

T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DERİN ÖĞRENME TABANLI BEYİN MR GÖRÜNTÜLERİNDEN BEYİN
TÜMÖRLERİNİN TESPİT EDİLMESİ VE SINIFLANDIRILMASI**

Ali ARI

DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

HAZİRAN 2019

Tezin Başlığı: Derin Öğrenme Tabanlı Beyin MR Görüntülerinden Beyin Tümörlerinin Tespit Edilmesi ve Sınıflandırılması

Tezi Hazırlayan: Ali ARI

Sınav Tarihi: .../.../2019

Yukarıda adı geçen tez jürimizce değerlendirilerek Bilgisayar Mühendisliği Ana Bilim Dalında Doktora Tezi olarak kabul edilmiştir.

Sınav Jüri Üyeleri

Tez Danışmanı: Prof. Dr. Davut HANBAY

İnönü Üniversitesi

Prof. Dr. Abdulkadir ŞENGÜR

Fırat Üniversitesi

Prof. Dr. Ali KARCI

İnönü Üniversitesi

Dr. Öğrt. Üyesi Ömer Faruk ALÇİN

Bingöl Üniversitesi

Dr. Öğrt. Üyesi Abdullah Erhan AKKAYA

İnönü Üniversitesi

Prof. Dr. Halil İbrahim ADIGÜZEL

Enstitü Müdürü

ONUR SÖZÜ

Doktora Tezi olarak sunduđum “Derin Öğrenme Tabanlı Beyin MR Görüntülerinden Beyin Tümörlerinin Tespit Edilmesi ve Sınıflandırılması” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Ali ARI



ÖZET

Doktora Tezi

Derin Öğrenme Tabanlı Beyin MR Görüntülerinden Beyin Tümörlerinin Tespit Edilmesi ve Sınıflandırılması

Ali ARI

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
xvii+108 sayfa
2019

Danışman: Prof. Dr. Davut HANBAY

Beyin tümörlerinden kaynaklanan ölümlerin sayısı her geçen gün artmaktadır. Beyin tümörleri çok hızlı büyürler. Erken teşhis kanser tanısında, tedavi planlamasında ve tedavi sonucunun değerlendirilmesinde hayati öneme sahiptir. Eğer beyin tümörü olan bir hasta doğru ve erken tedavi görmemişse, hastanın hayatta kalma şansı düşebilir ve ölümlerine sonu çanabilir. Beyin tümörlerinin tanı ve teşhisinde tıbbi görüntüleme önemli bir role sahiptir. Manyetik Rezonans Görüntüleme (MRG), en popüler medikal görüntüleme yöntemlerinden biridir. MRG'den tümörlerin varlığını ve tümör özelliklerini belirlemek uzmanlar tarafından yapılmaktadır. Beyin tümörlerinin niteliğinin belirlenmesi doktorun deneyimine ve bilgisine bağlıdır. Dünya Sağlık Örgütü (DSÖ)'nün raporları beyin tümöründen etkilenen kişilerin sayısının dünya genelinde her yıl önemli ölçüde arttığını göstermektedir. Tümörler farklı şekil ve büyüklüğe sahiptir ve beyin bölgesinde farklı alanlarda bulunabilirler. Bu durum uzmanların tümörü tespit edebilme sürecini daha karmaşık hale getirmektedir. Uzmanlar tarafından beyin tümörünün tespit edilmesi zaman alıcı ve hataya açık bir süreçtir. Uzmanın deneyimi tespit sürecinin başarımını etkilemektedir. Beyin tümörünün manuel tespiti, hasta sayısının fazla olduğu durumlarda kullanışlı bir yöntem değildir. Bu nedenle, beyin tümörlerinin otomatik olarak tespit edilmesine ihtiyaç duyulmaktadır. Hekimlerin teşhis yeteneklerini arttırmak ve doğru teşhis için uzmanlar tarafından harcanan süreleri azaltmak, Bilgisayar Destekli Otomatik Tespit Sistemleri (BDOTS) ile mümkün olabilmektedir. Bu tez çalışmasında beyin MR görüntülerinden otomatik tümör tespiti yapan ve tümörleri derecelerine ve türlerine göre sınıflandırabilen beş farklı BDOTS tasarlanmıştır. 6 farklı veri tabanı kullanılarak tasarlanan BDOTS'ların performansı değerlendirilmiştir. Tasarlanan BDOTS'lardan iki tanesi ön işlem, morfolojik işlemler, kenar tespiti ve beyin tümörlerinin dokusal, istatistiksel, morfolojik ve renk özniteliklerinin çıkarımı ve sınıflandırma işlemlerini kapsamaktadır. Diğer üç sistem ise Evrişimsel Sinir Ağları (ESA), Bölgesel Evrişimsel Sinir Ağları (BESA), AlexNet, VGG16, Yerel Alıcı Alanlar- Aşırı Öğrenme Makinesi gibi derin öğrenme mimarileri temellidir. Her bir BDOTS'un sağladığı üstünlükler ve eksiklikler tez içerisinde detaylı bir şekilde irdelenmiştir. Yapılan çalışmaların sonucunda beyin tümörlerinin tespitinin ve sınıflandırılmasının başarılı bir şekilde gerçekleştiği görülmüştür.

