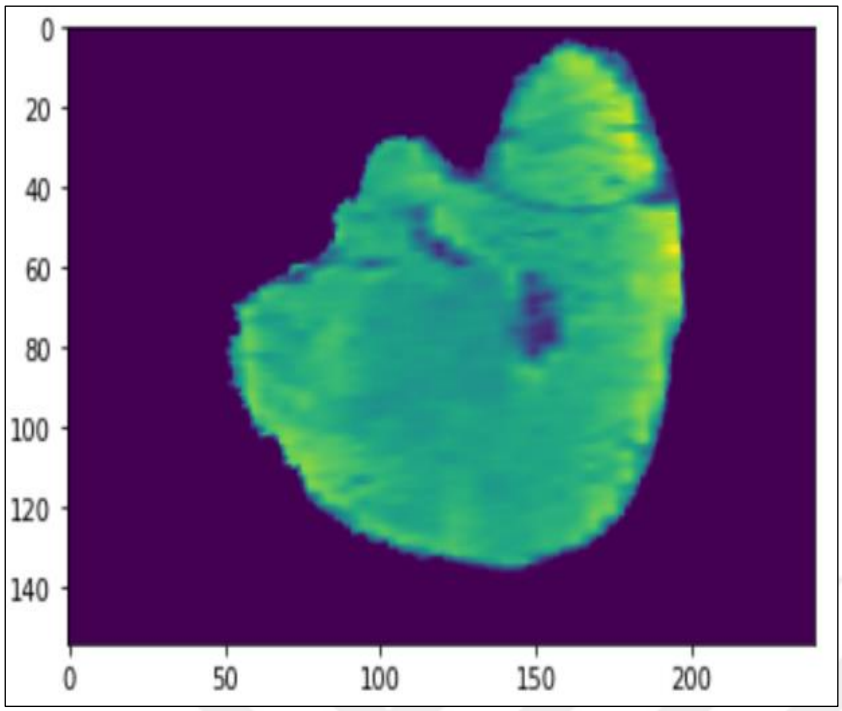
Bu çalışmada, derin öğrenme Unet algoritması temel alınarak beyin tümör tanısı için yeni ve etkin, uçtan uca bir segmentasyon ağı kullanılmıştır. Önerilen model Unet mimarisine dayanmakta, genişleyen ve daralan yollardan, kodlayıcı (encoder) ve kod çözücü (decoder) olmak üzere iki ağdan oluşmaktadır.

4.1. Veri Kümesi

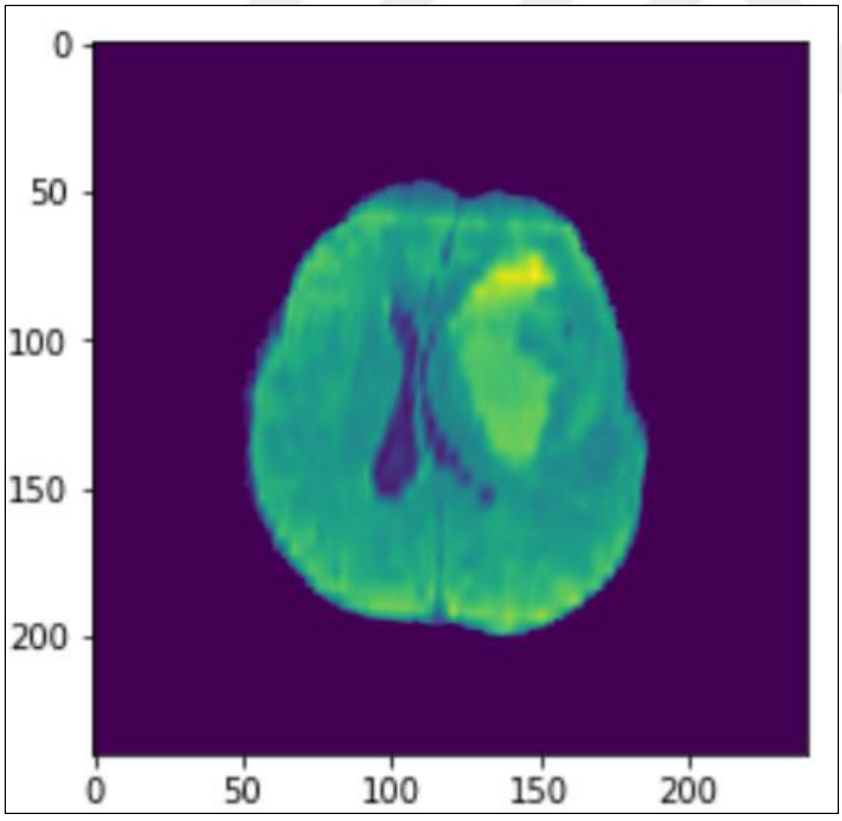
Multimodal Brain Tumor Segmentation Challenge (BraTS), beyin tümörleri ile ilgili yapılan çalışmalarda en büyük veriyi sağlayan kamuya açık veri kümesidir [76]. BraTS 2018 veri kümesi kullanılmıştır. Bu veri kümesi ile eğitim verisi için 18750 görüntü, doğrulama test veri işlemleri için 4650 görüntü kullanılmıştır. Şekil 4.1'de koronal, Şekil 4.2'de sagittal ve Şekil 4.3'te aksiyal kesitler verilmiştir.



Şekil 4.1 Koronal kesit

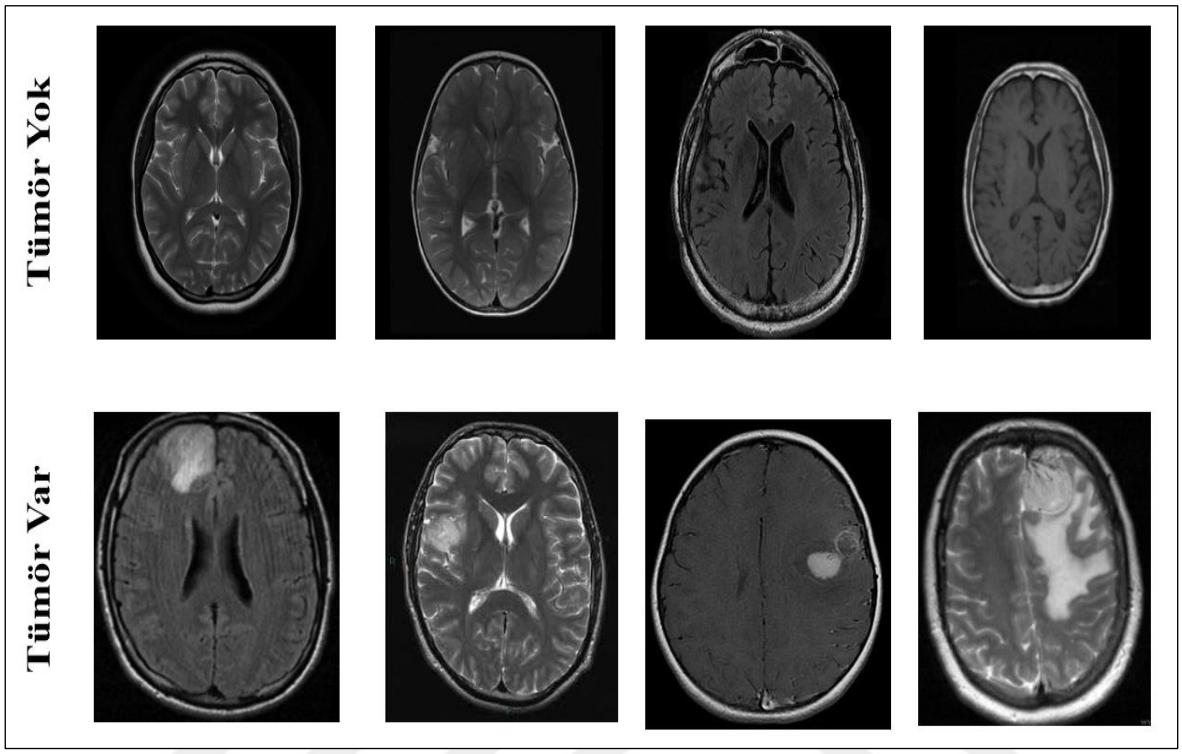


Şekil 4.2 Sagital kesit



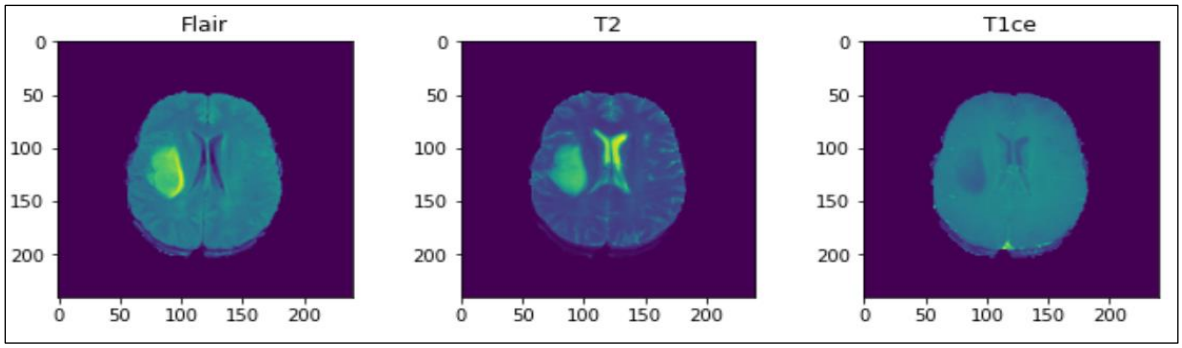
Şekil 4.3 Aksiyal kesit

Şekil 4.4'de deneyler sırasında kullanılan veri seti iki kısma ayrılır. Birinci kısım sağlıklı (tümör olmayan) ikinci kısım ise sağlıksız (tümör olan) hasta görüntülerinden oluşmaktadır.



