



**T.C.  
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ**

**YAPAY SINIR AĞLARINDA BEYİN  
TÜMÖRLERİNİN GÖRÜNTÜ İŞLEME İLE  
SEGMENTASYONU VE BİR UYGULAMA**

**Emin GÖKÇE**

**BURDUR, 2022**



T.C.  
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARINDA BEYİN  
TÜMÖRLERİNİN GÖRÜNTÜ İŞLEME İLE  
SEGMENTASYONU VE BİR UYGULAMA

Emin GÖKÇE

Danışman: Dr. Öğr. Üyesi Mehmet Fatih DEMİRAL

BURDUR, 2022

## ETİK KURALLARA UYGUNLUK BEYANI

Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum **“Yapay Sinir Ağlarında Beyin Tümörlerinin Görüntü İşleme İle Segmentasyonu ve Bir Uygulama”** başlıklı bu tezin;

- Kendi çalışmam olduğunu,
- Sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi,
- Bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi,
- Kullandığım verilerde değişiklik yapmadığımı,
- Tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını,
- Bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı,
- Bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı,

bildirir, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

26 / 07 / 2022

(İmza)

Emin GÖKÇE

## **TEŐEKKÜR**

Bu tez alıřmasında beni ynlendiren, karřılařtıđım zorlukları bilgi ve tecrbesi ile ařmamda yardımcı olan deđerli Danıřman Hocam Dr. đr. yesi Mehmet Fatih DEMİRAL'a sonsuz teőekkrlerimi sunarım. alıřmalarımnda hibir yardımı esirgemeyen deđerli hocalarım Prof. Dr. Ali Hakan IŐIK ve Dr. đr. yesi Mehmet BİLEN'e teőekkr ederim.

0786-YL-21 No`lu Proje ile tezimi maddi olarak destekleyen Mehmet Akif Ersoy niversitesi Bilimsel Arařtırma Projeleri Koordinatrlđ'ne teőekkr ederim.

alıřma ve eđitim hayatımın her ařamasında desteklerini esirgemeyen eřime ve aileme sonsuz sevgi ve saygılarımı sunarım.

**Temmuz, 2022**

**Emin GKE**

# İÇİNDEKİLER

	Sayfa
TEŞEKKÜR .....	i
İÇİNDEKİLER.....	ii
ŞEKİL DİZİNİ.....	iv
ÇİZELGE DİZİNİ .....	vi
SİMGELER VE KISALTMALAR DİZİNİ .....	vii
ÖZET.....	viii
SUMMARY .....	ix
1. GİRİŞ.....	1
2. GENEL BİLGİLER .....	3
2.1. Görüntü.....	3
2.2. Görüntü İşleme Teknikleri .....	4
2.2.1. Görüntü Grileştirme.....	4
2.2.2. Nokta (Piksel) İşleme Teknikleri.....	4
2.2.3. Negatif Alma .....	5
2.2.4. Görüntü Histogramı .....	6
2.2.5. Histogram Eşitleme .....	7
2.2.6. Görüntünün Parlaklığını Ayarlama .....	8
2.2.7. Karşıtlık (Kontrast) Ayarlama .....	9
2.2.8. Görüntü Eşikleme Yöntemleri.....	10
2.2.9. Kenar Belirleme Yöntemleri .....	10
2.2.10. Morfolojik Görüntü İşleme Teknikleri.....	10
2.3. Yapay Sinir Ağları.....	11
2.3.1. İnsan Beyni ve Biyolojik Nöronlar.....	12
2.3.2. Yapay Sinir Hücreleri.....	13
2.3.3. Yapay Sinir Ağı Katman Yapıları .....	14
2.3.4. Geri Yayılım Algoritması.....	15
2.3.5. Geri Beslemeli Yapay Sinir Ağları.....	15
2.3.6. Öğrenme Teknikleri.....	16
2.3.7. YSA Performansı ve Değerlendirme Ölçütleri.....	17
2.3.8. YSA Avantaj ve Dezavantajları .....	17
2.4. Evrişimli Sinir Ağları .....	18
2.4.1. Evrişim İşlemi .....	18
2.4.2. Aktivasyon.....	19
2.4.3. Havuzlama İşlemi .....	19
2.4.4. Tam Bağlantı İşlemi .....	20
2.5. Literatürde Yapılan Çalışmalar .....	20
3. MATERYAL VE YÖNTEM.....	22
3.1. Veri Kümesi .....	22
3.2. Yöntem .....	24
3.2.1. Ön İşleme Adımı .....	24
3.2.2. U-Net Modeli.....	24
3.2.3. Eğitim Adımı .....	25
3.2.4. Değerlendirme Ölçütleri .....	26
3.3. Geliştirilen Uygulama Arayüzü.....	27

4. ARAŞTIRMA BULGULARI.....	30
5. SONUÇ.....	35
KAYNAKLAR.....	36



## ŞEKİL DİZİNİ

	<b>Sayfa</b>
Şekil 1.1. Tümör çeşitleri .....	1
Şekil 2.1. Görüntüler üzerinde pikselasyon .....	3
Şekil 2.2. Nokta işleme .....	5
Şekil 2.3. RGB görüntü ve negatif uygulanmış hali .....	5
Şekil 2.4. Görüntü ve görüntünün histogramı .....	6
Şekil 2.5. Görüntü ve görüntü histogramındaki karanlık ve parlaklık imgeleri.....	7
Şekil 2.6. Sabit sayıya göre parlaklık ayarı.....	7
Şekil 2.7. (a) Orijinal görüntü, (b) Orijinal görüntü histogramı, (c) Histogram eşitleme uygulanmış görüntü, (d) Histogram eşitleme uygulanmış görüntünün histogramı. ....	8
Şekil 2.8. Sabit sayıya göre parlaklık ayarı.....	9
Şekil 2.9. Sabit sayıya göre kontrast ayarı.....	10
Şekil 2.10. Biyolojik sinir hücresi içyapısı .....	12
Şekil 2.11. Doğrusal olmayan nöron modeli.....	13
Şekil 2.12. Tek katmalı bir YSA modeli.....	14
Şekil 2.13. Çok katmalı bir YSA modeli .....	15
Şekil 2.14. Veri akışı ve hata yayılımı .....	15
Şekil 2.15. Geri beslemeli YSA modeli .....	16
Şekil 2.16. Standart bir ESA mimarisi .....	18
Şekil 2.17. Evrişim işlemi .....	19
Şekil 2.18. Havuzlama işlemi.....	20
Şekil 3.1. Flair, T1, T1ce, T2 kontrastlı beyin MRI görüntüleri ve uzmanlar tarafından MRI görüntüleri baz alınarak yapılan tümör segmentasyonu (mavi nekroz, yeşil ödem ve sarı genişleyen tümör).....	23
Şekil 3.2. U-Net modeli.....	25
Şekil 3.3. Uygulama arayüzü .....	27
Şekil 3.4. Hastaya ait MR görüntüsü ve etiketlenmiş tümör bölgeleri.....	28
Şekil 3.5. Uygulama tarafından odaklanılan tümör bölgesi ve tespit edilen tüm tümör bölgesi .....	28

<b>Şekil 3.6.</b> Uygulama tarafından tespit edilen genişleyen tümör ve nekroz bölgesi .....	29
<b>Şekil 4.1.</b> Değerlendirme indekslerinin WT üzerindeki skorları .....	30
<b>Şekil 4.2.</b> Değerlendirme indekslerinin CT üzerindeki skorları.....	31
<b>Şekil 4.3.</b> Değerlendirme indekslerinin ET üzerindeki skorları.....	31
<b>Şekil 4.4.</b> (a) Hastalara ait Flair görüntüleri, (b) Uzmanlar tarafından etiketlenen WT tümör bölgeleri, (c) Uygulanan model tarafından tahmin edilen WT tümör bölgeleri. ....	32
<b>Şekil 4.5.</b> (a) Hastaya ait T1ce görüntü kesiti, (b) Uzmanlar tarafından etiketlenen ET tümör bölgesi, (c) Uygulanan model tarafından tahmin edilen ET tümör bölgesi .....	32
<b>Şekil 4.6.</b> (a) Hastaya ait T1ce görüntü kesiti, (b) Uzmanlar tarafından etiketlenen CT tümör bölgesi, (c) Uygulanan model tarafından tahmin edilen CT tümör bölgesi .....	33

## ÇİZELGE DİZİNİ

	<b>Sayfa</b>
<b>Tablo 3.1.</b> Eğitim hiper parametreleri.....	25
<b>Tablo 4.1.</b> BraTs veri seti üzerinde benzerlik skorlarının karşılaştırılması .....	33



## SİMGELER VE KISALTMALAR DİZİNİ

<b>MR</b>	: Manyetik Rezonans
<b>GPU</b>	: Grafik İşlemci Ünitesi
<b>TPU</b>	: Tensör İşlemci Ünitesi
<b>YSA</b>	: Yapay Sinir Ağı
<b>ESA</b>	: Evrişimli Sinir Ağı
<b>CT</b>	: Tümör Çekirdeği
<b>ET</b>	: Genişleyen Tümör
<b>WT</b>	: Tüm Tümör

# ÖZET

Yüksek Lisans Tezi

## Yapay Sinir Ağlarında Beyin Tümörlerinin Görüntü İşleme İle Segmentasyonu ve Bir Uygulama

Emin GÖKÇE

Burdur Mehmet Akif Ersoy Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Mehmet Fatih DEMİRAL

Temmuz, 2022

Beyin tümörleri kafatası içinde anormal hücre ve kitle büyümesinin genel adıdır. Beyin tümörü tanısı konulabilmesi için en yaygın tetkik beyin dokusu ve dokudaki yabancı kitleleri gösteren MR (manyetik rezonans) görüntülemesinin yapılmasıdır. Tanı konduktan sonra hızlıca tedavi süreci planlamalıdır. MR görüntüleri çekildikten sonra uzman radyologlar tarafından görüntülerin incelenerek raporlanması zaman alabilmektedir. Son yıllarda hızla gelişen derin öğrenme teknolojileri ile tıp alanında bulunan yenilikler sayesinde hastalıkların erken ve doğru teşhis edilmesi için çeşitli çalışmalar yapılmaktadır. İnsan kaynaklı hataların en aza indirilmesi bu çalışmalar içerisinde önemli bir yere sahiptir. Bu çalışmada MR görüntülerinin işaretlenerek uzmanlara yardımcı olması için yapay zekâ tekniklerinden yararlanılarak yeni bir evrişimli sinir ağı modeli eğitilmiştir. Eğitim aşamasında U-Net modelinden yararlanılarak, BRST veri kümesinin %80'i kullanılmıştır. Veri kümesi içerisindeki örneklerin %20'si modelin performansının değerlendirilmesi için kullanılmıştır. Eğitim ve test işlemleri sonucunda elde edilen bulgular incelendiğinde eğitilen modelin tüm tümör, tümör çekirdeği ve genişleyen tümör bölgelerini sırayla 0.908, 0.807 ve 0.877 Benzerlik oranı (BO, Dice Coefficient Score) ile başarılı bir şekilde işaretleme yapabilen bir model eğitildiği görülmektedir.

**Anahtar Kelimeler:** u-net, mr, beyin tümörü, segmentasyon, evrişimli sinir ağı

Hazırlanan bu Yüksek Lisans Tezi Mehmet Akif Ersoy Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından 0786-YL-21 proje numarası ile desteklenmiştir.

# **SUMMARY**

**Master's Thesis**

**Segmentation of Brain Tumors with Image Processing in  
Artificial Neural Networks and an Application**

**Emin GÖKÇE**

**Burdur Mehmet Akif Ersoy University  
Graduate School of Natural and Applied Sciences  
Department of Computer Engineering**

**Supervisor: Assist. Prof. Dr. M.Fatih DEMİRAL**

**July, 2022**


Brain tumors are the general name for abnormal cell and mass growth in the skull. In order to diagnose a brain tumor, the most common examination is an MR (magnetic resonance) image that shows foreign masses in the brain tissue and tissue. After the diagnosis is made, one should quickly plan a course of treatment. After the MR images are taken, it may take time for the images to be examined and reported by expert radiologists. In recent years, thanks to the rapidly developing deep learning technologies and innovations in the field of medicine, various studies are being conducted to diagnose diseases early and accurately. Minimizing human-caused errors has an important place in these studies. In this study, a new convolutional neural network model has been trained by using artificial intelligence techniques to help experts by marking MR images. At the training stage, 80% of the BRAST dataset was used by using the U-Net model. 20% of the samples in the dataset were used to evaluate the performance of the model. When the findings obtained as a result of the training and testing procedures are examined, it is seen that the trained model has been trained as a model that can successfully mark the entire tumor, tumor nucleus and expanding tumor sites with a similarity ratio of 0.908, 0.807 and 0.877 (BO, Dice Coefficient Score), respectively.

**Keywords:** u-net; mr, brain tumor, segmentation, convolutional neural network

The present M.Sc. Thesis was supported by Coordinatorship of Scientific Research Projects of Mehmet Akif Ersoy University Under the Project number of 0786-YL-21

# 1. GİRİŞ

Hücrelerin bölünerek çoğalması sırasında meydana gelen anormal hücrelerin kontrolsüz çoğalarak yumru ve kitle haline gelmesine tümör denir. Tümörler büyüyerek beyin ve kafatası üzerine baskı yapar ve hastalarda değişik semptomlar olarak ortaya çıkar. Yapısal olarak tümörler iki grupta incelenir.



**Şekil 1.1.** Tümör çeşitleri

Şekil 1.1’de görüldüğü gibi iyi huylu veya kötü huylu olmak üzere iki türlü tümör vardır. Normal hücrelerin aksine kötü huylu tümörler, agresif olup kontrolsüz olarak büyürler ve komşu organlara baskı yaparak bu organlarda da yayılabilir ve sıçrayabilirler. İyi huylu olan beyin tümörlerinde ise diğer organlara yayılım nadiren gözükür.