ANAHTAR KELİMELER: Beyin tümör tespiti; beyin tümör sınıflandırma; derin öğrenme; tıbbi görüntüleme; öznitelik çıkarımı.

ABSTRACT

Ph.D.Thesis

Detection and Classification of Brain Tumors from MR Images Based on Deep Learning

Ali ARI

İnönü University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering
xvii+108 pages
2019

Supervisor: Prof.Dr Davut HANBAY

The number of deaths stemming from brain tumors is increasing every day. Brain tumors grow quite fast. Early diagnosis has a vital role in diagnosis of cancer, treatment planning and evaluation of treatment. If a patient with brain tumor has not received accurate and early treatment, the chance of survival decreases and this may cause death. Medical imaging plays a crucial role in detection and diagnosis of brain tumors. Magnetic Resonance Imaging (MRI) is one of the most popular medical imaging methods. Detection of tumors and description of tumor features are done by experts through MRI. Defining the quality of brain tumors depends on doctors' experience and knowledge. World Health Organization (WHO) reports show that the number of people suffering from brain tumors is increasing significantly every year. Tumors have different shape and size and may exist in different parts of the brain. This creates a challenge for experts to detect the tumor. Detection of tumors by experts is a long and sensitive process. Experts' experience affects the success of tumor detection process. Manual detection of tumors is not an effective method in cases where the number of patients is redundant. Therefore, there is a need for detection of tumors automatically. Improving diagnosis skills of doctors and diminishing the time spent by experts for accurate diagnosis is possible through Computer Assisted Automatic Detection Systems (CAADS). In this dissertation study, 5 different CAADS, which can automatically identify tumors and classify them according to tumor levels and tumor types through brain MR images, have been designed. The performance of CAADS, which were designed using 6 different databases, has been evaluated. Two of the CAADS covers the pretreatment, morphological operations, side detection and definition of the textural, statistical, morphological and color qualities of brain tumors and their classification. Other three systems, on the other hand, are based on deep learning architectures such as Convolutionary Nerve Networks (CNN), Local Convolutionary Nerve Networks (LCNN), AlexNet, VGG16, Local Reciever Areas and Excessive Learning Machine. Advantages and challenges of each CAADS have been thoroughly examined in this study. As a result of studies, it is seen that systems successfully identify and classify brain tumors.

KEYWORDS: Brain tumor detection; classification of brain tumors; deep learning; medical imaging; feature extraction

TEŞEKKÜR

Doktora eğitimimin ve hayatımın her anında bana destek olan akademik bilgi ve tecrübelerinin yanı sıra hayat tecrübelerini ve bilgi birikimini sabır ve cömertlikle benimle paylaşan kıymetli danışman hocam Prof. Dr. Davut HANBAY'a,

Doktora eğitimim boyunca yoğunluğumu, sıkıntımı, stresimi anlayan hayatım boyunca aldığım her karar da yanımda olan sevgili eşim Berna ARI'ya ve varlığına her daim şükrettiğim, ilgilenemediğim zamanlarda stres yaptığım, sanki beni anlıyormuş gibi bana davranan ve kocaman yüreğiyle tüm sıkıntılarımı bana unutturan oğlum Giray Bera ARI'ya,

Bugünlere gelmem de büyük emekleri olan, hayatımın her anında bana destek olan, haklarını hiçbir zaman ödeyemeyeceğim kıymetli annem ve babam ile kardeşlerime,

Akademik eğitimim boyunca bana destek olan kıymetli hocalarım Prof.Dr. Abdulkadir ŞENGÜR, Dr.Öğr. Üyesi Ömer Faruk ALÇİN, Arş.Gör. Muammer TÜRKOĞLU ve Arş. Gör. Furkan AYAZ'a,

İnönü Üniversitesi Bilgisayar Mühendisliği Bölümü akademisyenleri kıymetli hocalarıma ve idari personellerine,