Şekil 4.4 Tümör hücresi içeren ve içermeyen örnek beyin MRG.

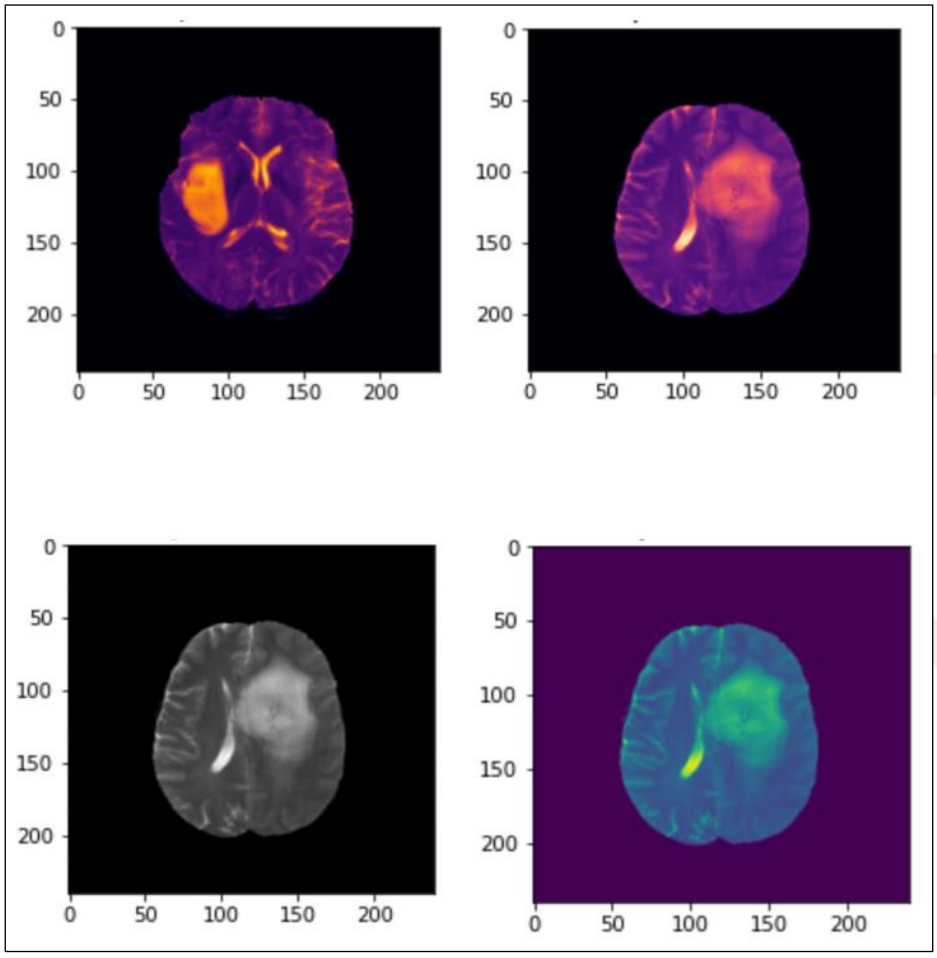
Veri kümesi beynin 3 boyutlu olarak çekilmiş MRG oluşmaktadır. Bu veri kümesindeki her görüntü, 240 × 240 × 155 voksel boyutunda. Bu görüntüler T2 Fluid Attenuated Inversion Recovery (FLAIR), Kontrastlı T1 ağırlıklı (T1CE), T1 ve T2 olarak adlandırılan 3D MRG modalitesini içerir. Şekil 4.5'de veri kümesinin görselleştirilmiş hali verilmiştir.



Şekil 4.5 MRG Flair, T2 ve T1ce kesitleri.

Tümör bölgesi T2 ve Flair görüntüsünde belirginlik gösterir. Radyoloji de tümörün ödem kısmı T2 görünümünden çekilir. Flair görünümü ise ödemin beyindeki diğer sıvı dolu

yapılardan ayrımını yapmak için kullanılır. Bu çalışmada beyin tümörü tespit edilirken Flair ve T2 görüntüleri beraber incelenir ve eğitime alınır. Flair ve T2 görüntülerin birleştirilmiş durumu Şekil 4.6'da gösterilmiştir.



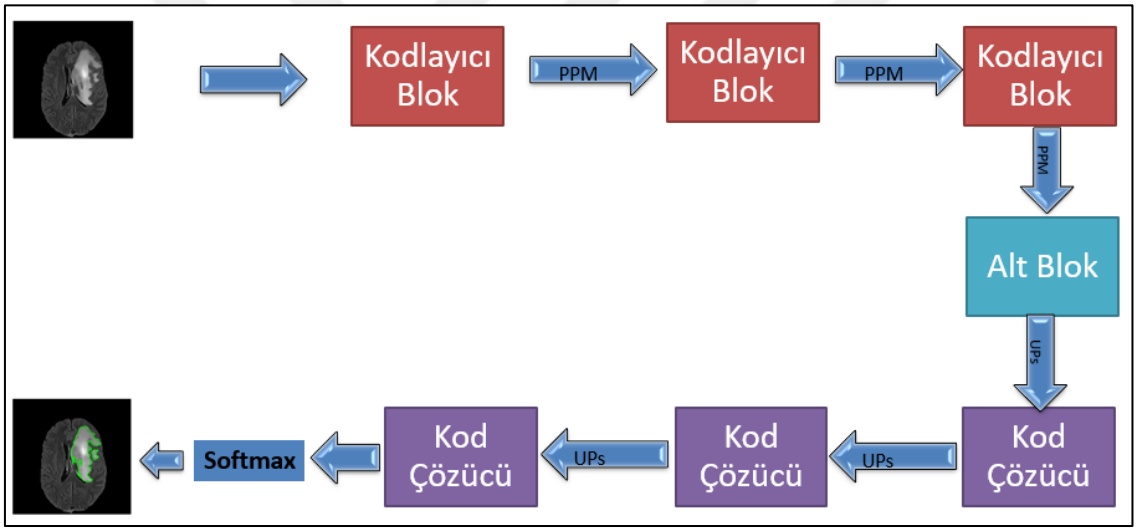
Şekil 4.6 MRG Flair ve T2 kesitlerinin birleştirilmiş görüntüsü.

4.2. Önerilen Unet Tabanlı Derin Öğrenme Mimarisi

Hasta MRG doktorlar tarafından manuel segmentasyonu görüntülerin dilim dilim ana hatlarının çıkarılmasını gerektirir. Ancak manuel segmentasyonun uzman görüşü ve teknolojik kısıtları nedeniyle bazı dezavantajları vardır. Bununla birlikte görüntü yorumlama son derece zaman alan bir işlemdir. Tecrübeye bağlı olarak hata yapma oranı da yüksektir. Bu çalışmada, beyin MRG otomatik tümör tespiti için uçtan uca Çok Ölçekli Çok Düzeyli Ağ (Multi-Scale Multi-Level Network MM-Network) modeli önerilmiştir. Gerçekleştirilen çalışmada, Unet'teki evrişimli ağ seviyesinde çoklu uzamsal ölçeklerin küresel bağlamsal özelliklerini birleştirerek, ağlar boyunca özellik haritalarının boyutuna bağlı olarak alıcı

alanın farklı oranlarda genişlemesini sağlayan genişletilmiş evrişim modülünden yararlanılmıştır.

Görüntü modele geldikten sonra, kodlayıcı (encoder) ağındaki her seviyede (PPM #1, 2 ve 3) tekrar tekrar bağlanır böylece yeniden tasarlanan sık piramit havuzlama ağı, çok uzamlı küresel bilgilerin çıkarılmasına ve öğrenilmesine ve bunların kodlayıcı ve kod çözücü ağlar arasında paylaşılmasına olanak tanır. Bununla birlikte, iç içe evrişim blokları veya yoğun bağlantılar kullanarak kodlayıcıyı kod çözücü boşluğu güçlendirilmiştir. Derin öğrenme yapıldığı için model, görüntünün özniteliklerini otomatik olarak bulması gerekir. Bu noktada görüntüyü anlamlandıran, resmin belirli özelliklerini çıkartan katman evrişim katmanıdır. Yöntem blok diyagramı Şekil 4.7'de verilmiştir.