Beyin tümörleri beynimizde başlayabilir veya vücudumuzun diğer yerlerinden başlayıp beynimize yayılabilir. Beynimizde başlayan tümörlere birincil beyin tümörleri denir. Vücudumuzun diğer yerlerinde başlayıp beynimize yayılan tümörlere ise metastatik veya ikincil beyin tümörleri denir.

Küresel Kanser Gözlemevinin 2020 yılı verilerine göre her 100.000 kişiden %7,2’sinin beyin kanserine yakalandığı açıklanmıştır. Beyin ve merkezi sinir sistemi kanserleri yakalanma oranına bakıldığında kanser türleri arasında her ne kadar ya 14. sırada olsa da hastalığa yakalananların yalnız ölüm bildiriminde akciğer kanserinden sonra oransal olarak 2. sırada yer almaktadır.

Manyetik rezonans görüntüleme (MRG, MRI) beyin tümörünün tespitinde en yaygın kullanılan görüntüleme yöntemlerinin başında gelmektedir (Arakeri ve Reddy, 2015). Beyin tümörünün sınırlarının tespitinin yapılarak kesin teşhisi, MR görüntülerinin analiz edilmesi

yapılmaktadır. Uzmanlar tarafından tümör teşhisi yapılarak tümörlü bölge belirlendikten sonra hekim tarafından, kemoterapi, ameliyat ve radyoterapi gibi hastaya uygun tedavi planlaması yapılır (Huo, Brown, ve Okada, 2012). Tedavinin başarısı tümörün konumunun, sınırlarının, tipinin ve kötü huylu olup olmadığı kadar hekim tarafından erken ve doğru olarak belirlenmesine de bağlı olarak değişebilmektedir (Dandil, 2015) .

Teknolojik gelişmelere paralel olarak, son zamanlarda bilgisayarlı görü (computer vision) alanında, uydu görüntüleri üzerindeki yerleşim yerlerine bakarak nüfus yoğunluğunun tahminlenmesi, hava durumu tahminlenmesi ve hava gözlemi gibi erken tespit uygulamalarında, medikal görüntüleme ile hastalık teşhisi uygulamalarında ve astronomi uygulamaları gibi bir çok alanda dijital görüntülerden anlamlı sonuçlar çıkarma uygulamaları geliştirilerek yer almaktadır (Perihanoğlu, 2015).

Görüntü işleme kısaca bir sahnenin matematiksel formülünü çıkarma durumudur. Görüntü işleme ile ilgili çalışmalar yapmak için birçok programlama diline kütüphaneler eklenmiş ve bununla ilgili daha hızlı işlenmesi amacıyla GPU ve TPU gibi veri işleme gücü yüksek sistemler geliştirilmiştir.

Bu çalışmada, görüntü işleme teknikleri ile MR görüntülerindeki tümörlü bölgelerin optimizasyonu yapılmış evrişimli sinir ağı modeli U-Net ile MR görüntüleri ile uzmanlar tarafından etiketlenen tümör bölgeleri eğitime tabi tutulmasıyla öznitelik bilgileri çıkartılarak daha hızlı ve optimal sonuçlara ulaşmaya çalışılmıştır.


Bu tez çalışması 5 ana başlık altında sunulmuştur. Giriş başlığında çalışmanın amacı, neden bu çalışmanın yapılmasına ihtiyaç duyulduğu ve yapılmak istenen tümör tespitinin neden önemli olduğu açıklanmıştır. Devamında yapılan bu çalışmada kullanılan görüntü ve yapay sinir ağları hakkında genel bilgiler ile bilinmesi gerekenler aktarılmış ve literatürde yapılan çalışmalar bölümünde bu tezde yapılan çalışmaya benzer çalışmalar incelenerek açıklanmıştır. Materyal ve yöntem bölümünde üzerinde çalışılan veri kümesinden bahsedilmiş ayrıca geliştirilen yöntem ve değerlendirme kriterleri detaylıca açıklanmıştır. Araştırma bulguları bölümünde çalışmadaki bulgular ile literatürdeki bulgular karşılaştırmalı bir şekilde verilerek değerlendirilmiştir. Son olarak çalışmada elde edilen sonuçlar ve çalışmanın geleceği hakkında öngörü ve öneriler verilerek bitirilmiştir.

## 2. GENEL BİLGİLER

Bu başlıkta görüntü, dijital bir görüntüyü işleme teknikleri, yapay sinir ağları ve evrişimli sinir ağları hakkında bilinmesi gerekli olan bilgiler sırası ile verilmiştir.

### 2.1. Görüntü

Dijital bir görüntü resim görüntü elemanı veya piksel adı verilen belirli sayıda bileşenden oluşmaktadır ve her bir bileşen belli bir görüntünün değerini içermektedir. Bu bileşenlere resim görüntü elemanı veya piksel adı verilir. Piksel bir görüntünün bileşenlerini göstermede kullanılan bir terimdir. Örneğin; full hd bir görüntü 1080p olarak adlandırılır ve 1920 x 1080 pikselden oluşur (Gonzalez ve Woods, 2008). Bir görüntüdeki dikey ve yatay piksel sayılarının birbiriyle çarpımı çözünürlük olarak ifade edilir. Çözünürlük düştükçe veya görüntü yakınlştırıldıkça görüntüdeki piksellerin çıplak gözle görünmesi artar. Bu olay pikselasyon olarak adlandırılır. Pikselasyon Şekil 2.1’de gösterilmiştir.



Şekil 2.1. Görüntüler üzerinde pikselasyon

Görüntü 4 farklı grupta incelenmektedir.

- **İkili Görüntü** : Her bir pikselin 1 bit ile kodlanması ile (0-Siyah veya 1-Beyaz) oluşan toplamda 2 farklı renk değeri alması sonucunda bir araya gelen piksellerce ortaya çıkan görüntüler ikili (binary) görüntü olarak isimlendirilir.

- **Gri Seviyeli Görüntü :** Her bir piksel 8 bit ile kodlanması ile (0-Siyah, 255 Beyaz ve bu değerler arasındaki kodlar ise gri tonlara karşılık gelen parlaklık seviyesiyle) oluşan toplamda 256 farklı renk değeri alması sonucunda bir araya gelen piksellerce ortaya çıkan görüntüler gri seviyeli görüntü olarak isimlendirilir.
- **Renkli Görüntü :** R(Kırmızı), G(Yeşil), B(Mavi) olmak üzere üç renk bandının her piksel için ayrı ayrı 8 bit ile kodlanması ile oluşan toplamda (256x256x256) 16.777.216 farklı renk değeri alması sonucu bir araya gelen piksellerce ortaya çıkan görüntüler renkli görüntü olarak isimlendirilir.
- **Yapay Renkli Görüntü:** Renkli görüntünün 3 bandının 2 ikisine ilişkin değerlerin sıfır alınmasıyla (sadece kırmızı, sadece mavi, sadece yeşil olarak yapay renklendirilmiş görüntülere) oluşan görüntüler yapay renkli görüntü olarak isimlendirilir.

## 2.2. Görüntü İşleme Teknikleri

Dijital bir görüntüyü yapay zekaya veya matematiksel formlere dayalı sistemlerde kullanmak üzere anlamlı hale getirmek için problemin çözümüne uygun yöntemler ile piksel piksel veya görüntünün tümü üzerinde uygulanan farklı algoritmalar görüntü işleme teknikleri olarak adlandırılır.


### 2.2.1. Görüntü Grileştirme

Normalde görüntü insan gözünün gördüğü ve sürekli akıp giden zamanın bir kesiti olarak adlandırılabilir. İnsan gözünün gördüğü bu kesit kırmızı, yeşil ile mavi renk tonlarının karışımı olup; renkli görüntü olarak tanımlanır. Dijital renkli görüntülerde her bir renk tonu için 0 ile 255 arasındaki 8 bitlik bir veri ile ifade edilir. 3 farklı renk tonu için ise her bir piksel 24 bitlik veri ile ifade edilir.

Gri seviyeli bir görüntüde her bir piksel 0 değerinin siyah rengi, 255 değerinin beyaz rengi işaret ettiği 8 bitlik veri ile ifade edilir. Görüntü işlemede renkli görüntüyü grileştirmedeki amaç boyutu indirme, 3 kanallı görüntüyü 1 kanallı olarak ifade etme ve yapay zekâ modelleri için daha anlamlı bir hal kazandırmaktır.

### 2.2.2. Nokta (Piksel) İşleme Teknikleri

Orijinal görüntüdeki bir piksel üzerinde yapılan işlemin çıktısı görüntüsünde sadece karşılığı olan pikselde değişiklik yapılması durumuna nokta işleme adı verilir (Şekil 2.2).



**Şekil 2.2.** Nokta işleme

Nokta işleme teknikleri sadece bir pikselin değerinde değişiklikler yaparlar. Diğer piksel değerleri değiştirilen pikselden etkilenerek herhangi bir değişikliğe uğramazlar. Değiştirilen her bir pikselin yeni değeri tekrar yerine konulur. Sonucunda ise piksel piksel işlem yapılmış yeni bir görüntü meydana gelir. Nokta işlemede tek tek pikseller üzerinde işlem yapıldığı için bütün görüntüyü değiştirir. Ancak bir piksel sadece bir defa kullanıldığı ve başka pikselleri etkilemediği için yeni piksel değeri tekrar bir işleme tabi tutulup yerine yazarak orijinal görüntüye ulaşmak mümkündür (Luhmann vd., 2011).

### 2.2.3. Negatif Alma

Görüntü işlemenin en temel işlemi olan bir görüntünün negatif görüntüsünü alma bize görüntü hakkında daha fazla bilgi verecek veya daha anlaşılır kılacaksa kullanılır.

Renkli bir görüntünün negatifi her bir RGB kanalındaki her bir piksel için değil işlemi uygulanarak bulunur. Her bir piksel 8 bit olduğu için  $2^8$  (11111111)'den çıkarılarak görüntünün negatiline ulaşılır. Renkli bir görüntü ve negatifi alınmış hali Şekil 2.3'deki gibidir.

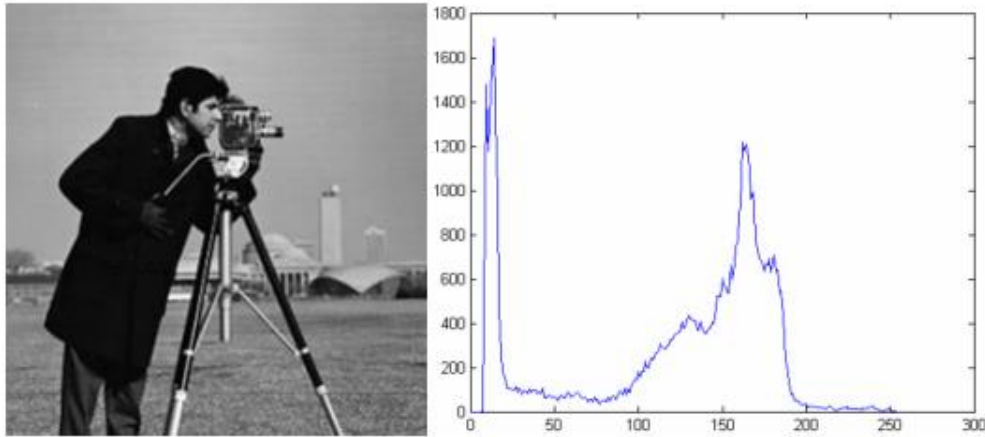


**Şekil 2.3.** RGB görüntü ve negatif uygulanmış hali

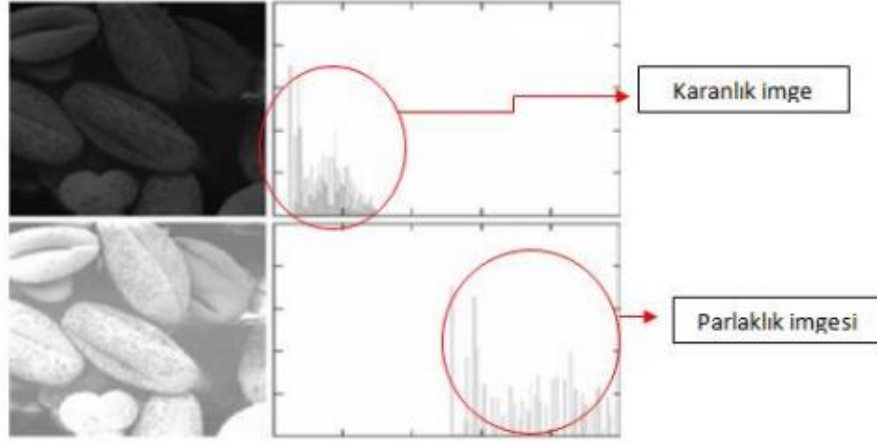
#### 2.2.4. Görüntü Histogramı

Dijital bir görüntünün histogramı, 0 ile 255 arasındaki gri ton seviyesinin görüntüde kaç adet bulunduğunu gösterir. Buna görüntünün frekansı da denilir. Görüntü histogramında, işleme tabi tutulan görüntüdeki piksellerin sayısının ne olduğunu ve yoğunlaştıkları gri ton seviyelerini gösterir. Görüntü ile ilgili çeşitli bilgilerin çıkartılması gri ton seviyesinin yoğunlaştığı değerlere bakılarak sağlanır. Görüntüdeki gri ton seviyesi sifıra yakınlığına göre karanlık bölge bire yakınlığına göre aydınlık bölge değerleri hakkında çeşitli bilgiler elde edilebilir. Eşik değerleri bu bilgiler değerlendirilerek tahmin edilebilir (Qidwai ve Chen, 2009).