Malatya'da her daim birlikte olduğumuz kıymetli dostlarım, Sedat - Ayça YEŞİLYURT, Ömür - Seval ERDEM, Tuğrul – Melike TURAN, Caner - Armağan Veli, Murat – Zeynep MARAŞ, Ömer – Hatice BARK, Erman - Burçin TACER çiftlerine,

Tez yazımım boyunca sürekli olarak beni motive eden, bana destek olan kıymetli hocalarım Prof. Dr. Hacı Bayram KARADAĞ, Doc. Dr. Müge KARADAĞ, Doc. Dr. Kemal ÖZDEMİR, Dr.Öğr. Üyesi Filiz ÖZDEMİR, Dr.Öğr.Üyesi İlknur Ucu ve Doc.Dr. Yeşim Aksoy DERYA'ya,

Bera Ar-Ge Yazılım ve Danışmanlık Hiz. San.Tic.Ltd.Şti'nin kıymetli çalışanları Gökçe BULUT, Yavuz ÇAYLI, Şevket KAPLAN, Hayriye CİNGÖZ, Batuhan KARADAĞ ve Neslihan SOGUR'a,

Doktora eğitimim boyunca bana destek olan Malatya Turgut ÖZAL Üniversitesi Doğanşehir Vahap Küçük MYO'nun yönetimine ve birlikte görev yaptığımız tüm akademisyen arkadaşlarıma,

Şükranlarımı sunuyor teşekkür ediyorum.

İÇİNDEKİLER

ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
İÇİNDEKİLER.....	vi
ŞEKİLLER LİSTESİ.....	ix
ÇİZELGELER LİSTESİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ.....	1
1.1. Önerilen Sisteminin Genel Çerçevesi.....	12
1.1.1. Tezin Amacı	12
1.1.2. Tezin Gerekçeleri	13
1.1.3. Tezin Çıktıları.....	13
1.1.4. Tezin Yenilikçi Yönü ve Ar-Ge Niteliği	15
1.1.5. Tezin Organizasyonu.....	15
2. BEYİN TÜMÖRLERİNİN TESPİTİ VE SINIFLANDIRILMASI.....	16
2.1. Ön İşlem	16
2.1.1. Orta Değer Filtresi	16
2.1.2. Gauss Filtresi	17
2.1.3. Adaptif Filtreler	17
2.1.4. Histogram Germe	17
2.2. Bölütleme	18
2.2.1. Eşikleme	18
2.2.2. Otsu Bölütleme.....	19
2.2.3. Havza Bölütleme	19
2.3. Öznitelik Çıkarımı	20
2.3.1. İstatistik Temelli Özellik Çıkarım Teknikleri	20
2.3.2. Doku Temelli Öznitelik Çıkarım Teknikleri	21
2.3.2.1. Gabor Dalgacık Öznitelikleri	21
2.3.2.2. Dalgacık Tabanlı Özellik Çıkarımı	22
2.3.2.2.1. Ayrık Dalgacık Dönüşümü.....	22
2.3.2.2.2. İki boyutta Ayrık Dalgacık Dönüşümü	23

2.3.2.3.	Contourlet dönüşümü	24
2.3.2.4.	Shearlet dönüşümü	25
2.3.2.5.	Curvelet dönüşümü.....	26
2.3.2.6.	Gri Seviye Eş Oluşum Matrisi.....	27
2.3.2.7.	Gri Seviye Dizi Uzunluğu Matrisi.....	29
2.3.2.8.	Yönlendirilmiş gradyan özelliklerinin histogramı	29
2.3.2.9.	Yerel İkili Örüntü Özellikleri	30
2.4.	Boyut İndirgeme.....	31
2.4.1.	Temel Bileşen Analizi	31
2.4.2.	Doğrusal Ayırt Edici Analiz.....	32
2.4.3.	Bağımsız Bileşen Analizi	32
2.4.4.	YAK'a göre özellik seçimi.....	33
2.5.	Sınıflandırma	34
2.5.1.	Yapay Sinir Ağları.....	34
2.5.2.	Destek Vektör Makinesi	35
2.5.2.1.	DVM Sınıflandırıcının incelenmesi	35
2.5.2.2.	Doğrusal DVM sınıflandırıcı.....	35
2.5.2.3.	Doğrusal olmayan DVM sınıflandırıcısı	36
2.5.2.4.	DVM çekirdek fonksiyonları.....	36
2.5.3.	Aşırı Öğrenme Makineleri.....	37
2.5.4.	Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi	38
2.5.5.	En Küçük Kareler Destek Vektör Makinesi	40
2.5.6.	Parçacık Sürü Optimizasyonu	41
2.5.7.	Kendini Yineleyen Haritalar	42
2.6.	Morfolojik işlemler.....	43
2.6.1.	Genişletme İşlemi.....	44
2.6.2.	Aşındırma İşlemi	45
2.6.3.	Boşluk doldurma	46
2.7.	Kenar Bulma.....	46
2.7.1.	Roberts Operatörü	47
2.7.2.	Sobel Operatörü.....	48
2.7.3.	Prewitt operatörü	48
3.	DERİN ÖĞRENME	49
3.1.	Veri Arttırma	50