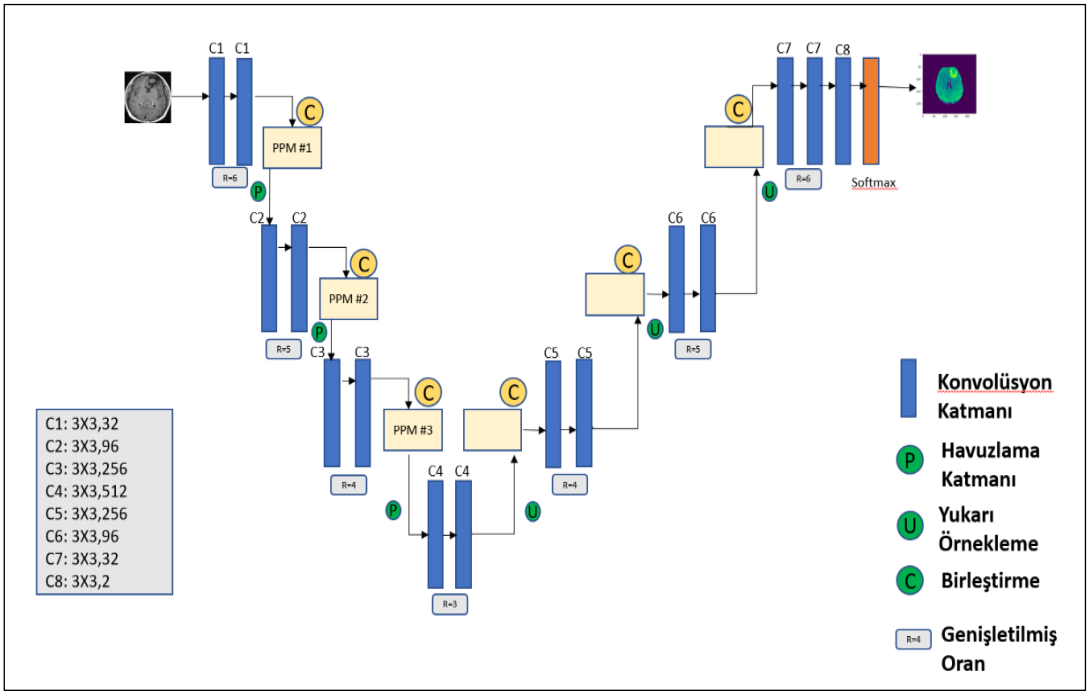


Şekil 4.7 Blok diyagram

Önerilen çalışma, kullanılan bileşenlerin yani genişletilmiş evrişim ve PPM çeşitli uzamsal ölçeklerin yakalanmasına yol açan her ağ katmanı aracılığıyla küresel çok ölçekli bağlamsal bilgiden tam olarak yararlanmak için yeniden tasarlanma şekline dayanır ve böylece giriş çözünürlüğü kaybını en aza indirir. Kod çözücü bloğu, görüntü boyutuna geri örnekleyen bir çözücü bloktur. Kodlayıcı bloğunun her bir yukarı örnekleme seviyesine karşılık gelen kodlayıcı blok çıktısını alır ve bir sonraki kod çözücü bloğunu beslemeden önce birleştirilir. Bu sayede görüntü kaybı olmadan görüntü anlamlı bir duruma gelecektir. Verileri sınıflandırmak için softmax katmanı kendisinden önce gelen tam bağlı katmandan girdi verisini alır. Alınan olasıksal veriyi hangi sınıfa ait olduğunu ve daha yakın olduğuna dair değer üretir. Her bir sınıf için derin öğrenme ağı içerisinde üretilen olasıklıksal hesaplama

gerçekleştirerek olasılık değerini çıkarır. Daha sonrasında model başarılı şekilde tümör bölgesini çıktı olarak verir.

Daralan yol, hiyerarşik özellikleri yakalamaktan sorumlu olan sıralı evrişim ve alt örnekleme katmanlarını içerir. Bu çalışmada Unet evrişimsel ağ yolunda sekiz evrişim ve üç havuzlama katmanı ve yedi yukarı evrişim, üç yukarı örnekleme ve genişleyen yolda tek bir softmax katmanı dahil olmak üzere dört ana seviyeden oluşur. Tümör tespiti için kullanılan mimarinin detayları Şekil 4.8'de görülmektedir.



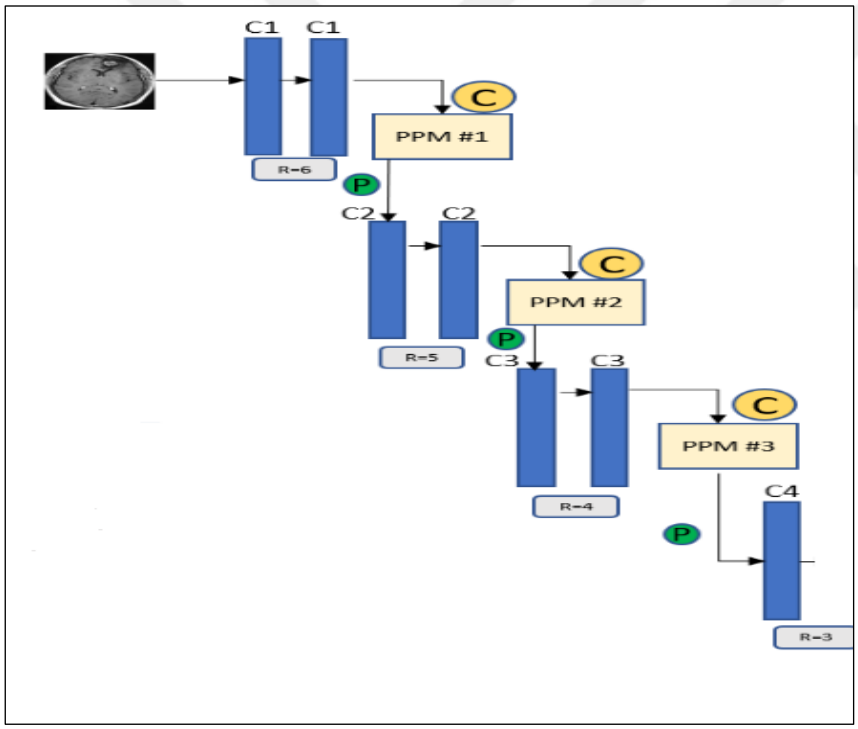
Şekil 4.8 Önerilen modelin alt yapı mimarisi [21]

Şekil 4.8' de görüldüğü gibi Unet mimarisi, kodlayıcı (encoder) ağındaki her seviyede (PPM #1, 2 ve 3) tekrar tekrar bağlanmasıyla gerçekleştirilir. Böylece, yeniden tasarlanan sık piramit havuzlama ağı, çok uzamlı küresel bilgilerin çıkarılmasına ve öğrenilmesine ve bunların kodlayıcı ve kod çözücü ağlar arasında paylaşılmasına olanak tanır. Bununla birlikte, iç içe evrişim blokları veya yoğun bağlantılar kullanarak kodlayıcıyı kod çözücü boşluğu güçlendirilmiş ve orijinal Unet'ten farklılaştırılmıştır. Önerilen çalışma, kullanılan bileşenlerin yani genişletilmiş evrişim ve PPM çeşitli uzamsal ölçeklerin yakalanmasına yol açan her ağ katmanı aracılığıyla küresel çok ölçekli bağlamsal bilgiden tam olarak yararlanmak için yeniden tasarlanma şekline dayanır ve böylece giriş çözünürlüğü kaybını en aza indirir. Daha spesifik olarak PPM #1 ve 2'de olduğu gibi erken kodlayıcı düzeyinde

PPM'nin uygulanması küresel ince taneli ve yapısal ayrıntıların öğrenilmesine ve ayrıca PPM kodlayıcının tepesindeyken giriş çözünürlüğünün (PPM #3) korunmasına neden olur. Bölümün devamında, deneysel çalışmada kullanılan veri kümesinden ve önerilen modelin mimari yapısından bahsedilmiştir.

4.3. Kodlama Bloğu (Encoder)

Modelin sol tarafı kodlayıcı blok (encoder) tarafıdır. Burada görüntünün "Ne" olduğu öğrenilir. Eğitim için modele bir görüntü eklenir. Bu görüntü kodlayıcı blok katmanında sürekli sıkıştırılır. Yani görüntünün boyutu her katmanda yarıya düşürülür. Şekil 4.9'da kodlayıcı blok kısmı verilmiştir.



Şekil 4.9 Kodlayıcı blok kısmı

Bunların arasında, kodlayıcı, giriş verilerinin uzamsal boyutunu kademeli olarak azaltmak için bir havuzlama katmanı kullanır.