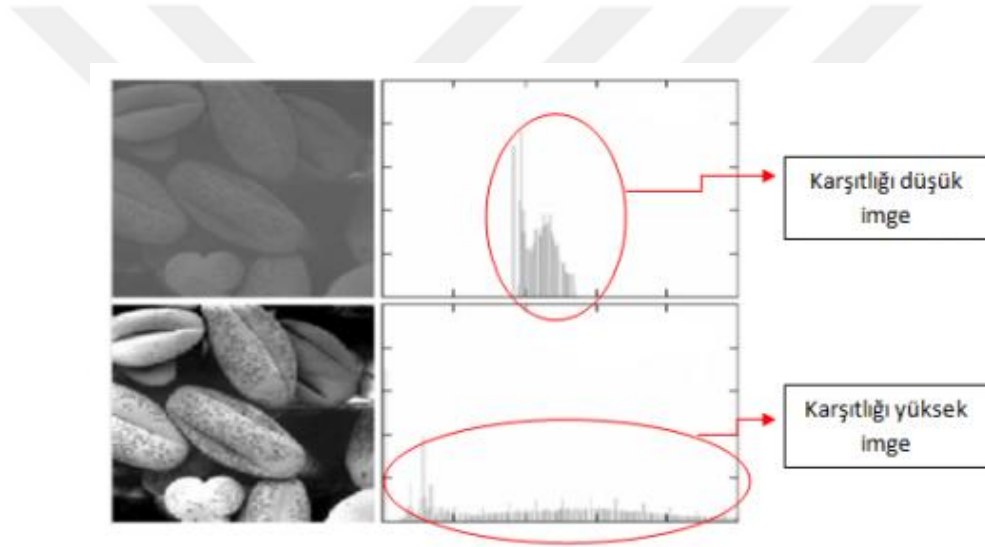
Histogramda piksellerin gri tonlarının seviye değerleri x ekseninde gösterilirken y ekseninde gri tona sahip piksellerin sayısı verilir (Şekil 2.4). Bu sayede grafikten görüntünün gri ton dağılımında bir tona yoğunlaşmasından parlaklık ve karanlık değeri ile karşıtlık değerleri ilgili bilgiler edinilir (Şekil 2.5 ve Şekil 2.6). Görüntünün histogramından bilhassa eşikleme yöntemlerinde faydalanılır.



Şekil 2.4. Görüntü ve görüntünün histogramı (Bellanger, 2000).



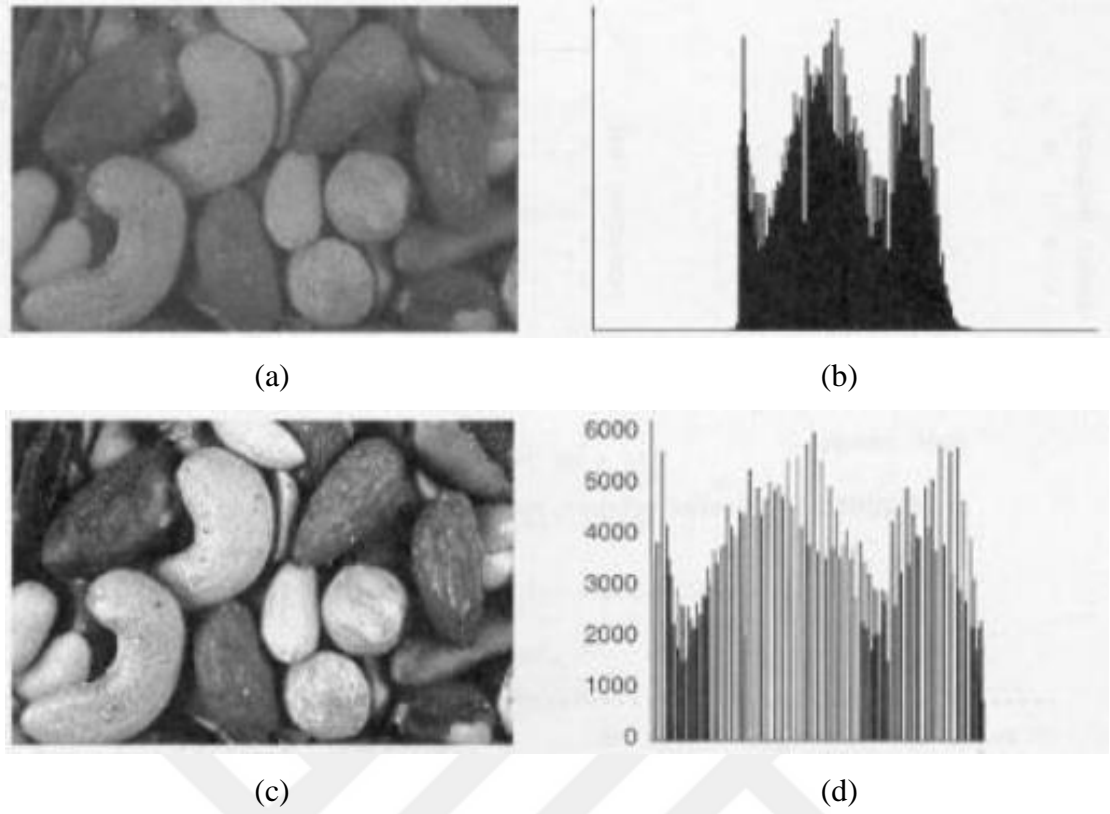
Şekil 2.5. Görüntü ve görüntü histogramındaki karanlık ve parlaklık imgeleri (Gonzalez ve Woods, 2008).



Şekil 2.6. Sabit sayıya göre parlaklık ayarı (Gonzalez ve Woods, 2008).

### 2.2.5. Histogram Eşitleme

Görüntü histogramı 0'a yaklaştıkça karanlık, 255'e yaklaştıkça aydınlık bir görüntü elde edilir. Görüntü histogramındaki renk değerlerinin sayısı 0-255 arasında dar bir bölgede toplanmışsa karşıtlık düşük, dengeli bir şekilde dağılım göstermiş ise karşıtlık yüksektir. Görüntünün karşıtlığı düşük olduğu bir görüntüyü iyileştirmek için en sık kullanılan yöntemdir. Histogram eşitlemede renk değerleri 0-255 arasına orantılı yayılarak renk değerlerinin belirli bir değer aralığı içerisinde kümelenmesini gidermek için kullanılan bir yöntemdir (Şekil 2.7).



**Şekil 2.7.** (a) Orijinal görüntü, (b) Orijinal görüntü histogramı, (c) Histogram eşitleme uygulanmış görüntü, (d) Histogram eşitleme uygulanmış görüntünün histogramı (Gonzalez ve Woods, 2008).

Histogram eşitleme işlemi 4 adımda yapılır.

- 0 ile 255 arasındaki her bir sayı için piksel değeri o sayıya ait olan piksellerin toplamı bulunarak bir diziye atılır.
- Dizideki her bir değer, dizideki bir önceki değer ile toplanır.
- Dizideki her bir eleman, resimdeki piksel sayısına bölünür ve en yüksek piksel değeri ile çarpılır.
- Bu işlemlerin sonucunda elimizde 256 elemanlı bir dizi oluşacak olup; her piksele dizinin piksel değerini dizideki piksel değerinin gösterdiği elemanına atarak histogram eşitleme işlemi yapılarak görüntü elde edilecektir.

### 2.2.6. Görüntünün Parlaklığını Ayarlama

Dijital görüntülerde beyazın tam beyaz ve siyahın tam siyah olma durumu parlaklık olarak ifade edilmektedir.

Görüntülerdeki varyans da kontrastın, renk değerlerindeki ağırlık ortalaması da ortalama parlaklığın değerlerini belirler. Renkli ve gri görüntülerin parlaklığı görüntüye ait piksellerin değerleri değiştirilerek ayarlanabilir (Şekil 2.8).



Şekil 2.8. Sabit sayıya göre parlaklık ayarı (Bellanger, 2000).

### 2.2.7. Karşıtlık (Kontrast) Ayarlama

Görüntülerde arka plandaki nesnelere iki farklı nesneyi ayırt edilebilmek için kullanılır. İnsanların gri renk değerlerindeki farklılığı ayırt edebilmesi için renk değerinde otuz ton atlama olması gerekir. Bir görüntüde gri ton değeri arasında 30 tondan daha az farkın olması durumunda, insan gözü görüntü arasında farkı algılayamayabilir. Gri seviyeli görüntülerin dar bir aralığında piksellerde yoğunlaşma görülmesi durumunda görüntünün kontrastının olduğu ifade edilir (Bellanger, 2000).

Görüntü içerisindeki grilik seviyesinin farkları genliğine kontrast denilir. İnsan gözünün ile ayırt edilmesi zor olan kontrastı düşük görüntüler dönüşüm fonksiyonları ile daha kolay ayırt edilebilir. Kontrastı düşük ve ağırlıklı olarak koyu tonları olan bir görüntüyü iyileştirmek için optimal kontrast değerine getirmek veya yaklaştırmak gerekir (Şekil 2.9) (Bellanger, 2000).



Şekil 2.9. Sabit sayıya göre kontrast ayarı (Bellanger, 2000).

### 2.2.8. Görüntü Eşikleme Yöntemleri

Görüntüleri anlamlı bölümlere ayırmak ve görüntüdeki bir nesneye odaklanarak arka plandan ayırmak için kullanılan yöntem eşikleme adı verilir (Boykov ve Jolly, 2001).

Eşikleme işleminde, gri tonlamalı bir görüntünün histogramından faydalanılarak uygun bir eşik değeri tespit edilir ve nesnelerin arka plandan ayrılması amaçlanır. Medikal görüntülerin işlenmesi, nesne algılama, cevap anahtarı gibi belgelerin analizi, parmak izi ve yüz tanıma vb. birçok görüntünün analizinde ön işlem olarak tercih edilir (Abdullah, 2020).

Görüntünün histogramından faydalanılarak görüntüdeki piksellerin değerleri ile belirlenen optimal T eşik değerini karşılaştırmak en kolay yöntem olacaktır. Eğer belirlenen optimal T eşik değeri görüntüdeki pikselin değerinden küçükse nesne, aksi halde pikselin arka plana ait olduğu varsayılır (Jähne, 2002).

### 2.2.9. Kenar Belirleme Yöntemleri

Görüntü işlemede en hassas ve önemli konulardan birisi de kenar belirlemedir. Bir görüntünün fiziksel görünüşünde olan kenar, aydınlatma veya yüzey yansımaları gibi önemli bir değişimi ifade eder. Görüntülerin içeriğindeki objeler, arka plan veya diğer objelerden obje geçişleri arasında bulunan farklı gri ton değerlerine bakılarak belirlenirler. Görüntülerde gri tonundaki değerlerde bulunan ani değişikliklerin olduğu bölgeler kenar olarak adlandırılır. Kenar belirleme yöntemlerinden en yaygını, görüntünün üzerinde bir filtre maskesi ile işlem yapılmasıdır (Young vd., 1998).

### 2.2.10. Morfolojik Görüntü İşleme Teknikleri

Morfolojik görüntü işleme, geometrik yapı taşları ile görüntüleri şekillere göre işleyen teknikler kümesidir. Morfolojik işlemlerde yapılandırma elemanı uygulanan giriş

görüntüsü boyutları aynı çıkış görüntüsü verir. Yapılandırma elemanı kare, çizgi veyahut daire gibi geometrik bir yapıya sahip ikili (binary) bir görüntüdür (Kimori, 2013).

Yapılandırma elemanı ana görüntü üzerinde dolaştırılarak uygulanan morfoloji işlemine göre piksel değeri ile karşılaştırılarak sonuç görüntüsü elde edilir. Karşılaştırma işlemi görüntünün her bir pikseli yapılandırma elemanının merkez noktasına konularak gerçekleştirilir (Acar ve Bayram, 2009).

**Genişleme ve Aşınma Morfoloji Operatörleri:** Genişleme işleminde, görüntü üzerinde dolaştırılan yapılandırma elemanı merkezi ile aranılan nesne tespit edildiği anda nesnenin büyümesi ve arka planın küçülmesi için yapılandırma elemanı kadar bir genişleme gerçekleşir. Aşındırma işleminde, görüntü üzerinde inceltme yapılmasıyla nesnelere boyutsal olarak daralır. Aşındırma işlemine genişleme işleminin tersi de denilebilir. Diğer tüm morfolojik işlemler genişleme ve aşınma işlemi referans alınarak gerçekleştirilir (Atalı vd., 2016).

**Açma ve Kapama Morfoloji Operatörleri:** Aşınma işleminin ardından genişleme işleminin sırasıyla uygulanması ile oluşturulmuş bir matematiksel morfoloji operatörüdür. Açma işlemi ile nesne üzerindeki ince çizgi ve boşluklar ortadan kaldırılır. Kapama işleminde ise önce genişleme sonra aşınma işleminin sırasıyla uygulanması ile oluşturulan bir operatördür. Kapama işleminde ise birbirine yakın iki nesnenin görüntüde değişiklik yapılmadan birbirine bağlanması sağlanır.

**Diğer Morfoloji Operatörleri:** Görüntü yumuşatma, genişleme ve aşınma ile açma ve kapama temel matematiksel operatörlerin dışında iskelet, inceltme ve kalınlaştırma operatörleri gibi farklı uygulamalarda kullanılmak üzere geliştirilen morfolojik operatörler vardır.