3.2.	Evrişimsel Sinir Ağları	50
3.2.1.	Girdi Katmanı	51
3.2.2.	Evrişim katmanları	52
3.2.3.	Havuzlama Katmanı	53
3.2.4.	Aktivasyon Fonksiyonu	54
3.2.5.	Çıktı Katmanı	54
3.2.6.	Kayıp Fonksiyonu	55
3.2.6.1.	Öklid Fonksiyonu	55
3.2.6.2.	Softmax Fonksiyonu	55
3.3.	ESA Mimarileri	56
3.3.1.	AlexNet	57
3.3.2.	VGG16	57
3.3.3.	Yerel Alıcı Alanlar - Aşırı Öğrenme Makinesi	58
3.3.4.	GoogleNet	59
3.3.5.	U-NET	60
3.3.6.	ResNet	60
4.	UYGULAMALAR	64
4.1.	Kullanılan Veri Setleri	64
4.2.	Kullanılan Performans Kriterleri	65
4.3.	Uygulama 1: Bölgesel Evrişimsel Sinir Ağları ile Beyin MR Görüntülerinden Tümör Tespiti	66
4.4.	Uygulama 2: Derin Öznitelikler Kullanılarak Beyin MR Görüntülerinin Sınıflandırılması ve Tümör Tespiti	74
4.4.1.	Sınıflandırma Sonuçları	76
4.4.2.	Bölütleme Sonuçları	79
4.5.	Uygulama 3: MR Görüntülerinden Aşırı Öğrenme Makinesi Tabanlı Tümör Tespiti	81
4.6.	Uygulama 4: Ensemble YSA Kullanılarak Beyin MR Görüntülerinin Sınıflandırılması	81
4.7.	Uygulama 5: Derin Öğrenme Tabanlı Beyin Tümörlerini Sınıflandırma ve Tespit Sistemi	87
5.	SONUÇ	92
6.	KAYNAKLAR	95
	ÖZGEÇMİŞ	108

ŞEKİLLER LİSTESİ

Şekil 1.1.	Düzlemlere ait beyin MR görüntüleri: (a) aksiyel düzlem, (b) sagittal düzlem, (c) koronal düzlem.....	2
Şekil 1.2.	Her bir sekansa ait MR görüntüleri (a) T1 ağırlıklı, (b) T2 ağırlıklı, (c) Proton ağırlıklı	3
Şekil 2.1.	Beş farklı ölçekte ve sekiz yönde Gabor dalgacık taneleri.....	22
Şekil 2.2.	CNT'nin ayrışma şeması.....	24
Şekil 2.3.	Seçilen piksel için açıların sunumu	27
Şekil 2.4.	GSEM karesinin oluşturulması	28
Şekil 2.5.	YİÖ operatörünün uygulanışı	30
Şekil 2.6.	Tekdüze YİÖ'nun görsel sunumu.	31
Şekil 2.7.	Yapay Sinir Ağlarının temel yapısı	34
Şekil 2.8.	UATBÇS mimarisinin yapısı	39
Şekil 2.9.	KYH'nin gösterimi.....	42
Şekil 2.10.	İkili görüntü üzerinde uygulanan mantıksal işlemlerin gösterimi.....	44
Şekil 2.11.	Genişletme işleminin gösterimi.....	45
Şekil 2.12.	Aşındırma işleminin gösterimi	45
Şekil 2.13.	Açma işlemi.....	46
Şekil 2.14.	Kapama işlemi	46
Şekil 3.1.	ESA'nın çalışma prensibi	51
Şekil 3.2.	Ağırlığı paylaşılan evrişim katmanları ile tam bağlı katmanın karşılaştırılması: (a) Tam bağlı katman parametre sayısı, (b) Ağırlığı paylaşılan evrişim katmanı parametre sayısı.....	52
Şekil 3.3.	Evrişim operatörünün uygulanışı	53
Şekil 3.4.	Ortalama ve maksimum havuzlama işlemi örneği	54
Şekil 3.5.	Alexnet mimarisin dizilimi.....	57
Şekil 3.6.	VGG16 derin öğrenme mimarisinin çalışma prensibi.....	58
Şekil 3.7.	GoogLeNet mimarisinin çalışma prensibi	59
Şekil 3.9.	ResNet mimarisinin çalışma prensibi.....	61
Şekil 4.2.	Tasarlanan sistem tarafından doğru olarak etiketlenen Benchmark veri setine ait örnek görüntüler	69
Şekil 4.3.	Tasarlanan sistem tarafından doğru olarak etiketlenen REMBREDANT veri setine ait örnek görüntüler.....	70