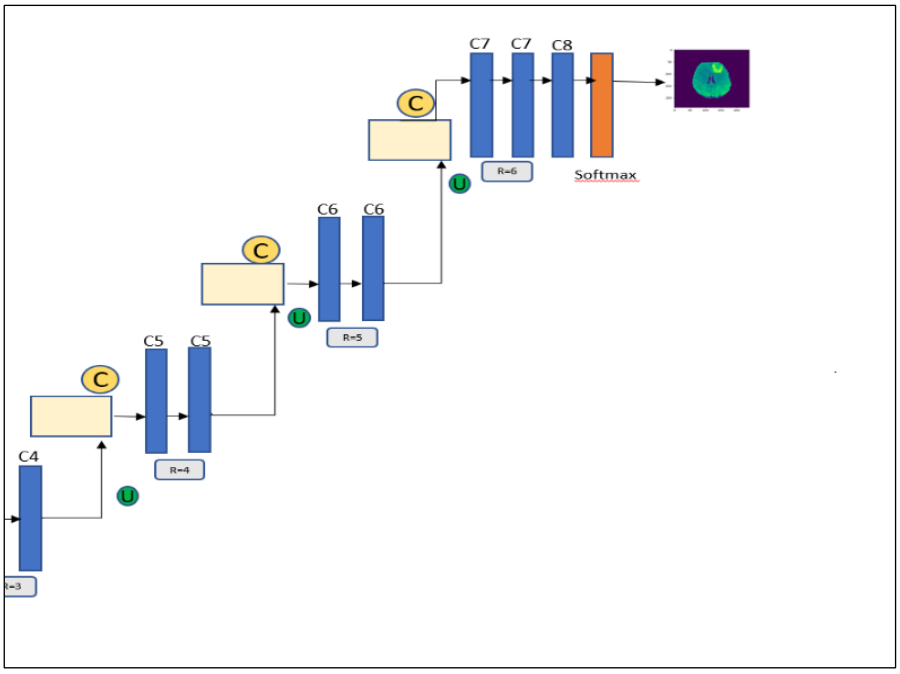
4.4. Piramit Havuzlama (PPM)

Piramit Havuzlama Modülü (PPM) arka plan bilgilerini toplamak için kullanılır. Düzleştirilmiş ve birleştirilmiş çok seviyeli özellikleri sınıflandırma görevlerinde F-ESA'ya

geçiren Uzamsal Piramit Havuzu (Spatial Pyramid Pooling) aksine, PPM çeşitli alt düzeyler arasındaki bilgi kaybı azaltılır ve etkili hiyerarşik küresel temsilleri çıkarılır [21]. PPM, kıvrımlı özelliklerin farklı ölçeklerle dört paralel piramit seviyesine alt örneklenmesiyle başlar. Daha büyük havuzlama faktörü, daha kaba özellikler üretirken daha ince temsiller daha küçük havuzlama faktörleriyle çıkarılır. Ardından, 1×1 evrişim kullanan darboğaz katmanı, bağlam boyutunu 1/N indirerek hesaplama yeteneğini geliştirmek için havuzlanmış her özellikten sonra doğrudan uygulanır; burada N, piramidin seviye boyutunu gösterir. Örneğin, havuzlama piramidinin seviye boyutu N=4 ise, o zaman her seviyenin özellik haritaları 1/4 faktörü kadar azaltılacaktır [21]. Piramidin hemen önündeki orijinal özellik haritalarına geri dönmek için havuzlama, çift doğrusal enterpolasyon yoluyla yukarı örnekleme, her piramit düzeyine uygulanır. Sonunda, küresel bağlam özelliklerini birleştirmek için tüm yukarı örneklenmiş özellik haritalarının orijinal özellik haritasıyla birleştirilmesi gerçekleştirilir.

4.5. Kod Çözücü (Decoder)

Görüntü genişlemeye Decoder işleminde başlar. Burada görüntünün boyu tekrar 2 katına çıkarılır. Daha sonra yukarı örnekleme (UpConv) işlemi yapılır. Modelin asıl detayı bu kısımda ortaya çıkmaktadır. Çünkü decoder tarafındaki her katman encoder tarafında karşılık geldiği katmanla birleştirilir. Şekil 4.10'da kod çözücü blok kısmı gösterilmiştir.

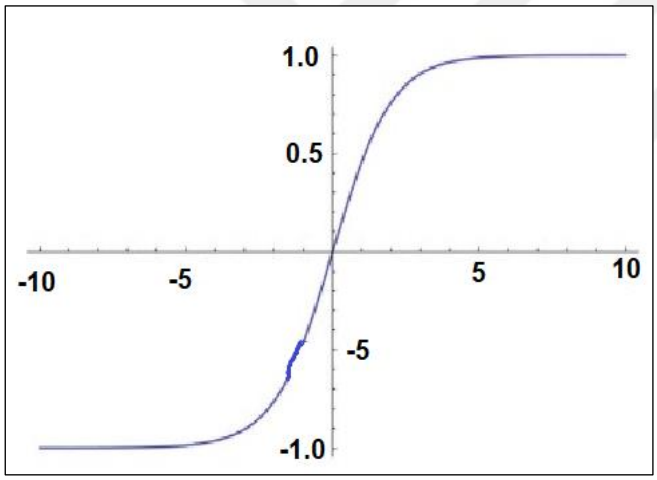


Şekil 4.10 Kod çözücü blok kısmı

4.6. Softmax

Softmax, sınıflandırma işlemi yapabilen bir aktivasyon fonksiyonu olarak tanımlanır. Gerçek dünya karmaşık verileri yapay sinir ağına öğretebilmek için kullanılır. Aktivasyon fonksiyonu kullanılmayan yapay sinir ağı modeli, verilerdeki karmaşık yapıları tespit ve analiz etmekte çoğu zaman yetersiz kalacaktır. Bu yüzden eğitilen modellerde aktivasyon fonksiyonu kullanılır.

Softmax, aktivasyon fonksiyonlarından biridir. Softmax işlevi genellikle sinir ağı tabanlı bir sınıflandırıcının son katmanında kullanılır. Softmax fonksiyonu sıklıkla çoklu Sigmoid olarak bilinir. Bu tanımlama çok sınıflı hedef değişkeni içeren sınıflandırma problemleri (multi-class classification) için uygun bir fonksiyondur. Softmax grafiği Şekil 4.11'de gösterilmiştir. Softmax, çıktı olarak her sınıfa ait olasılık sonucu döndürür [77].



Şekil 4.11 Softmax aktivasyon fonksiyon grafiği [77]

Çoklu sınıflandırma problemleri için kullanılan aktivasyon fonksiyonudur. Bu aktivasyon fonksiyonu verilen her bir girdinin bir sınıfa ait olma olasılığını gösteren 0 ile 1 arasında çıktılar üretir. Genellikle sınıflandırma işlemi yapan yapay sinir ağlarının çıkış birimi olarak kullanılır. N sınıf sayısı olmak üzere v çıkış nöronuna gelen giriş değeri girdinin i sınıfına ait olma olasılığı "Eş. 4.1" gibi tanımlanır [77].

$$p_i = \frac{e^{v_i}}{\sum_{j=1}^{N} e^{v_j}} \tag{4.1}$$

5. DENEYSEL ÇALIŞMA ve BULGULAR

Deneysel çalışmalar, NVIDIA GeForce GTX 1050 ekran kartı bulunan bir bilgisayar üzerinde, Python TensorFlow ve Keras kütüphaneleri kullanılarak gerçekleştirilmiştir. Veri kümesi olarak NIFTI formatındaki yüksek çözünürlüklü 18750 örneklem kullanılmıştır. Bu veri kümesinde 18750 örnek eğitim aşamasında 4650 örnek ise modelin test edilmesi aşamasında kullanılmıştır.

Model eğitilirken veri setinde bulunan tüm verileri aynı anda işlemesi bilgisayar donanım gücüne bağlı olarak zaman ve bellek açısından problem oluşturabilir. Batch_size değeri GPU belleğine uygun kullanmak için ikinin katları şeklinde belirlenmiştir. Batch_size değerindeki değişiklikler model başarısında yüksek etkiye sahiptir. Bu çalışmada Çizelge 5.1 ve Çizelge 5.2'de görüldüğü gibi batch_size 16 ve epoch 30 için en uygun değer %99,45 ile adam optimizasyonu belirlenmiştir.