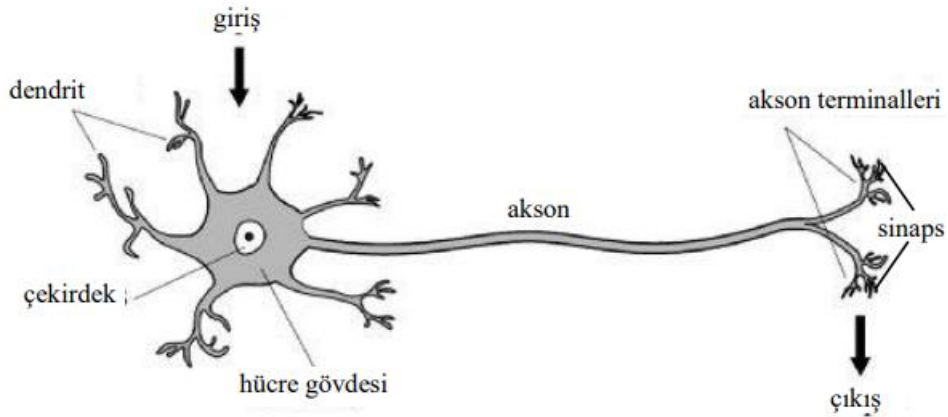
### **2.3. Yapay Sinir Ağları**

Yapay sinir ağları (YSA); insan beyninde bulunan biyolojik sinir hücrelerinin içyapısı ve çalışma prensiplerinden esinlenilerek tasarlanmış, verilen bilgiyi kullanarak eğitilip öğrenmeleri için programlanabilen karar verme yapılarıdır (Graupe, 2013). YSA modeli örnek etiketli veriler üzerinden eğitilerek hiç karşılaşmadığı etiketsiz veriler ile test edilerek bir çözüm veya sonuç üretmesi beklenir. Elde edilen sonuç çeşitli metrikler ile kıyaslanarak YSA modelinin başarımı ölçülür.

### 2.3.1. İnsan Beyni ve Biyolojik Nöronlar

İnsan beyninin yapısı ve çalışma fonksiyonları ile ilgili çok sayıda çalışma olmasına karşın insan beyninin çalışma sistemi hakkında bilgiler oldukça sınırlıdır. Buna karşın, bu alanda yapılan çalışmalarda elde edilen sınırlı bilgiler insan beyninin öğrenme mantığı örnek alınarak oluşturulan YSA modelinin ortaya çıkması için yeterli olmuştur. İnsan beyninin yapısı ile ilgili yapılan çalışmalar beyindeki farklı bölümlerin farklı işlevler gerçekleştirdiğini ortaya koymuştur (Aydemir ve Kayıkçıoğlu, 2009). Dış ortamdan reseptörler vasıtasıyla algılanan sinyaller beyinde bulunan sinir ağlarında işlenerek hangi eylemin uygulanacağını belirleyen karar sinyallerine dönüştürülür. Bu sinyaller beyin dışına aktararak komut ve eylemleri oluşturur.

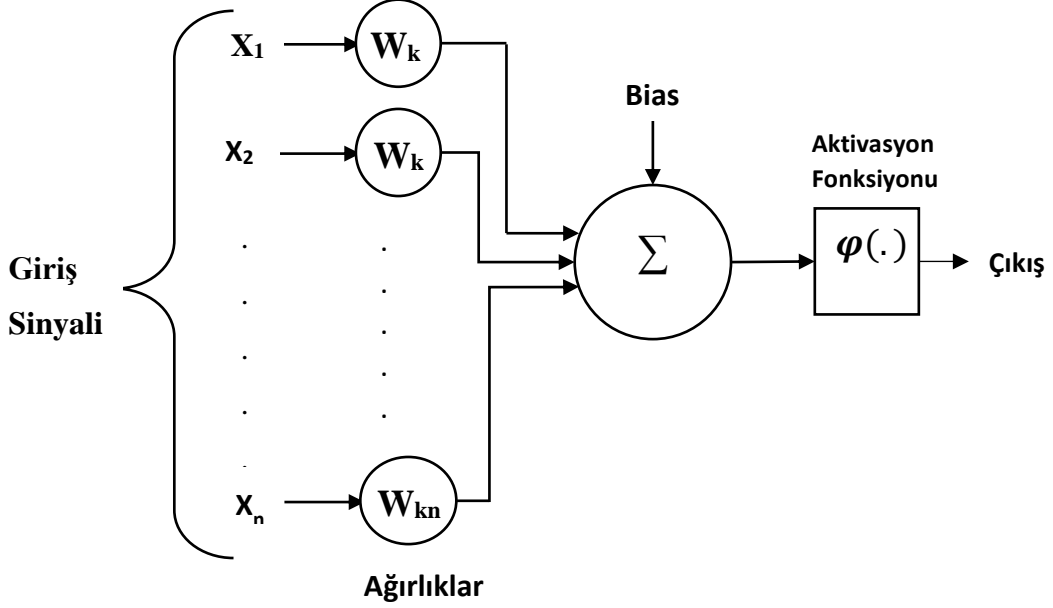
Sinir sisteminin merkezi olan insan beyninin yapı taşı nöron olarak isimlendirilen sinir hücreleridir. Farklı şekil ve büyüklüklerde olan nöronlar birbirleriyle bağlantılıdır (Ersoy ve Karal, 2012). Nöronlarda yer alan soma adı verilen hücre gövdesi içerisinde çekirdek yer alır. Çekirdek, sinir hücrelerinin gereksinim duyduğu maddeleri barındıran plazma ve kalıtsal nitelikleri ihtiva eder. Hücre gövdesinin dendrit denilen kısa uzantıları ve akson denilen uzun uzantıları bulunur. Aksonlar uçlarında bulunan sinaps adı verilen iletili bağlantı noktaları aracılığıyla diğer nöron veya nöron olmayan hücrelere hücre gövdesinin üretmiş olduğu bilgileri iletirler. Hücre gövdesinin kısa olan diğer uzantıları dendritler ise diğer nöronlardan gelen uyarıları algılayarak bu uyarıların hücre gövdesine aktarılmasına yardımcı olur (Yazıcı vd., 2007). Biyolojik sinir hücrelerinin içyapısı Şekil 2.10'da görülmektedir.



Şekil 2.10. Biyolojik sinir hücresi içyapısı

### 2.3.2. Yapay Sinir Hücreleri

Bir YSA hücresi beş ana bölümden oluşur. Bu bölümler; girdiler, birleştirme fonksiyonu, ağırlıklar, aktivasyon fonksiyonu ve çıkışlardır. Biyolojik sinir hücreleri ile karşılaştırıldığında birleştirme fonksiyonu dendritlere, ağırlıklar sinapslara, aktivasyon fonksiyonu çekirdeğe, çıktılar aksonlara karşılık gelir. Yapay sinir hücrelerine ait model Şekil 2.11’de gösterilmiştir.



Şekil 2.11. Doğrusal olmayan nöron modeli (Haykin, 1999).

**Giriş sinyalleri:** Giriş sinyalleri dışarıdan YSA'ya işlem yapılmak üzere gelen verilerdir. Girdiler diğer sinir ağı hücrelerinin çıktıları olabileceği gibi direkt dış ortamdan gelen verilerden de oluşabilir (Öztemel, 2003). Girdiler YSA hücresinde öğrenme veya test verisi olarak kullanılabilir.

**Ağırlıklar:** Giriş verilerinin çıkış değeri üzerindeki etkisini belirler. Her giriş verisi çıktı üzerinde aynı etkiye sahip değildir. Eğitim verileri ilk defa ağırlıklara sunulduğunda her giriş verisi rastgele bir ağırlık değeri ile çarpılarak sonraki işlem basamağına aktarılır. Ağırlığın ürettiği çıktı ile olması gereken çıktı değeri karşılaştırılır. Eğer ağırlığın ürettiği çıktı değeri olması gereken çıktıya göre kabul edilebilir hata oranına sahip değilse YSA başa dönerek giriş verilerinin ağırlık değerlerini değiştirir. Bu işlem uygun sonuç değerine ulaşana kadar devam eder. Ağırlıklar pozitif değerler alabileceği gibi negatif değerler de

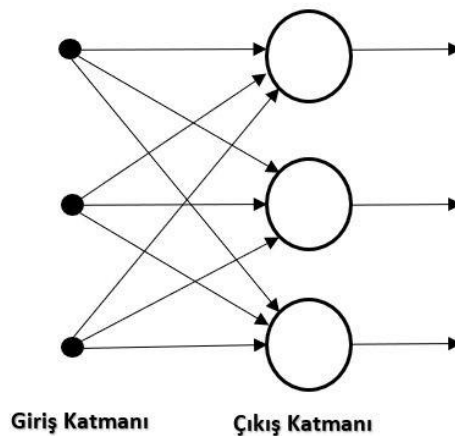
alabilir. Ağırlığın sıfır değerine sahip olması ağırlıkla ilişkili giriş verisinin sonuç üzerinde hiç etkisinin olmadığını gösterir (Öztemel, 2003).

Eşik değeri: Bias ile ifade edilen eşik değeri; biyolojik sinir hücrelerinin yüzeylerinde bulunan gerilim farkı değerlerinin bir benzerini yapay sinir hücrelerine uygulamak için kullanılır. Eşik değeri, YSA çıktı değerinin sıfır olmasını engeller. Eşik değeri birleştirme fonksiyonunda hesaplanan değere ilave edilerek çıkan sonuç aktivasyon fonksiyonuna giriş parametresi olarak verilir. Eşik değeri ile toplama, aktivasyon fonksiyonunun çıktı uzayının yatayda kaydırılmasına neden olur. Eşik değeri sabit olarak belirlenen bir giriş değeri değil, ağın eğitimi esnasında hesaplanan bir değerdir.

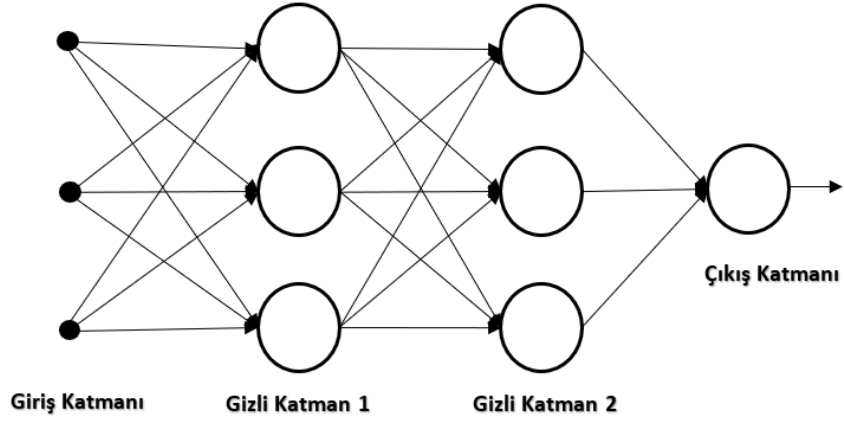
Birleştirme fonksiyonu: Birleştirme fonksiyonu; giriş değerlerinin ağırlıklar ile çarpılarak işlem gördüğü yerdir. Bu işlem genellikle girdilerin ağırlık değerleriyle çarpılarak toplanması şeklinde olur. Ancak toplama yerine farklı hesaplama yöntemleri de kullanılabilir.

### 2.3.3. Yapay Sinir Ağı Katman Yapıları

YSA yapay sinir hücrelerinin birbirine bağlanması ile oluşan, tek ve çok katmanlı olabilen yapılardır. Giriş, gizli (ara) ve çıkış olmak üzere üç katmanda incelenirler. Bilgi yapay sinir ağının girdi katmanına giriş biçimine uygun olarak iletilir. Gizli katman veya katmanlarda işlenerek çıkış katmanına çıkış biçimine uygun olarak gönderilir. Çıkış katmanında ağırlık değerleri ve aktivasyon fonksiyonu kullanılarak çıktıya dönüştürülür. Yapay sinir ağı modelleri Şekil 2.12 ve Şekil 2.13’de görülmektedir.



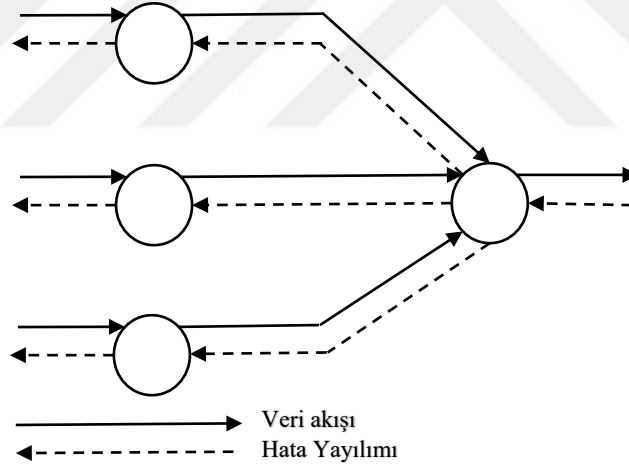
Şekil 2.12. Tek katmanlı bir YSA modeli (Haykin, 1999).



Şekil 2.13. Çok katmalı bir YSA modeli (Haykin, 1999).

#### 2.3.4. Geri Yayılım Algoritması

Geri yayılım algoritmasında üretilen çıktı değerleri olması istenen değerler ile karşılaştırılır. Aradaki fark hata sinyalleri olarak geri yayımlı olarak önceki katmanlara dağıtılır. Amaç hata değerlerini minimize etmektir (Şekil 2.14).

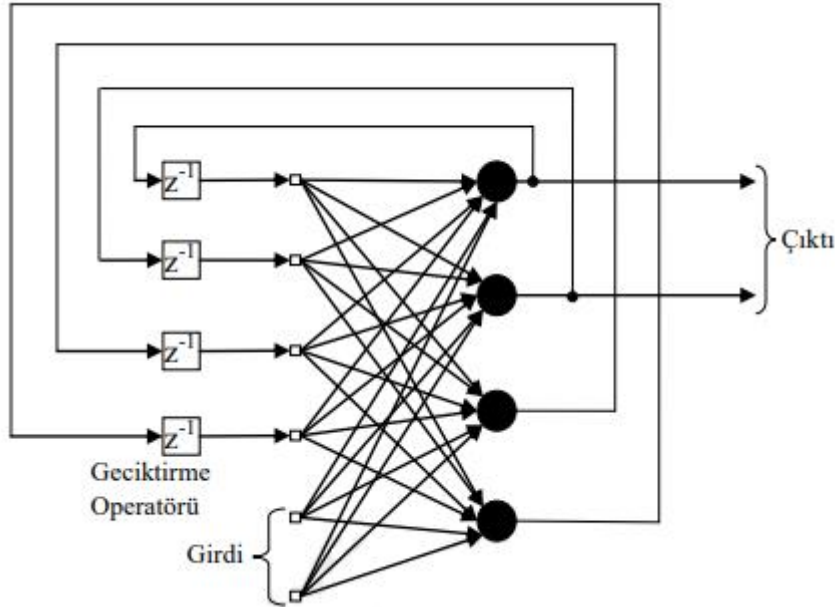


Şekil 2.14. Veri akışı ve hata yayılımı (Haykin, 1999)

#### 2.3.5. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli ağlarda aktivasyon fonksiyonu çıkışları bir sonraki katmanlardaki nöronların girişine verilebildiği gibi önceki katmanlardaki ya da aynı katmanda bulunan nöronlara da giriş olarak verilebilir (Haykin, 1999). Bu sayede YSA dinamik bir hafıza yapısına kavuşmuş olur. Böylece aynı hatalarla karşılaşıldığında hatayı belirleme ve geriye dönük olarak hata düzeltilmesi yapabilmeye kolaylığına erişilmiş olur. Bu tipte ağ yapıları

karmaşık bir yapıya sahip olmakla beraber ön tahmin gereken problemlerin çözümünde etkili sonuçlar üretirler. Şekil 2.15’de geri beslemeli YSA’ya ait bir gösterim bulunmaktadır.



Şekil 2.15. Geri beslemeli YSA modeli (Haykin, 1999)

### 2.3.6. Öğrenme Teknikleri

**Öğretmensiz Öğrenme:** Öğretmenli öğrenmede öğrenme denetim unsuru vasıtasıyla yapılırken, öğretmensiz öğrenmede öğrenme sürecini denetleyen bir öğretmen bulunmaz (Haykin, 1999). Öğrenme sürecinde ağda yalnızca girdi verileri kullanılır. Öğretmenli öğrenmede girdi verilerine karşılık olması gereken çıktı verileri bulunurken, öğretmensiz öğrenmede çıktıların denetimini sağlayan olması gereken çıktı verileri yoktur. Ağa verilen giriş verilerinden türetilen çıktılarından ortak özellikte olanlar kendi aralarında gruplandırılır. Ağ yapmış olduğu bu gruplamaya göre bağlantı ağırlıklarını yeniden düzenler. Öğretmensiz öğrenme genellikle kümelemeye dayalı çalışmalarda tercih edilir (Öztemel, 2003).

**Öğretmenli Öğrenme:** Denetimli öğrenme olarak da adlandırılır. Öğretmenli öğrenmede ağın eğitimi için girdiler verilirken, bu girdilerle beraber olması gereken çıktılar da bellidir (Elmas, 2003). Verilen girdilerin ağda ürettiği sonuçlar olması gereken çıktılar ile karşılaştırılarak hata payı bulunur. Bulunan hata değeri geri yayımlı olarak ağdaki bütün hücrelere paylaşılır ve ağırlık değerleri güncellenir. Önceden belirlenmiş olan girdi ve çıktı değerleri ağın eğitimi için bir nevi öğretmen görevi görmüş olurlar. Geri yayılım algoritması bu türde öğrenmeye örnek olarak verilebilir

Destekleyici Öğrenme: Bu öğrenme yönteminde öğrenmenin başarılı olup olmadığını belirleyen bir kriter bulunur. Kriter; ağın üretmiş olduğu çıktıyı doğru-yanlış veya başarılı-başarısız olarak değerlendirir (Şen, 2004) Başarısız çıktı üretildiğinde sonuç başarılı olana kadar eğitime devam edilir. Destekleyici öğrenme, öğretmenli öğrenmede olduğu gibi çıktıları denetleyen bir sistemdir. Ancak öğretmenli öğrenmede kullanılan girdi verilerine karşılık olması istenen çıktı verileri destekleyici öğrenmede kullanılmaz.

### **2.3.7. YSA Performansı ve Değerlendirme Ölçütleri**

YSA modellerinden elde edilen test sonuçlarını değerlendirmek için farklı hata değerlendirme yöntemleri bulunmaktadır. Bu yöntemlerde ağdan elde edilmek istenen çıktı değerleri ile ağın üretmiş olduğu çıktı değerleri arasındaki fark değerleri üzerinden hesaplamalar yapılarak ağın hata değeri belirlenir. Belirlenen hata değeri YSA modelinin üretmiş olduğu çıktıların kabul edilebilir bir doğruluk oranına sahip olduğunu belirlemek açısından önemlidir. YSA modelleri tasarlanırken hata değerlerinin minimum seviyeye ulaşım ulaşmadığı göz önünde bulundurulur. Ayrıca, YSA geri yayılım algoritmasında ağın eğitimi sırasında hesaplanan hata değerinin belirlenen ölçütlere ne kadar yaklaştığı değerlendirilerek ağırlıkların güncellenmesi sağlanır.

### **2.3.8. YSA Avantaj ve Dezavantajları**

YSA'ların sağlamış olduğu bazı önemli avantajları şu şekilde sıralamak mümkündür:

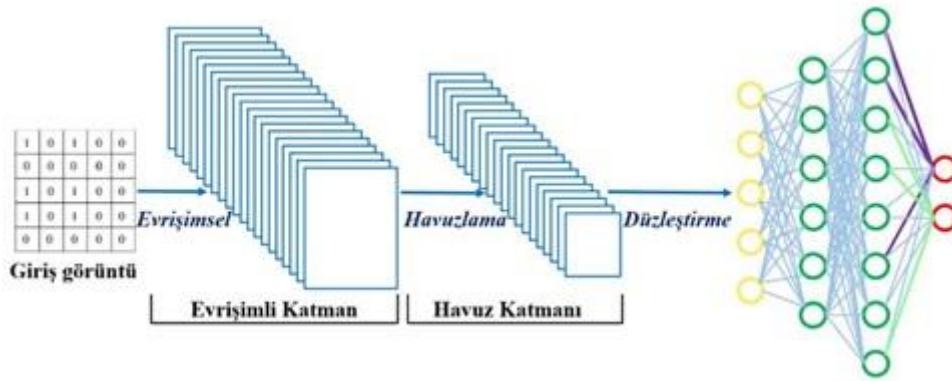
- Problemlerin çözümünü gerçekleştirirken aynı zamanda öğrendikleri için kurmuş oldukları mantıksal bağıntılar ile benzer problemlere veya aynı olay için hiç karşılaşmadıkları örneklerle ilgili de çözüm bulabilirler.
- Doğrusal olan veya doğrusal olmayan; çoklu girişli veya çoklu çıkışlı, tahmine dayalı sistemlere de çözüm sağlayabilirler (Yazıcı vd., 2007)
- Hata toleransına sahiptirler. Eksik veya hatalı bilgiler içeren örnek veri setleriyle bile çalışabilirler.
- Matematiksel sistemlerin çözemediği, klasik yöntemlerle sonuç elde edilemeyen, karmaşık sistemlerde bile iyi sonuç verebilirler.
- YSA'ların eğitimi, eğitim örneklerinin durumuna ve yapısına bağlı olarak uzun sürebilse de paralel çalışma yapısı sayesinde problemlerin çözüm süreci kısa olabilir.

YSA'ların bazı dezavantajlı yönleri şu şekilde sıralanabilir:

- Doğru sonuçlar elde etmek için kullanılan veri setindeki örnek sayısının fazla olması gerekebilir. Fazla sayıda veri toplamak yoğun uğraş ve zaman gerektirici olabilir
- Eğitim süreci belirlenen problemin içeriği, belirlenen ağ yapısı ve veri setinin kapasitesine bağlı olarak uzun zaman alabilir
- YSA'ların modellenmesinde ağ yapılarının oluşturulması, öğrenme algoritmalarının seçimi ve ağırlıkların belirlenmesi gibi konularda kesin kurallar bulunmamaktadır. Ağ tasarımı tecrübe ve deneme yanılma yöntemine dayalı olarak belirlenir (Yazıcı vd., 2007).
- Ağın eğitimi, çıktılar belirlenen sınır değerinin altına inince sonlanır. Ancak eğitim bittiği zaman en iyi sonucun elde edilmiş olduğu tam olarak bilinemez.
- Ağda işlenecek olan her türde verinin sayısal değerlere çevrilmesi gerekir (Öztemel, 2003).

## 2.4. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (Convolutional Neural Network - CNN) genel olarak yüksek boyutlu görüntü verilerinin analizinde kullanılan denetimli bir sinir ağı modellerinin genel adıdır. ESA modelleri ile görüntü ve videolardan obje tanıma, sınıflandırma ve takibi uygulamaları yanı sıra tıbbi görüntü analiz edilerek hastalık teşhisi ve hastalıklı bölge tespiti gibi birçok farklı alanda uygulamalar geliştirilmiştir. Standart bir ESA modelinde, sırasıyla girdi, evrişim, aktivasyon, havuzlama ve tam bağlantı katmanları bulunmaktadır (Şekil 2.16).




Şekil 2.16. Standart bir ESA mimarisi (Özbay ve Özbay, 2021)

### 2.4.1. Evrişim İşlemi

ESA modelinin girdilerini üzerinde çalışılan görüntü pikselleri oluşturur. Görüntüye ait piksellerin sayısal değerini matris olarak ele alınır. Evrişim katmanında görüntü

piksellerine ait matris ile bir filtre matrisi çarpımı aracılığı ile bir alt özelliğin ön plana çıkarılması sağlanır (Şekil 2.17).




Şekil 2.17. Evrişim işlemi

#### 2.4.2. Aktivasyon

Evrişim katmanında eğitilen modeldeki negatifliğe bağlı sebepler nedeniyle bazı özelliklerin modele öğretilmemesini önlemek için doğrusal olmayan fonksiyonlar ile negatif değerler sıfıra sabitlenir. Öğrenmenin negatifliğe düşmemesi için kullanılan ReLU, tanh ve sigmoid gibi fonksiyonlar aktivasyon fonksiyonu olarak anılır.

#### 2.4.3. Havuzlama İşlemi

Evrişim katmanında yapılan işleminin çıktısı havuzlama katmanına girdi olarak aktarılır. Havuzlama işleminin amacı da evrişim katmanı gibi bir sonraki katman için girdi boyutlarının küçültülmesidir. Filtre sırasıyla girdi matrisi üzerinde dolaşarak içerisinde kalan bölümündeki piksellerin ortalaması veya maksimum olarak, yeni çıktı üzerine sadece bir değer olarak iletir. Bu uygulamada belirli bir filtre bölgesindeki birbirine benzer değerlerden bir tanesi alınarak özellik indirgeme işlemi gerçekleştirilir. Bu şekilde görüntünün gereksiz ağırlıklardan kurtarılarak daha az hesaplama yükü ve ağırlık ezberinin azaltılarak daha performanslı işlenmesi sağlanır.



**Şekil 2.18.** Havuzlama işlemi

Şekil 2.18’de görüldüğü üzere filtre bölgesinin kapsadığı görüntü alandaki en büyük değer alınarak maksimum havuzlama yapılmıştır. Ortalama havuzlama uygulanıyor olsaydı filtre bölgesinin kapsadığı görüntü alanındaki değerlerinin ortalaması çıktı katmanında bir piksel ile ifade edilip; görüntü boyutu azaltılarak önemli özelliklerin görüntü üzerinde korunması sağlanır.

#### 2.4.4. Tam Bağlantı İşlemi

Evrışim ve havuzlama katmanları ile girdi görüntülerinin eğitilebilecek olgunluğa getirilmesinden sonra klasik sinir ağı modelinde olduğu gibi tam bağlantı katmanında her girişin tüm nöronlara bağlı olduğu bir yapı üzerinde çalışır.

#### 2.5. Literatürde Yapılan Çalışmalar

W Chen vd. Brats18 veri seti üzerinde 2018 yılında yaptıkları çalışmada; 3D U-Net modeli kullanarak yaptıkları çalışma ile tam tümörün, nekroz ve genişleyen tümör bölgelerine ait zar değeri (dice coef) sırasıyla 0.89353, 0.83093 ve 0.74932 benzerlik puanı almıştır (Chen vd., 2019).

Zeyu Jiang vd. Brats19 veri seti üzerinde iki basamaklı bir U-Net modeli kullanarak yaptıkları çalışmayı 405 kez eğiterek tam tümörün, nekroz ve genişleyen tümör bölgelerine ait zar değeri (dice coef) sırasıyla 0.88796, 0.83697 ve 0.83267 benzerlik puanı almıştır (Jiang vd., 2019).

W Cheng vd. Brats19 veri seti üzerinde 2019 yılında yaptıkları çalışmada; 3D U-Net modeli kullanarak yaptıkları çalışma ile tam tümörün, nekroz ve genişleyen tümör bölgelerine ait zar değeri (dice coef) sırasıyla 0.902, 0.824 ve 0.777 benzerlik puanı almıştır (Cheng vd., 2019).

Jianxin Zhang vd. Brats17 veri seti üzerindeki 57 MRI taraması ve Brats18 veri seti 66 MRI taraması ile U-Net, AResU-Net modelleri ile eğitim gerçekleştirilmiş eğitim sonuçları ResU-Net, Esemble Net, 3DU-Net, TTA ve MCC modellerinin değerlendirme sonuçları ile kıyaslanmıştır (Zhang vd., 2020).

Rehman, M.U. vd. Brats17 ve Brats18 veri setleri üzerinde 2020 yılında yaptıkları çalışmada: BU-Net modeli ile eğittikleri ağlarında zar değeri (dice coef) kullanılarak performans analizi yapılmıştır (Rehman vd., 2020).

Vaanathi Sundaresan vd. Brats20 veri seti üzerinde tam tümör, nekroz ve genişleyen tümör bölgelerini tespit etmeye çalışmışlardır. U-Net modeli ile eğittikleri ağlarında tam tümörün (WT), nekroz (TC, tümör çekirdeği) ve genişleyen (ET) tümör bölgelerine ait zar değeri (dice coef) sırasıyla 0.89, 0.84 ve 0.81 benzerlik puanı almıştır (Sundaresan vd., 2020).