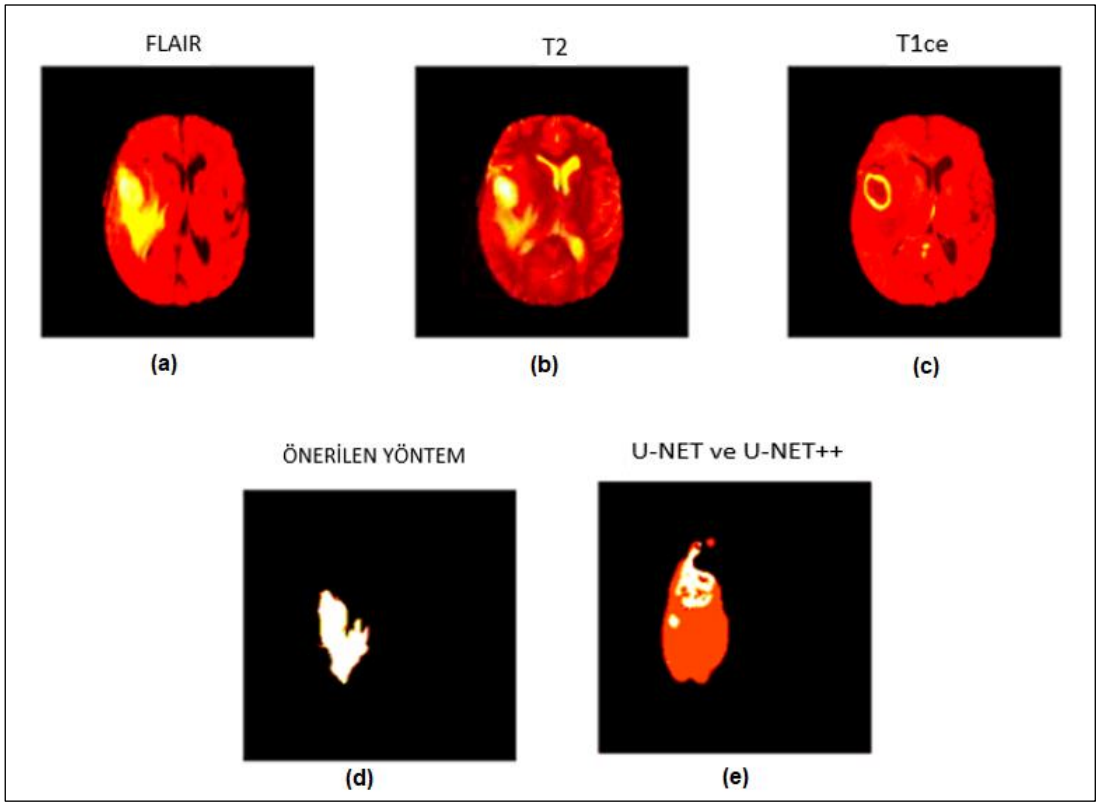
Çizelge 5.1 Parametre karşılaştırma

Küme Boyutu (Batch Size)	**Döngü Sayısı (Epoch)**	**Doğruluk (Accuracy)**
4	10	90,50%
4	20	92,60%
4	30	93,20%
8	10	94,50%
8	20	95,20%
8	30	95,80%
16	10	96,90%
16	20	98,20%
16	30	99,45%

Çizelge 5.2 Optimizer karşılaştırma

Optimizer	**Doğruluk (Accuracy)**
Adam	99,45%
SGD	89,60%
RMSprop	98,60%
Adagrad	90,70%
Adadelta	92,80%

Şekil 5.1'de Flair, T2, T1ce, Unet ve Unet++. Önerilen yöntem, veri görselleştirilmiş durumu verilmiştir. Tümör bölgesinin yüksek derece benzerliği ile başarılı bir sonuç vermiştir.



Şekil 5.1 Tümör segmentasyon

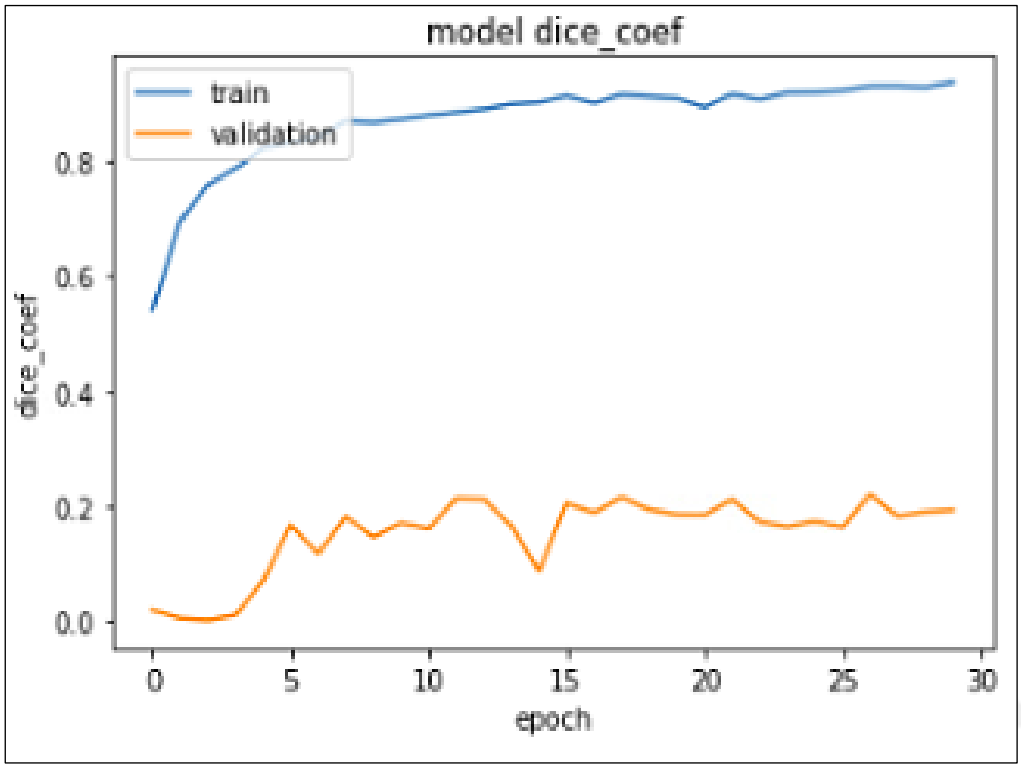
Bu çalışmada 18750 beyin MRG üzerinde deneysel çalışma yapılmıştır. 14690 tümör olan (pozitif) örneklem ile tümör olmayan 4060 örneklem kullanıldı. Veri kümesinin büyüklüğü modeli daha başarılı hale getirdiği gözlemlendi. Modelin karışıklık matrisi (confusion matrix) değerleri Çizelge 5.3'de verilmiştir.

Çizelge 5.3 Karışıklık matris sonucu

	Tahmin (Negatif)	**Tahmin (Pozitif)**
Gerçek (Negatif)	3995	65
Gerçek (Pozitif)	40	14650

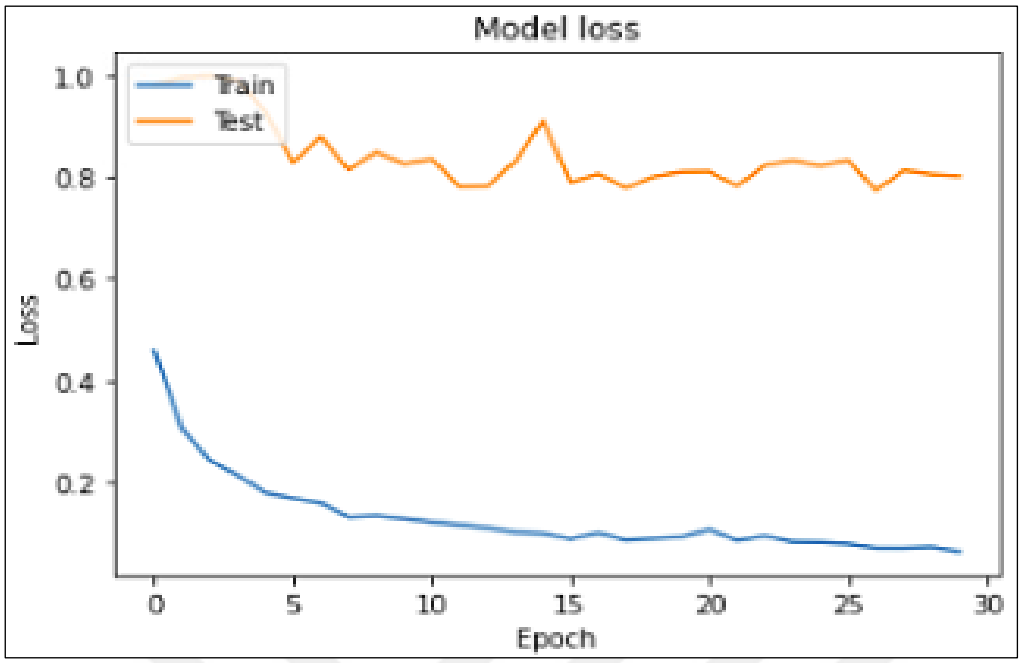
Model 30 epoch değeri ile eğitilmiş, zar benzerlik katsayısı değerleri sırası ile 0,9873 ve 0,9851 olarak bulunmuştur. Genişleyen tümör görüntüsünün iç kısmında bulunan küçük

Nekroz alanları dahi daha başarılı bir şekilde tespit edilebilmiştir. Şekil 5.2'de epoch adımları sırasında eğitim ve geçerleme süreçlerindeki zar benzerlik katsayısı grafik görüntüsü verilmiştir.



Şekil 5.2 Zar benzerlik katsayısı grafiği

Şekil 5.3'te epoch adımları sırasında eğitim ve test süreçlerindeki hata oranı (model loss) grafik görüntüsü verilmiştir. Eğitim sırasında hata oranının düşük olması eğitimin başarılı bir yol izlediğini gösterir.



Şekil 5.3 Hata oranı

6. SONUÇ VE DEĞERLENDİRME

Tıbbi görüntü segmentasyonu için çok ölçekli çok düzeyli ağ adlı uçtan uca bir derin öğrenme ağı önerilmiştir. Bu önerilen modelin ana fikri, ağın minimum çözünürlük kaybıyla hedefin çeşitli uzamsal ölçeklerini öğrenmesini sağlayan her kodlayıcı evrişim düzeyinde küresel çok düzeyli bağlamsal bilgi üretmektir. Aynı zamanda bu çalışmanın literatüre katkısı önerilen modelin, minumum çözünürlük kaybı ile yüksek doğruluk seviyesine ulaşmasıdır. Bu model ile sadece MRG üzerinde değil diğer biyomedikal görüntüler üzerinde de çalışma yapılıp yüksek doğruluk seviyesine ulaşılabilir.