Eker ve Duru Brats20 veri setleri üzerinde 2021 yılında yaptıkları çalışmada; T1ce MR görüntüsü üzerinde tümörlü bölgenin 64\*64 piksel kesitini alarak eğittikleri U-Net ağlarında 0.86 dice benzerlik puanı almıştır (Eker ve Duru, 2021).

### 3. MATERYAL VE YÖNTEM


Bu bölümde yapılan çalışmada kullanılan veri kümesi içerisinde bulunan MR görüntüleri ve uzmanlar tarafından etiketlenen tümör bölgeleri açıklanmıştır. Devamında çalışmada kullanılan yöntem, değerlendirme ölçüleri ve geliştirilen uygulama detaylı olarak aktarılmıştır.

#### 3.1. Veri Kümesi

Bu çalışmada kullanılan MR görüntüleri Perelman Sağlık Okulu tarafından derlenerek Brats19 olarak adlandırılmıştır. BraTS19 veri setindeki MR görüntüleri NITFI formatındadır. Eğitim setinde 3 ayrı ekseninde 240\*240 piksel boyutlarında 259 yüksek dereceli glioma (HGG) ve 76 düşük dereceli glioma (LGG) hastasından olmak üzere 335 adet mmMRI görüntüsü ve bu görüntülerin uzmanlar tarafından etiketlenmiş tümör görüntülerinden oluşmaktadır. (Menze vd., 2015; Bakas vd., 2017; Bakas vd., 2018)

Düşük dereceli gliomlarda (LGG) büyüme hızı nispeten yavaştır, düşük dereceli bir kötü huylu tümör çeşididir ve hastalığın iyileşme öngörüsü daha iyidir. Yüksek dereceli gliomlarda (HGG) büyüme hızlıdır, hastalığın iyileşme öngörüsü zayıf olup; teşhis konulduktan sonra sağkalım ortalama 15 aydır. (Zhang vd., 2016)

Veri seti Flair, T1, T1 kontrastlı (T1ce) ve T2 ağırlıklı olmak üzere her hastanın multimodel MRI taramalarını içerir ayrıca, tümörün uzmanlar tarafından tanımlanarak alt bölgeleri bölümlere ayrılmış görüntüsünü içerir. Ayrıca, nöroradyologlar tarafından her eğitim verisi etiketlenerek açıklanmıştır. Beyin tümörü segmentasyonunda dört etiket olup; tümör olmayan alan 0, nevrojik ve güçlenmeyen tümör çekirdeği (NCR/NET) 1, ödem 2, genişleyen tümör 4 olarak etiketlenmiştir. Sıfırdan büyük olarak etiketlenen bölgelere tam tümör (WT) denir. Şekil 3.1’de veri seti içerisindeki MR görüntüleri ve uzmanlar tarafından etiketlenen tümör bölgeleri gösterilmektedir.



**Şekil 3.1.** Flair, T1, T1ce, T2 kontrastlı beyin MRI görüntüleri ve uzmanlar tarafından MRI görüntüleri baz alınarak yapılan tümör segmentasyonu (mavi nekroz, yeşil ödem ve sarı genişleyen tümör)

Genellikle, Flair görüntülerinde su moleküllerinin sinyali ile ödem bölgesini, T1 görüntüleri sağlıklı dokuları ayırt etmek için kullanırken T2 görüntüleri görüntü üzerindeki parlak sinyal üreten ödem bölgesini tanımlamak için kullanılır. T1ce görüntülerinde tümör sınırı tümör dokusunun aktif hücre bölgesinde biriken maddenin parlak sinyali ile ayırt edilebilir.

Tümörlü beyin görüntüleri uzmanlar tarafından nekroz, genişleyen tümör ve ödem olmak üzere 3 başlık altında etiketlenerek yapılmış olup: bu etiketlerin birleşimi tümör bölgesini ifade etmektedir.

### **3.2. Yöntem**

Bu çalışmanın ön işleme adımı bölümünde veri kümesinde bulunan hastalara ait MR görüntülerinde anlam ifade etmeyen kısımlarının kırılarak atılması, görüntülerin yeniden boyutlandırılması anlatılmıştır. Devamında çalışmada kullanılan U-Net modeli verilmiştir. Eğitim adımı bölümünde eğitime tabi tutulacak görüntülerin test ve eğitim oranları ile kullanılan eğitim hiperparametreleri verilmiştir.

#### **3.2.1. Ön İşleme Adımı**

Brats19 veri kümesinin her bir MRI verisi için 240X240 boyutunda 155 görüntü mevcuttur. Flair ve T1ce ağırlıklı MRI taramalarındaki 155 görüntüden 84 ile 100 arasındaki 16 görüntü alınarak model için daha anlamlı veriler seçilerek evrişimli sinir ağının yükünü hafifletmiştir. Her bir hastadan 16 görüntü alınarak toplam 335 hasta için 5.360 görüntü elde edilmiştir.

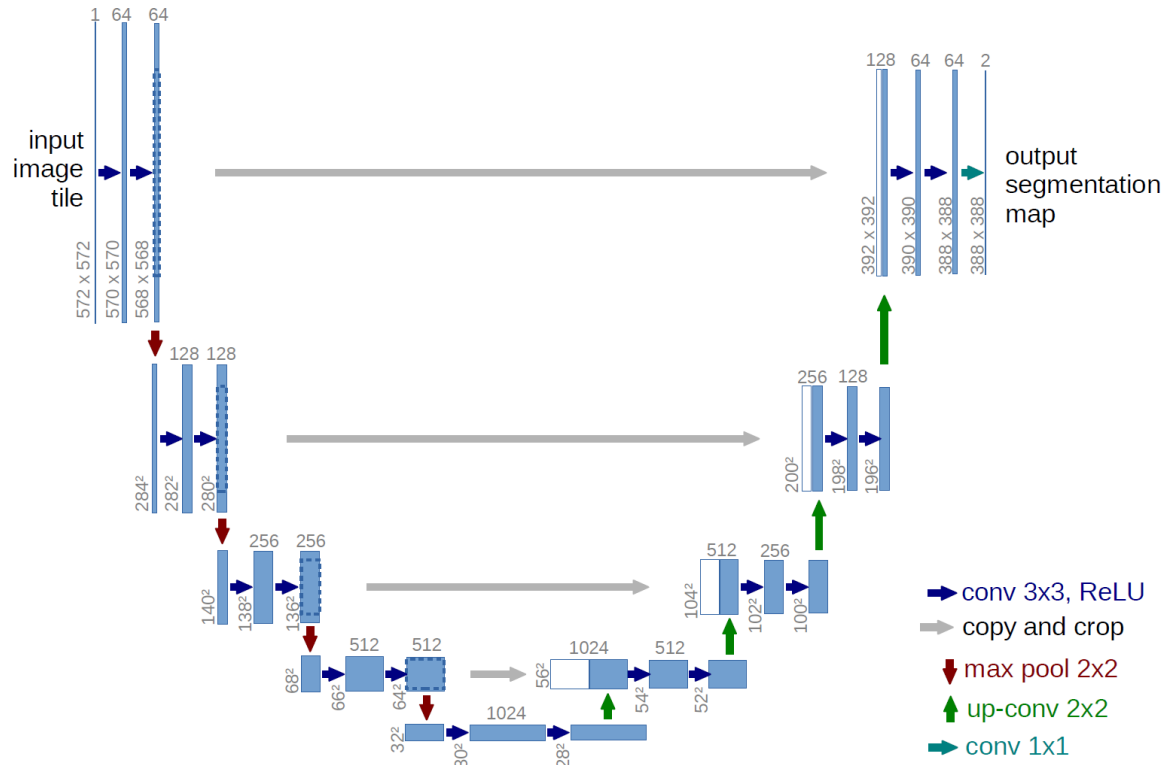
Orijinal görüntünün boyutları 256X256 yapılarak U-net modelinde daha uygun bir çözünürlüğe dönüşmüştür. Elde edilen Flair ve T1ce kontrastlı görüntüleri birleştirilerek 2 kanallı bir giriş değeri elde edilir.

#### **3.2.2. U-Net Modeli**

Evrişimli sinir ağları genellikle resim, resim sınıflandırma, video tanıma, tıbbi görüntü analizi ve benzeri görsel bilginin analiz edilmesi alanında kullanılmaktadır.

Evrişimli sinir ağlarında girdi, evrişim katmanı, aktivasyon katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıktı bulunmaktadır.

Bu çalışmada; Ronneberger vd. tarafından 2015 yılında görüntülerin hızlı ve hassas bölümlere ayrılması için tasarlanan evrişimli bir ağ mimarisi olan U-Net Modeli kullanılarak vaka tahminlemeleri gerçekleştirilmiştir. Şekil 3.2'de U-Net modeli gösterilmektedir (Ronneberger vd., 2015).



Şekil 3.2. U-Net modeli

U-Net mimarisi U şeklinde simetrik bir yapıya sahip olup; sol taraf kodlayıcı görevini sağ taraf kod çözücü görevini gerçekleştirir.

### 3.2.3. Eğitim Adımı

U-Net ağınnın eğitimi için beyin tümörlerinin enine kesit 5.360 görüntünün %80'i eğitim, %20 test için ayrılarak 100 dönem için eğittik. Minimum kayıp farkının sabitlenmesi durumunda erken durdurma 20 iterasyondan sonra devreye girerek, eğitimden otomatik olarak çıkılır. Eğitim için kullanılan hiper parametreler Tablo 3.1'de gösterilmektedir.

Tablo 3.1. Eğitim hiper parametreleri

İsim	Değer
Giriş Boyutu (Input Size)	2*256*256
Optimizer	Adam
Learning Rate	1e-4
Batch Size	3
Eğitim Sayısı (Epoch)	100
Kayıp Fonksiyonu (Loss Function)	$L_{Dice}$ loss

### 3.2.4. Değerlendirme Ölçütleri

Araştırmacılar tarafından görüntünün segmentasyonda performans sonuçlarını doğrulamak için çeşitli teknikler kullanılmaktadır. Bu çalışmada, performans sonuçlarını doğrulamak için değerlendirme indeksleri olarak Dice coefficient, Intersection Over Union, Precision (Keskinlik) ve Recall (Hassasiyet) kullanılmıştır

Dice Coefficient uzmanlar tarafından etiketlenen tümör görüntüsü ile tahmin edilen görüntü arasında piksel bazlı karşılaştırma yapar. Benzerlik artarsa sonuç 1'e azalırsa 0'a yaklaşır. Hesaplama formülü denklem 3.1'de gösterilmektedir.

$$Dice\ Coef(X, Y) = \frac{2|X \cap Y|}{|X| + |Y|} \quad (3.1)$$

Intersection Over Union iki görüntünün kesiştikleri alanın aynı iki görüntünün birleşimlerinden oluşan alana bölümü ile hesaplanır. Hesaplama formülü denklem 3.2'de gösterilmektedir.

$$IoU(X, Y) = \frac{|X \cap Y|}{|X \cup Y|} \quad (3.2)$$

Keskinlik, pozitif olarak tahmin edilen ve doğru çıkan değerlerin sayısını verir. Hesaplama formülü Denklem 3.3'de gösterilmekte olup, TP pozitif tahmin edilerek doğru çıkanların sayısını, FP pozitif tahmin edilerek yanlış çıkanların sayısını göstermektedir.

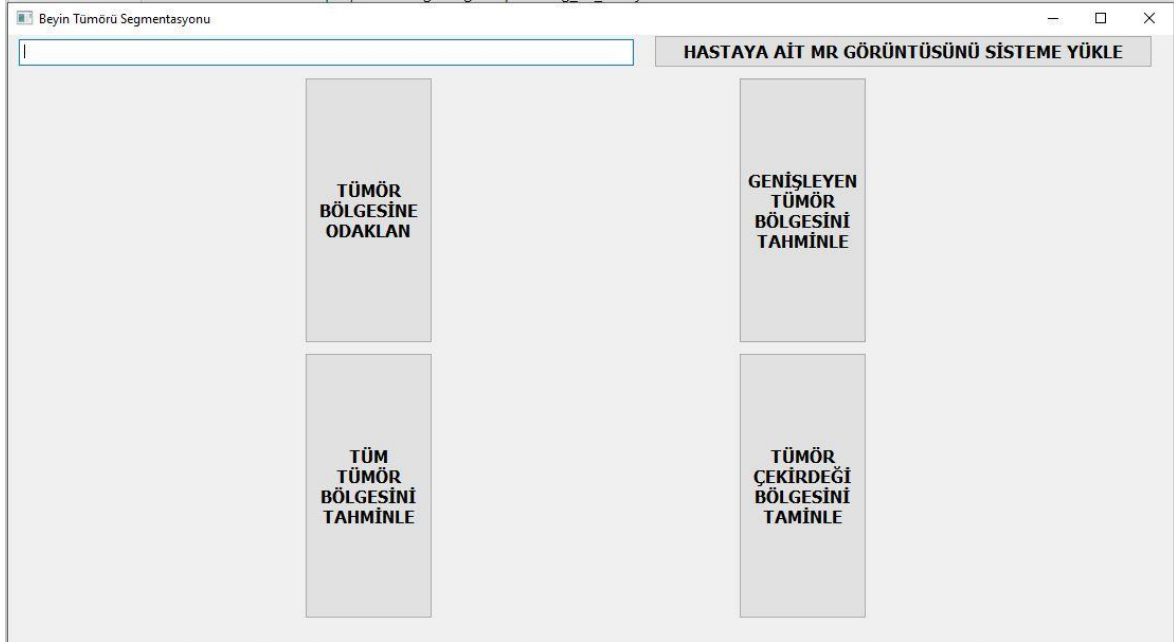
$$Precision = \frac{TP}{TP + FP} \quad (3.3)$$

Hassasiyet gerçekte doğru örneklerin başarılı bir şekilde pozitif olarak tahmin edilme oranını verir. Denklem 3.4'de gösterilmekte olup, TP pozitif tahmin edilerek doğru çıkanların sayısını, FN negatif tahmin edilerek yanlış çıkanların sayısını göstermektedir.

$$Recall = \frac{TP}{TP + FN} \quad (3.4)$$

### 3.3. Geliştirilen Uygulama Arayüzü

Beyindeki tümörlü bölgelerin alanını bize göstermek için hazırlanmış olan bu uygulama görüntü işleme kullanılarak performansı artırılan modelden elde edilen ağırlıkları kullanarak tüm tümör, tümör çekirdeği ve genişleyen tümör bölgelerini ayrı ayrı tespit etmektedir.