Gerçekleştirilen deneysel çalışmalarda BraTS 2018 veri kümesinden 18750 örneklem model çıkarımı için kullanılmıştır. 4650 örneklem üzerinde yapılan testte %99,45 doğrulukta tümör tanısı gerçekleştirilmiştir.

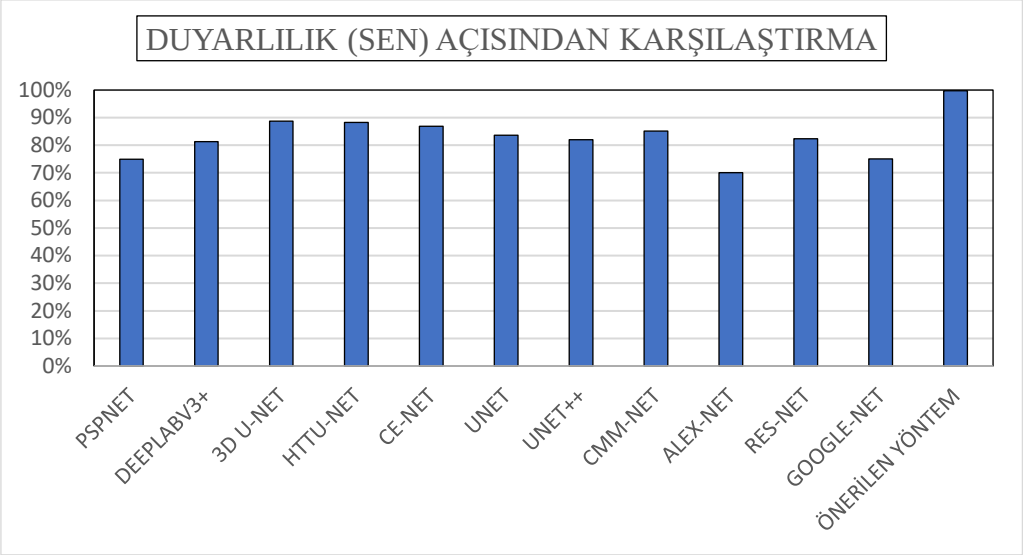
Literatürde BraTS 2018 veri kümesini kullanan çalışmalar ile çok düzeyli çok ölçekli ağ modeli ile gerçekleştirilen deneysel çalışma karşılaştırması Çizelge 6.1'de verilmiştir.

Çizelge 6.1 Tümör segmentasyon performansı

METHOD	SEN	SPE	ACC	DSC
PSPNET [20]	%74,94	%99,73	%99,38	%76,89
DEEPLABV3+ [31]	%81,30	%99,30	%99,03	%82,86
3D U-NET [78]	%88,70	%99,50	-	%88,90
HTTU-NET [30]	%88,30	%99,90	-	%86,50
CE-NET [32]	%86,91	%99,28	%99,11	%82,90
UNET [79]	%83,63	%98,27	%98,16	%71,28
UNET++ [80]	%82,03	%98,31	%98,10	%83,05
CMM-NET [21]	%85,19	%99,55	%99,35	%83,95
ALEX-NET [23]	%70	%86,21	%79,59	-
RES-NET [23]	%82,35	%87,50	%85,71	-
GOOGLE-NET [23]	%75	%89,66	%83,67	-
ÖNERİLEN YÖNTEM	**%99,72**	**%98,39**	**%99,45**	**%99,28**

Çizelge 6.1’de görüldüğü gibi; Önerilen çok düzeyli çok ölçekli ağ modelinin literatürde yapılan çalışmalar [5, 6, 8, 16-18, 20-22] ile kıyaslandığında daha iyi sonuçlar verdiği gözlemlenmiştir.

Önerilen yöntemin Duyarlılık (SEN) açısından yüzdelik kıyaslaması Şekil 6.1’de verilmiştir.

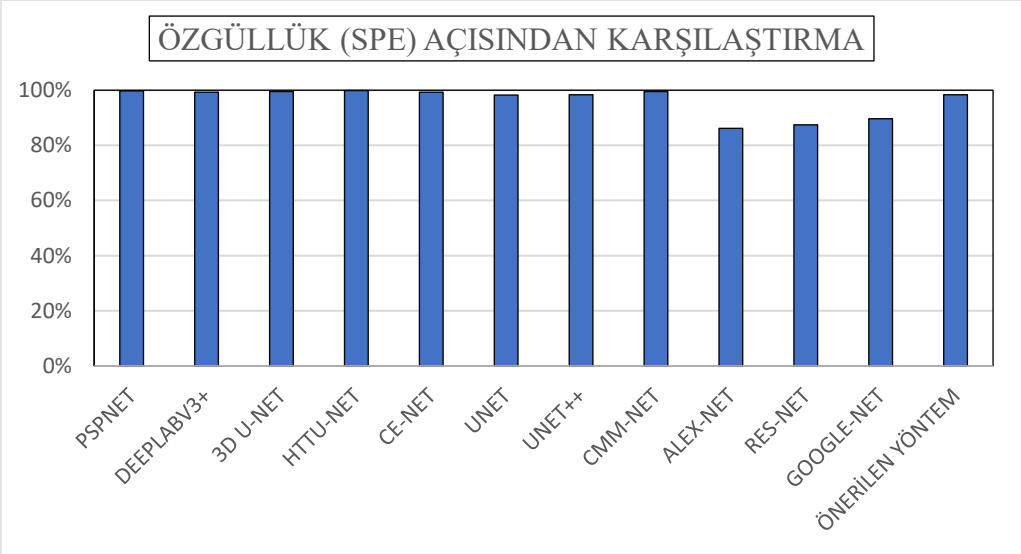


Şekil 6.1 Önerilen model ile diğer modellerin duyarlılık karşılaştırılması

Şekil 6.1’de PSPNET, DEEPLABV3+, 3D U-NET, HTTU-NET, CE-NET, UNET, UNET++, CMM-NET, ALEX-NET, RES-NET, GOOGLE-NET, Önerilen yöntem modellerin duyarlılık değerleri verilmiştir. Sırasıyla; %75, %81,30, %88,70, %88,30, %86,91, %84, %82,03, %85,19, %70, %82,35, %75, %99,72.

Önerilen yöntem, PSPNET, DEEPLABV3+, 3D U-NET, HTTU-NET, CE-NET, UNET, UNET++, CMM-NET, ALEX-NET, RES-NET, GOOGLE-NET karşılaştırıldığında sırasıyla %33,06, %22,65, %12,42, %12,93, %14,73, %19,23, %21,56, %17,05, %42,45, %21,09 ve %32,95 SEN sonuçları önemli bir artış göstermiştir.

Önerilen yöntemin Özgüllük (SPE) açısından yüzdelik kıyaslaması Şekil 6.2'de verilmiştir.

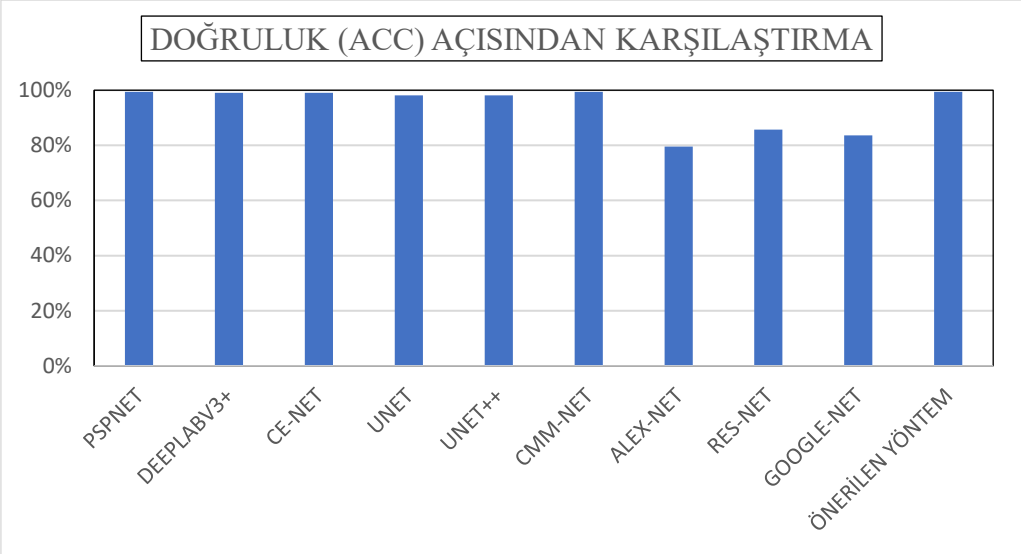


Şekil 6.2 Önerilen model ile diğer modellerin özgüllük karşılaştırılması

Şekil 6.2'de PSPNET, DEEPLABV3+, 3D U-NET, HTTU-NET, CE-NET, UNET, UNET++, CMM-NET, ALEX-NET, RES-NET, GOOGLE-NET, Önerilen yöntem modellerin özgüllük değerleri verilmiştir. Sırasıyla; %99,70, %99,30, %99,50, %99,90, %99,28, %98,27, %98,31, %99,55, %86,21, %87,50, %89,66, %98,39.