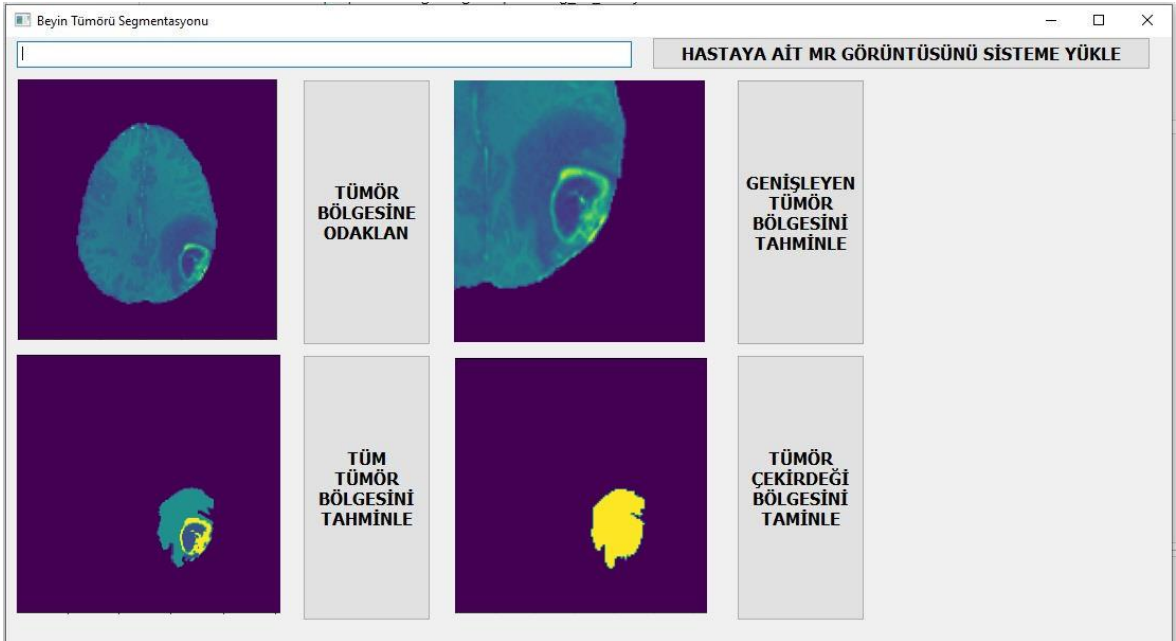
Şekil 3.3. Uygulama arayüzü

Uygulama Şekil 3.3'de görüldüğü gibi çalıştırdıktan sonra bir hastanın MR görüntüleri uygulamaya bulunduğu yol belirtilerek yüklenmektedir. Uygulamaya yüklenen görüntüler her bir tümör bölgesi için ayrı ayrı elde edilen ağırlıklar ile analiz ederek tümörlü bölgelerin tespiti gerçekleştiriliyor.



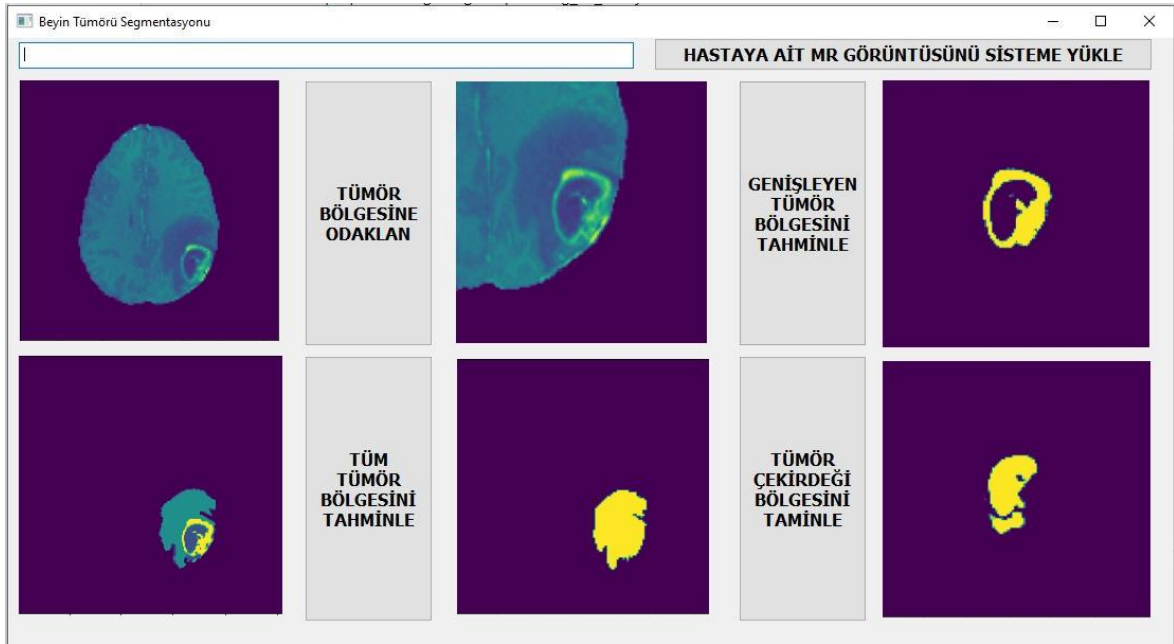
**Şekil 3.4.** Hastaya ait MR görüntüsü ve etiketlenmiş tümör bölgeleri

Şekil 3.4’te tümör bulunan bir hastaya ait MR görüntüleri seçilerek uygulama tarafından açılan MR görüntüsü ile uzman tarafından etiketlenen tümör bölgelerini gösteren uygulama çıktıları paylaşılmıştır.



**Şekil 3.5.** Uygulama tarafından odaklanılan tümör bölgesi ve tespit edilen tüm tümör bölgesi

Şekil 3.5’de seçilen MR görüntüsünde; odaklanılan tümör bölgesi ve tahminlenen tüm tümör bölgesine ait uygulama tarafından verilen çıktılar paylaşılmıştır.



Şekil 3.6. Uygulama tarafından tespit edilen genişleyen tümör ve nekroz bölgesi

Şekil 3.6’da seçilen MR görüntüsünde; odaklanılan tümör bölgesi ve tahminlenen tüm tümör bölgesinin yanı sıra genişleyen tümör bölgesi ile tümör çekirdeği bölgesinin tahminlemesine ait uygulama tarafından verilen çıktılar paylaşılmıştır.


#### 4. ARAŞTIRMA BULGULARI

Yapılan çalışmada kullanılan model Python ile kodlanmıştır. Çalışma 64 GB RAM, i5 işlemci, 12 Gb grafik kartına sahip donanım üzerinde gerçekleştirilmiştir.

Eldeki veri kümesinin %80'i eğitim, geriye kalan %20'si ise test kümesi olarak belirlenmiştir. Eğitim verileri kullanılarak uzmanlar tarafından etiketlenmesi yapılarak ortaya çıkan tümör görüntülerine yakın tahminlemeler yapılmıştır. Sistemin tahmin ettiği tümör görüntüsü uzmanların etiketlemesini yaptığı görüntüler ile karşılaştırılmış ve ortalama tahmin hata değerleri üzerinden sistem başarısı yorumlanmıştır.

Beyin tümörlerinin en yaygın türü olan 259 yüksek dereceli 76 düşük dereceli olmak üzere toplam 335 hastaya ait glioma tümör görüntülerinin %80'i ile eğitime tabi tutulmuştur. Eğitilen modelin tümör tahminlemesi ile uzmanlar tarafından etiketlenen tümör görüntülerini karşılaştırarak benzerlik değerleri belirlenmiştir.


Şekil 4.1'de 100 dönem boyunca eğitilen modelin tüm tümör bölgesi için değerlendirme indekslerinden aldığı sonuçlar gösterilmektedir. Her bir hastaya ait eğitim için en çok anlam ifade ettiği düşünülen 84. ile 100. kesitler arasındaki 16 adet T1ce ve Flair görüntülerinin birleştirilmesi sonucu oluşan 2 kanallı ve 256\*256 boyutlu 5.360 MR görüntüsü kullanılarak tüm tümör bölgesinin tespiti için eğitime tabi tutulmuştur.



Şekil 4.1. Değerlendirme indekslerinin WT üzerindeki skorları


Şekil 4.2'de 100 dönem boyunca eğitilen modelin tümör çekirdeği bölgesi için değerlendirme indekslerinden aldığı sonuçlar gösterilmektedir. Her bir hastaya ait eğitim için en çok anlam ifade ettiği düşünülen 70. ile 120. kesitler arasındaki T1ce

görüntülerindeki tümör bölgesine odaklanmış 128\*128 boyutunda kesiti alınarak kullanılarak tümör çekirdeği bölgesinin tespiti için eğitime tabi tutulmuştur.

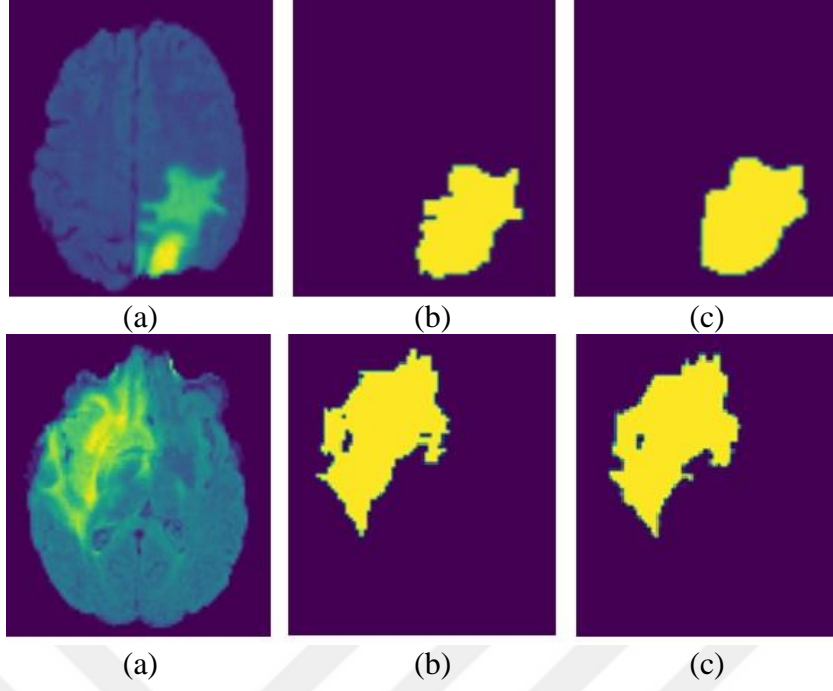


Şekil 4.2. Değerlendirme indekslerinin CT üzerindeki skorları

Şekil 4.3'de 100 dönem boyunca eğitilen modelin genişleyen tümör bölgesi için değerlendirme indekslerinden aldığı sonuçlar gösterilmektedir. Her bir hastaya ait eğitim için en çok anlam ifade ettiği düşünülen 70. ile 120. kesitler arasındaki T1ce görüntülerindeki tümör bölgesine odaklanmış 128\*128 boyutunda kesiti alınarak kullanılarak genişleyen tümör bölgesinin tespiti için eğitime tabi tutulmuştur.




Şekil 4.3. Değerlendirme indekslerinin ET üzerindeki skorları



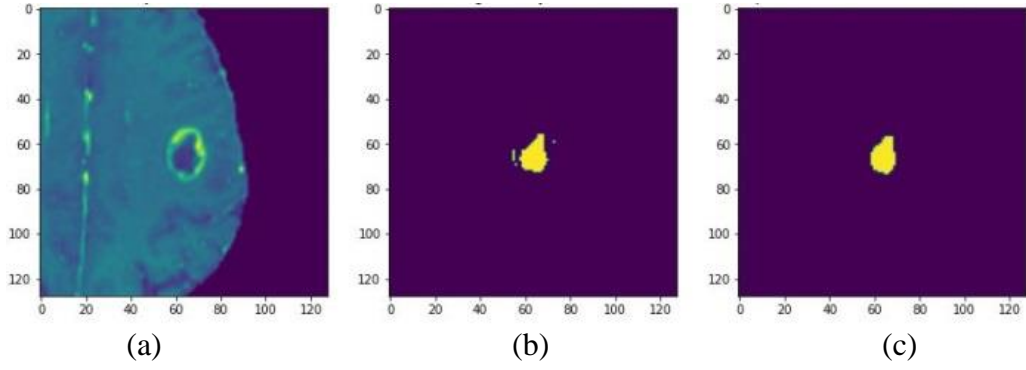
**Şekil 4.4.** (a) Hastalara ait Flair görüntüleri, (b) Uzmanlar tarafından etiketlenen WT tümör bölgeleri, (c) Uygulanan model tarafından tahmin edilen WT tümör bölgeleri.

Şekil 4.4’de Hastalara ait Flair görüntüleri ve uzmanlar tarafından etiketlenen Tüm tümör bölgeleri ile 100 dönem boyunca eğitilen modelin tüm tümör bölgesi için tahminlemesi gösterilmektedir.