Önerilen yöntem, UNET, UNET++, ALEX-NET, RES-NET, GOOGLE-NET karşılaştırıldığında sırasıyla %0,12, %0,08, %14,12, %12,44, %9,73, özgüllük değer sonuçları önemli bir artış göstermiştir.

Önerilen yöntemin Doğruluk (ACC) açısından yüzdelik kıyaslaması Şekil 6.3'de verilmiştir.



Şekil 6.3 Önerilen model ile diğer modellerin doğruluk karşılaştırılması

Şekil 6.3'de PSPNET, DEEPLABV3+, CE-NET, UNET, UNET++, CMM-NET, ALEX-NET, RES-NET, GOOGLE-NET, Önerilen yöntem, modellerin doğruluk değerleri verilmiştir. Sırasıyla; %99,38, %99,03, %99,11, %98,16, %98,10, %99,35, %79,59, %85,71, %83,67, 99,45.

Önerilen yöntem, PSPNET, DEEPLABV3+, CE-NET, UNET, UNET++, CMM-NET, ALEX-NET, RES-NET, GOOGLE-NET karşılaştırıldığında sırasıyla %0,07, %0,42, %0,34, %1,31, %1,37, %0,10, %24,95, %16,03 ve %18,85 doğruluk sonuçları önemli bir artış göstermiştir.

Bilgisayar destekli tanı sistemi özellikle teşhis ve tanı da önemli rol oynamaktadır. Beyin analizi çeşitli yaklaşımlarla bulgular ve anatomik bölgelerin doğru sınıflandırılmasına dayanır. Bu çalışmada insan hayatını olumsuz yönde etkileyen bir hastalığın teşhisine yönelik yöntem geliştirilmiştir. Önerilmiş olan model %99,45 sonucu ile yüksek başarı performansına ulaşmıştır. Aynı model ile ileride tanı ve teşhis için medikal görüntüler üzerinden çalışma yapılabilir.

KAYNAKLAR

1. A. Selvapandian and K. Manivannan (2018). Fusion based Glioma brain tumor detection and segmentation using ANFIS classification. *Computer Methods Programs Biomedicine*. 166, 33-38.

2. Z.U. Rehman, S.S. Naqvi, T.M. Khan, M.A. Khan, and T. Bashir (2019). Fully automated multi-parametric brain tumour segmentation using superpixel based classification. *Expert System Application*. 118(12), 598-613.

3. M. Talo, U.B. Baloglu, O. Yıldırım and U. Rajendra Acharya (2019). Application of deep transfer learning for automated brain abnormality classification using MR images. *Cognitive Systems Research*. 54(13), 176-188.

4. L. Šajn and M. Kukar (2011). Image processing and machine learning for fully automated probabilistic evaluation of medical image. *Computer Methods Programs Biomedicine*. 104(3), 75-86.

5. S. Kumar, C. Dabas and S. Godara (2017). Classification of Brain MRI Tumor Images: A Hybrid Approach. *Procedia Computer Science*. 122(2), 510-517.

6. K. Dimililer and A. Ilhan (2016). Effect of Image Enhancement on MRI Brain Images with Neural Networks. *Procedia Computer Science*. 102(12), 39-44.

7. J. Kleesiek, G. Urban, A. Hubert, D. Schwarz, K. Maier-Hein, M. Bendszus and A.Biller (2016). Deep MRI brain extraction: A 3D convolutional neural network for skull stripping. *Neuroimage*. 129(1), 460-469.

8. WORLD HEALTH ORGANIZATION. World health statistics 2018: monitoring health for the SDGs, sustainable development goals. World Health Organization, 2018.

9. A. ARI ve D. Hanbay (2018). Bölgesel evrişimsel sinir ağları tabanlı MR görüntülerinde tümör tespiti. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*. 34(3), 1395–1408.

10. Murino V., Puppo E., Sona, D., Cristani M., and Sansone C. (Eds.). (2015). New Trends in Image Analysis and Processing. ICIAP 2015 Workshops: ICIAP 2015 International Workshops. 9281.

11. Al-shamasneh A. R. M., and Obaidellah U. H. B. (2017). Artificial intelligence techniques for cancer detection and classification: review study. *European Scientific Journal*. 13(3), 342-370.

12. E. Dandil, Y. Erdınç and A. O. Selvi (2018), Automatic segmentation and applied analysis of liver on computed tomography scans, *26th Signal Processing and Communications Applications Conference (SIU),*1-4.

13. H. Chen, Q. Dou, L. Yu, J. Qin and P.A Heng (2018). VoxResNet: Deep voxelwise residual networks for brain segmentation from 3D MR images. *Neuroimage*.170(1), 446-455.

14. S.S. Yadav and S.M. Jadhav (2019). Deep convolutional neural network based medical image classification for disease diagnosis. *Journal of Big Data*. 6, 113.

15. S. Bakas, M. Reyes, A. Jakab, S. Bauer, M. Rempfler, A. Crimi, et al. (2018). Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation. *Progression Assessment, and Overall Survival Prediction in the BRATS Challenge*.

16. Isensee F., Kickingereder P., Wick, W., Bendszus M. and Maier-Hein (2018). No new-network. *International MICCAI Brainlesion Workshop*. 234–244.

17. Ronneberger Olaf and Fischer, Philipp and Brox, Thomas (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 234-241.

18. Zhou, Zongwei et al. (2020). UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation. *IEEE Transactions on Medical Imaging*. 39, 1856-1867.

19. M. A. Al-masni, M. A. Al-antari, J.M Park, G. Gi, T.Y Kim, P.Rivera, E. Valarezo, M.T. Choi, S.M Han and T.S. Kim (2018). Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system. *Computer Methods and Programs in Biomedicine*. 157, 85-94.

20. Zhao, Hengshuang, Jianping Shi, Xiaojuan Qi, Xiaogang Wang and Jiaya Jia (2017). Pyramid Scene Parsing Network. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 6230-6239.

21. M.A. Al-masni and D.H. Kim (2021). CMM-Net: Contextual multi-scale multi-level network for efficient biomedical image segmentation. *Scientific Reports*. 11, 10191.

22. O. Yıldız (2019). Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study. *Journal of the faculty of engineering and architecture of gazi university*. 34, 2241-2260.

23. H. Bingol ve B. Alatas (2021), Classification of Brain Tumor Images using Deep Learning Methods. *Turkish Journal of Science and Technology*. 16, 137-143.

24. A. ARI ve D. Hanbay (2018). Bölgesel evrişimsel sinir ağları tabanlı MR görüntülerinde tümör tespiti. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*. 18–2, 1395–1408.

25. Saeed, M.U., Ali G., Bin W., Almotiri, S.H. AlGhamdi, M.A. Nagra, A.A., Masood, K., Amin and R.u (2021). RMU-Net: A Novel Residual Mobile U-Net Model for Brain Tumor Segmentation from MR Images. *Electronics*. 10, 19-62.

26. Liu, H., Shen, X., Shang, F., Ge, F. ve Wang, F. (2019). CU-Net: Cascaded U-Net with Loss Weighted Sampling for Brain Tumor Segmentation. *Multimodal Brain Image Analysis and Mathematical Foundations of Computational Anatomy*. 102–111.

27. Arora, A. Jayal, A. Gupta, M. Mittal, P. Satapathy, S.C (2021). Brain Tumor Segmentation of MRI Images Using Processed Image Driven U-Net Architecture. *Computers 2021*. 10, 139.

28. Kong, X., Sun, G., Wu, Q., Liu, J. ve Lin, F. (2018). Hybrid Pyramid U-net Model for Brain Tumor Segmentation. *International conference on intelligent information processing*. 346–355.

29. Qamar, S., Ahmad, P. ve Shen, L. (2020). HI-Net: Hyperdense Inception 3D UNet for Brain Tumor Segmentation. *arXiv preprint arXiv:2012*. 06760.

30. N. M. Aboelenein, P. Songhao, A. Koubaa, A. Noor and A. Afifi (2020). HTTU-Net: Hybrid Two Track U-Net for Automatic Brain Tumor Segmentation. *IEEE Access*. 8-101406-101415

31. Chen, Liang-Chieh et al (2018). Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. *ArXiv*.1802,02611.

32. Z. Gu et al. (2019). CE-Net: Context Encoder Network for 2D Medical Image Segmentation. *IEEE Transactions on Medical Imaging*. 10 - 2281-2292.

33. M. Spahn (2013). X-ray Detectors in Medical Imaging. *Nuclear Instruments and Methods in Physics Research Section*. 731, 57–6311.

34. Kasban H., El-Bendary, M. A. M., and Salama, D. H. (2015). A comparative study of medical imaging techniques. *International Journal of Information Science and Intelligent Systems*. 4, 37–58.

35. J. Xu and B.M.W. Tsui (2014). Quantifying the Importance of the Statistical Assumption in Statistical X-ray CT Image Reconstruction. *IEEE Transactions on Medical Imaging*. 33, 61-73.

36. Zeleznik, R. Foldyna, B. Eslami, P. et al (2021). Deep convolutional neural networks to predict cardiovascular risk from computed tomography. Nature Communications. 12, 715.

37. I. Mehmood, N. Ejaz, M. Sajjad and S. W. Baik (2013). Prioritization of Brain MRI Volumes Using Medical Image Perception Model and Tumor Region Segmentation. *Computers in Biology and Medicine*. 43, 1471-1483.