**Şekil 4.5.** (a) Hastaya ait T1ce görüntü kesiti, (b) Uzmanlar tarafından etiketlenen ET tümör bölgesi, (c) Uygulanan model tarafından tahmin edilen ET tümör bölgesi

Şekil 4.5’de Hastalara ait T1ce görüntülerinde tümör bölgesine odaklanılarak 128\*128 piksel boyutlarında görüntü kesiti ve uzmanlar tarafından etiketlenen genişleyen tümör bölgesi ile model tarafından tahmin edilen genişleyen tümör bölgesi gösterilmektedir.



**Şekil 4.6.** (a) Hastaya ait T1ce görüntü kesiti, (b) Uzmanlar tarafından etiketlenen CT tümör bölgesi, (c) Uygulanan model tarafından tahmin edilen CT tümör bölgesi

Şekil 4.6’de Hastalara ait T1ce görüntülerinde tümör bölgesine odaklanılarak 128\*128 piksel boyutlarında görüntü kesiti ve uzmanlar tarafından etiketlenen tümör çekirdeği bölgesi ile model tarafından tahmin edilen tümör çekirdeği bölgesi gösterilmektedir.

Bu çalışmada geliştirilen U-Net modeli tüm tümör, tümör çekirdeği ve genişleyen tümör üzerinde sırasıyla 0.908, 0.807 ve 0.877 benzerlik oranı elde etmiştir. Veri setindeki görüntülerin çözünürlükleri yüksek tutulmuş ve genişleyen tümör ve tümör çekirdeği bölgelerinin tespitinde veri setindeki görüntülerde kırpmalar yapılmıştır. Literatürdeki benzer çalışmalar ve bu çalışmada elde edilen benzerlik oranları karşılaştırmalı bir şekilde Tablo 4.1’de sunulmuştur.

**Tablo 4.1.** BraTs veri seti üzerinde benzerlik skorlarının karşılaştırılması

Metot	Dice Skoru		
	WT	CT	ET
MECU-Net (Cheng vd. 2019)	0.902	0.824	0.777
U-Net (Sundaresan vd. 2020)	0.890	0.840	0.810
AresU-Net (Zhang vd. 2020)	0.892	0.853	0.825
3D U-Net (Chen vd. 2019)	0.893	0.830	0.749
RD2A 3D U-Net (Ahmad vd. 2021)	0.903	0.844	0.781
BU-Net (Rehman vd. 2020)	0.901	0.837	0.788
Two-stage cascaded U-Net (Jiang vd. 2019)	0.887	0.836	0.832
MIRAU-Net (AboElenein vd. 2022)	0.885	<b>0.879</b>	0.818
ReSU-Net (Sheng vd. 2021)	0.876	0.782	0.717
U-Net (Eker ve Duru 2021)	0.860	-	-
<b>U-Net</b>	<b>0.908</b>	0.807	<b>0.877</b>

Bu tez çalışmasında görüntü işleme ile veri kümesindeki anlam ifade etmeyen bölümlerin kırılarak alınması ile evrişimli sinir ağı modeli olan U-Net kullanılarak geliştirilen yöntem literatürdeki çalışmalardan WT ve ET bölgelerinin tespitinde en iyi sonucu elde etmiş. CT bölgesinin tespitinde değerlendirme ölçütlerinde literatürdeki çalışmalara yakın bir başarı elde etmiştir.



## 5. SONUÇ

Beyindeki tümör bölgesinin sınırlarını belirlemeyi hedefleyen bu çalışmada U-Net modeline dayalı bir görüntü segmentasyon yöntemi önerilmiş ve önerilen yöntem ile oluşturulan model kullanılarak masaüstü tabanlı bir uygulama gerçekleştirilmiştir.

Bu çalışmada MR görüntüleri 256\*256 piksel boyutlarında ayarlanıp eğitim verisindeki modelin eğitimi için anlam ifade etmeyen bölümleri çıkarılarak literatürdeki çalışmalara alternatif bir yöntem önerilmiştir. Ayrıca, tümör çekirdeği ve genişleyen tümör görüntüleri ön işlem ile tümör bölgesine odaklanılmış 128\*128 piksel kesitler halinde eğitime tabi tutularak literatürdeki benzerlik oranları yakalanmıştır. Tüm tümör, tümör çekirdeği ve genişleyen tümör bölgeleri için ayrı ayrı yapılan eğitimler sonucu sırasıyla 0.908, 0.807 ve 0.877 dice skorları elde edilmiştir. Geliştirilen ağı eğitimi için 2D görüntü dilimlerini kullanması uzmanlar tarafından yapılan segmentasyonun ise 3D görüntülerden faydalanarak yapması sebebiyle daha fazla benzerlik oranında düşüşe yol açmıştır. Gelecekte yapılması planlanan çalışmalarda daha başarılı segmentasyon sonuçları elde etmek ve U-Net modelinin 3D verilerle çalışabilmesi için güncellenmesi planlanmaktadır. Ayrıca performans iyileştirmesi için verinin farklı görüntü işleme ve özellik çıkarma tekniklerinden yararlanması planlanmaktadır.

Bu çalışmada gerçekleştirilen çalışmanın beyin tümörü segmentasyonunu otomatik olarak yapması ve ön tanıda bulunarak uzmanların değerlendirme hızı ve kalitesini artıracığı öngörülmektedir. Geliştirilen ağı şu an ki doğruluk değerleri ile uzman destek sistemi olarak uygulanması mümkün olsa da beyin tümörü teşhisinin hassas bir konu olması nedeni ile daha başarılı ve benzerlik değeri yüksek ağların geliştirilmesi ihtiyacı devam etmektedir.

## KAYNAKLAR

- Abdullah, E., 2020. Görüntü İkileştirme için Global Eşikleme Yöntemleri Üzerine Bir İnceleme. *Mühendislik Bilimleri ve Araştırmaları Dergisi* 2, 38–49.
- Aboelenein, N.M., Piao, S., Noor, A., Ahmed, P.N., 2022. MIRAU-Net: An improved neural network based on U-Net for gliomas segmentation. *Signal Processing Image Communication* 101.
- Acar, U., Bayram, B., 2009. Building Extraction with Morphology.
- Ahmad, P., Jin, H., Qamar, S., Zheng, R., Saeed, A., 2021. RD2A: densely connected residual networks using ASPP for brain tumor segmentation. *Multimedia Tools Applications* 80, 27069–27094.
- Arakeri, M.P., Reddy, G.R.M., 2015. Computer-aided diagnosis system for tissue characterization of brain tumor on magnetic resonance images. *Signal Image Video Process.*
- Atalı, G., Özkan, S.S., Karayel, D., 2016. Morfolojik görüntü işleme tekniği ile yapay sinir ağlarında görüntü tahribat analizi. *Akademik Platform Mühendislik ve Fen Bilimleri Dergisi* 4.
- Aydemir, Ö., Kayıkçıoğlu, T., 2009. EEG tabanlı beyin bilgisayar arayüzleri. *Akademik Bilişim* 9, 11–13.
- Bakas, S., Akbari, H., Sotiras, A., Bilello, M., Rozycki, M., Kirby, J.S., Freymann, J.B., Farahani, K., Davatzikos, C., 2017. Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features. *Scientific Data* 4, 170117.
- Bakas, S., Reyes, M., Jakab, A., Bauer, S., Rempfler, M., Crimi, A., Shinohara, R.T., Berger, C., Ha, S.M., Rozycki, M., 2018. Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge.
- Bellanger, M., 2000. *Digital processing of signals*. Wiley Chichester, İngiltere.
- Boykov, Y.Y., Jolly, M.-P., 2001. Interactive graph cuts for optimal boundary & region segmentation of objects. *Proceedings Eighth IEEE International Conference on Computer Vision, ICCV 2001*, 105–112.
- Chen, W., Liu, B., Peng, S., Sun, J., Qiao, X., 2019. S3D-UNet: Separable 3D U-Net for Brain Tumor Segmentation, *Springer*, 358–368.
- Cheng, X., Jiang, Z., Sun, Q., Zhang, J., 2019. Memory-efficient cascade 3D U-Net for brain tumor segmentation, in: International Miccai Brainlesion Workshop. *Springer*, 242–253.

- Dandıl, E., 2015. MR görüntüleri ve MR spektroskopi verileri ile yapay öğrenme tabanlı beyin tümörü tespit yöntemi ve uygulaması. Doktora Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, Türkiye.
- Eker, A.G., Duru, N., 2021. Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. *Acta Infologica* 5, 459–474.
- Elmas, Ç., 2003. *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*, 192s. Seçkin Ankara.
- Ersoy, E., Karal, Ö., 2012. Yapay sinir ağları ve insan beyni. *İnsan ve Toplum Bilimsel Araştırmaları Dergisi* 1, 188–205.
- Gonzalez, R.C., Woods, R.E., 2008. *Digital image processing - Third edition*, Pearson Education.
- Graupe, D., 2013. Principles of artificial neural networks. *World Scientific*.
- Haykin, S., 1999. *Neural networks: a comprehensive foundation*, Pearson Education.
- Huo, J., Brown, M.S., Okada, K., 2012. CADrx for GBM brain tumors: predicting treatment response from changes in diffusion-weighted MRI, in: Machine Learning in Computer-Aided Diagnosis: Medical Imaging Intelligence and Analysis. IGI global, pp. 297–314.
- Jähne, B., 2002. Digital Image Processing, in: Digital Image Processing. *Springer*, 413–424.
- Jiang, Z., Ding, C., Liu, M., Tao, D., 2019. Two-stage cascaded U-Net: 1st place solution to BraTS challenge 2019 segmentation task, in: International MICCAI Brainlesion Workshop. *Springer*, 231–241.
- Kimori, Y., 2013. Morphological image processing for quantitative shape analysis of biomedical structures: effective contrast enhancement. *J. Synchrotron Radiat.* 20, 848–853.
- Luhmann, T., Robson, S., Kyle, S., Harley, I., 2011. Close Range Photogrammetry: Principles, Methods and Applications.
- Menze, B.H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., Burren, Y., Porz, N., Slotboom, J., Wiest, R., Lanczi, L., Gerstner, E., Weber, M.-A., Arbel, T., Avants, B.B., Ayache, N., Buendia, P., Collins, D.L., Cordier, N., Corso, J.J., Criminisi, A., Das, T., Delingette, H., Demiralp, C., Durst, C.R., Dojat, M., Doyle, S., Festa, J., Forbes, F., Geremia, E., Glocker, B., Golland, P., Guo, X., Hamamci, A., Iftekharuddin, K.M., Jena, R., John, N.M., Konukoglu, E., Lashkari, D., Mariz, J.A., Meier, R., Pereira, S., Precup, D., Price, S.J., Raviv, T.R., Reza, S.M.S., Ryan, M., Sarikaya, D., Schwartz, L., Shin, H.-C., Shotton, J., Silva, C.A., Sousa, N., Subbanna, N.K., Szekely, G., Taylor, T.J., Thomas, O.M., Tustison, N.J., Unal, G., Vasseur, F., Wintermark, M., Ye, D.H., Zhao, L., Zhao, B., Zikic, D., Prastawa, M., Reyes, M., Van Leemput, K., 2015. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). *IEEE Transactions on Medical Imaging* 34, 1993–2024.

- Özbay, E., Özbay, F.A., 2021. Derin Öğrenme ve Sınıflandırma Yaklaşımları ile BT görüntülerinden Covid-19 Tespiti. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi* 12, 211–219.
- Öztemel, E., 2003. *Yapay Sinir Ağları*. Papatya Yayıncılık, İstanbul.
- Perihanoğlu, G.M., 2015. Dijital Görüntü İşleme Teknikleri Kullanılarak Görüntülerden Detay Çıkarımı, Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- Qidwai, U., Chen, C., 2009. Digital image processing: an algorithmic approach with MATLAB. *Chapman and Hall/CRC Press*.
- Rehman, M.U., Cho, S., Kim, J.H., Chong, K.T., 2020. Bu-net: Brain tumor segmentation using modified u-net architecture. *Electronics* 9, 2203.
- Ronneberger, O., Fischer, P., Brox, T., 2015. U-net: Convolutional networks for biomedical image segmentation, in: International Conference on Medical Image Computing and Computer-Assisted Intervention. *Springer*, 234–241.
- Şen, Z., 2004. *Yapay sinir ağları*. Su Vakfı Yayınları, İstanbul.
- Sheng, N., Liu, D., Zhang, Jianxia, Che, C., Zhang, Jianxin, Key Lab of Advanced Design and Intelligent Computing (Ministry of Education), Dalian University, Dalian 116622, China, School of Computer Science and Engineering, Dalian Minzu University, Dalian 116600, China, School of Intelligent Engineering, Henan Institute of Technology, Xinxiang 453003, China, 2021. Second-order ResU-Net for automatic MRI brain tumor segmentation. *Mathematical Biosciences and Engineering*, 18, 4943–4960.
- Sundaresan, V., Griffanti, L., Jenkinson, M., 2020. Brain tumor segmentation using a triplanar ensemble of U-Nets on MR images, in: International MICCAI Brainlesion Workshop. *Springer*, 340–353.
- Yazıcı, H., Fresko, I., Yurdakul, S., 2007. Behçet's syndrome: disease manifestations, management, and advances in treatment. *Nature Clinical Practice Rheumatology*. 3, 148–155.
- Young, I.T., Gerbrands, J.J., Vliet, L.J. van, TU Delft, F. der T.N., 1998. Fundamentals of image processing. Delft University of Technology, *Delft*.
- Zhang, C., Burger, M.C., Jennewein, L., Genßler, S., Schönfeld, K., Zeiner, P., Hattingen, E., Harter, P.N., Mittelbronn, M., Tonn, T., Steinbach, J.P., Wels, W.S., 2016. ErbB2/HER2-Specific NK Cells for Targeted Therapy of Glioblastoma. *Journal National Cancer Institute*.
- Zhang, J., Lv, X., Zhang, H., Liu, B., 2020. AResU-Net: Attention residual U-Net for brain tumor segmentation. *Symmetry* 12, 721.