38. S. Seshamani, X. Cheng, M. Fogtmann, M. E. Thomason and C. Studholme (2014). A Methodfor handling intensity inhomogenieties in fMRI sequences of moving anatomy of the early developing brain. *Medical Image Analysis*. 18, 285-300.

39. P. Sahuquillo, J. I. Tembl, V. Parkhutik, J. F. Vázquez, I. Sastre and A. Lago (2013). The Study of Deep Brain Structures by Transcranial Duplex Sonography and Imaging Resonance Correlation. *Ultrasound in Medicine and Biology*. 39, 226-232.

40. Smith, N. B., and Webb, A. (2010). Introduction to medical imaging: physics, engineering and clinical applications. *Cambridge university press*.

41. Hosseini MP., Lu S., Kamaraj K., Slowikowski A., Venkatesh H.C. (2020). Deep Learning Architectures. In: Pedrycz W., Chen SM. (eds) Deep Learning: Concepts and Architectures. *Studies in Computational Intelligence Springer*. 866.

42. He K., Zhang X., Ren S., Sun, J. (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition*. 770-778.

43. Szegedy C., Liu, W., Jia, Y., Sermanet P., Reed, S., Anguelov D., Rabinovich A. (2015). Going deeper with convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition*.1-9.

44. Bishop, C. M. (2006). Pattern recognition and machine learning (Information science and statistics). Springer-Verlag New York. Inc.

45. Jayanth Balaji, A., Harish Ram, D. S., and Nair, B. B. (2018). Applicability of deep learning models for stock Price forecasting an empirical study on BANKEX data. *Procedia Computer Science*. 143, 947–953.

46. Spooner T., Fearnley J., Savani R., and Koukorinis A. (2018). Market making via reinforcement learning. *Proceedings of the 17th International Conference on Autonomous Agents and MultiAgent systems*. 434–442.

47. Şapcı B. and Taşlı Pektaş Ş. (2021). Makine Öğrenmesi Aracılığı ile Kullanıcı Deneyimi Bilgilerinin Erken Mimari Tasarım Süreçleriyle Bütünleştirilmesi. *Journal of Computational Design*. 2 (1), 67-94.

48. Lalmuanawma S., Hussain J., Chhakchhuak L. (2020). Applications of machine learning and artificial intelligence for covid-19 (sars-cov-2) pandemic: a review. *Chaos Solitons and Fractals*. 110059.

49. Kushwaha S, Bahl S, Bagha AK, Parmar KS, Javaid M, Haleem A, Singh RP (2020). Significant applications of machine learning for covid-19 pandemic. Journal of Industrial Integration Management. 5(4).

50. Ardabili SF, Mosavi A, Ghamisi P, Ferdinand F, Varkonyi-Koczy AR, Reuter U, Rabczuk T, Atkinson PM (2020). Covid-19 outbreak prediction with machine learning. *Journal of Algorithms*. 13(10), 249.

51. Shrestha, Y. R., Krishna, V., and von Krogh, G. (2021). Augmenting organizational decision-making with deep learning algorithms: Principles, promises, and challenges. *Journal of Business Research*. 123, 588–603.

52. Jayanth Balaji, A., Harish Ram, D. S., and Nair, B. B. (2018). Applicability of deep learning models for stock Price forecasting an empirical study on BANKEX data. *Procedia Computer Science*. 143, 947–953.

53. Russell, S. J., and Norvig, P. (2021). Artificial intelligence: A modern approach (4th ed.). Pearson.

54. Jayanth Balaji, A., Harish Ram, D. S., and Nair, B. B. (2018). Applicability of deep learning models for stock Price forecasting an empirical study on BANKEX data. *Procedia Computer Science*. 143, 947–953.

55. Alakus TB, Turkoglu I. (2020). Comparison of deep learning approaches to predict covid-19 infection. Chaos Solitons Fractals.140.

56. L. Dian and S. Dongmei (2016). Contactless palmprint recognition based on convolutional neural network. *IEEE 13th International Conference on Signal Processing (ICSP)*.1363–1367.

57. İnternet: Michael Nielsen, Neural Networks and Deep Learning.URL: http://neuralnetworksanddeeplearning.com, Son Erişim Tarihi:01.12.2019

58. İnternet: CS231n Convolutional Neural Networks for Visual Recognition.URL: http://cs231n.github.io/convolutional-networks, Son Erişim Tarihi: 08.05.2019.

59. İnik, Ö. & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri . Gaziosmanpaşa Bilimsel Araştırma Dergisi , 6 (3) , 85-104 .

60. Krizhevsky A., Sutskever I., Hinton G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*. 25, 1097-1105.

61. He K., Zhang X., Ren S., Sun, J. (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition*. 770-778.

62. Szegedy C., Liu, W., Jia, Y., Sermanet P., Reed, S., Anguelov D., Rabinovich A. (2015). Going deeper with convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition*.1-9.

63. R. Kijowski F.Liu, F. Caliva and V.Pedoia (2020). Deep learning for lesion detection, Progression, and Prediction of Musculoskeletal Disease. *Journal of Magnetic Resonance Imaging*. 52 (6),1607-1619.

64. Y. Hou, Z. Liu, T. Zhang and Y. Li (2021). C-UNet: Complement UNet for remote sensing road extraction. *Sensors (Basel, Switzerland)*. 21(6), 2153.

65. İnternet: François Chollet, Keras. URL: https://tr.wikipedia.org/wiki/Keras. Son Erişim Tarihi :23.01.2022

66. Ashraf, M. et al. (2021). Prediction of Cardiovascular Disease Through Cutting-Edge Deep Learning Technologies: An Empirical Study Based on TENSORFLOW, PYTORCH and KERAS. *Sipringer (Singapore)*. 239-255.

67. Jürgen Schmidhuber (2015). Deep learning in neural networks: An overview. *Neural Networks*. 61, 85-117.

68. Kingma D. P., and Ba J. L. (2015). Adam: a Method for Stochastic Optimization. *International Conference on Learning Representations*. 1-13.

69. Zhang S., Choromanska A., and LeCun Y. (2015). Deep learning with Elastic Averaging SGD. *Neural Information Processing Systems Conference (NIPS 2015)*. 1–24.

70. Duchi J., Hazan E., and Singer, Y. (2011). Adaptive Subgradient Methods for Online Learning and Stochastic Optimization. *Journal of Machine Learning Research*. 12, 2121–2159.

71. İnternet: Ruder S., An overview of gradient descent optimization algorithms. URL: https://ruder.io/optimizing-gradient-descent/, Son Erişim Tarihi: 19.01.2016.

72. Zeiler, M. D. (2012). ADADELTA: An Adaptive Learning Rate Method. *Dblp computer science bibliography*. 1212.5701.

73. Giese, Andrew and Seitzer, Jennifer (2011). Using a Genetic Algorithm to Evolve. *D* Search Heuristic*. 67-72.

74. D. Surya Prabha and J. Satheesh Kumar (2016). Performance Evaluation of Image Segmentation using Objective Methods. *Indian Journal Science Technology*. 1-8.

75. Toğaçar, Mesut ve Ergen, Burhan and Cömert, Zafer. (2019). BrainMRNet: Brain Tumor Detection using Magnetic Resonance Images with a Novel Convolutional Neural Network Model. *Medical Hypotheses.* 134, 109531.

76. S. Bakas, M. Reyes, A. Jakab, S. Bauer, M. Rempfler, A. Crimi, et al. (2018). Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation. *Progression Assessment, and Overall Survival Prediction in the BRATS Challenge*. 38.

77. S. Bakas, M. Reyes, A. Jakab, S. Bauer, M. Rempfler, A. Crimi, et al. (2018). Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation. *Progression Assessment, and Overall Survival Prediction in the BRATS Challenge*. 38.

78. Siddharth S., Simone S., (2020). Activation Functions In Neural Networks . *International Journal of Engineering Applied Sciences and Technology*. 310–316.

79. Ronneberger Olaf and Fischer, Philipp and Brox, Thomas (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 234-241.

80. Zhou, Zongwei et al. (2020). UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation. *IEEE Transactions on Medical Imaging*. 39, 1856-1867.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : Doğanay,Tarıkcan
Uyruğu : T.C
e-mail

Eğitim

Yüksek lisans	Gazi Üniversitesi /Sağlık Bilişimi	Devam Ediyor
Lisans	Karabük Üniversi1tesi Tıp Mühendisliği	2018
Lise	Kırıkkale Atatürk Anadolu Lisesi	2013

İş Deneyimi

Yıl	Yer	Görev
2018 - 2022	Ekstrem Bir Bilgisayar	Bilişim Mühendisi
2022 - Halen	Akgün Teknoloji	Üretim Müdürü

Yabancı Dil

İngilizce

Tezden Üretilen Yayınlar

(Tezden üretilmiştir.) T.Doğanay ve O.Yıldız (Baskıda). Beyin Tümör Tespiti İçin Derin Öğrenme Temelli Bilgisayar Destekli Tanı Sistemi.*Düzce Üniversitesi Bilim ve Teknoloji Dergisi*

Hobiler

Yapay zeka, metaverse, NFT,blockchain



GAZİLİ OLMAK AYRICALIKTIR...