Şekil 4.4. Tasarlanan sistem tarafından doğru olarak etiketlenen Harvard veri setine ait örnek görüntüler	71
Şekil 4.5. Tasarlanan sistemler tarafından yanlış olarak etiketlenen örnek MR görüntüleri (Example MR images incorrectly labeled by the proposed systems)	73
Şekil 4.6. Önerilen yöntemin çalışma prensibi	75
Şekil 4.8. Tümör tespit aşamaları	80
Şekil 4.9. Önerilen BDOTS'un çalışma prensibi	82
Şekil 4.10. İki boyutlu dalgacık dönüşümü uygulanmış görüntüler	82
Şekil 4.11. (a) Orjinal MR görüntüsü, (b) Ön işlem uygulanmış MR görüntüsü	83
Şekil 4.12. (a) Eşiklenmiş MR görüntüsü, (b) Açma işlemi, (c) Kapama işlemi, (d) Tümör tespiti	83
Şekil 4.13. Ensemble modelin eğitim performansı	86
Şekil 4.14. Ensemble modelin ROC eğrisi	86
Şekil 4.15. Tasarlanan BDOTS'un çalışma prensibi	87
Şekil 4.16. (a) Orijinal görüntü, (b) Ön işlem uygulanmış görüntü, (c) Beyin kafatasının çıkarımı, (d) Beyin dokusunun çıkarımı, (e) Beyin tümörünün tespiti	88
Şekil 4.17. YAA-AÖM'nin çalışma prensibi	89
Şekil 4.18. Evrişim işleminin sonucu oluşan görüntüler	89
Şekil 4.19. Havuzlama işleminin sonucu oluşan görüntüler	89

ÇİZELGELER LİSTESİ

Çizelge 3.1.	İlgili parametreler ile veri arttırma teknikleri	50
Çizelge 3.2.	ESA mimarilerinin kapsamlı olmaktan uzak, kronolojik olmayan bir listesi ve bazı üst düzey açıklamalar	62
Çizelge 4.1.	Tasarlanan BESA'ların parametreleri ve değerleri	67
Çizelge 4.2.	Tasarlanan sistemlerin Benchmark veri seti için başarımlar sonuçları	69
Çizelge 4.3.	Tasarlanan sistemlerin REMBREDANT veri seti için performans sonuçları	71
Çizelge 4.4.	Tasarlanan sistemlerin Harvard veri setinde başarımlar ölçüt sonuçları	72
Çizelge 4.5.	Tasarlanan BESA'ların çalışma süreleri	73
Çizelge 4.6.	Önerilen yöntemin mevcut yöntemler ile doğruluk oranlarının karşılaştırılması	74
Çizelge 4.7.	RIDER veriseti için elde edilen öznelik vektörleri ve doğruluk oranları	77
Çizelge 4.8.	Figshare veriseti için elde edilen öznelik vektörleri ve doğruluk oranları	77
Çizelge 4.9.	REMBREDANT veriseti için elde edilen öznelik vektörleri ve doğruluk oranları	78
Çizelge 4.10.	Rider veri setini kullanan literatürdeki çalışma ile önerdiğimiz metodun başarımlarının kıyaslanması	78
Çizelge 4.11.	Figshare veri setini kullanan literatürdeki çalışma ile önerdiğimiz metodun başarımlarının kıyaslanması	79
Çizelge 4.12.	REMBREDANT veri setini kullanan literatürdeki çalışma ile önerdiğimiz metodun başarımlarının kıyaslanması	79
Çizelge 4.13.	Önerilen yöntemin tümör tespitinde başarımlar sonuçları	80
Çizelge 4.14.	Tip 1 YSA mimarisinin özellikleri ve eğitim parametreleri	84
Çizelge 4.15.	Düzlemlerden elde edilen performans sonuçları	84
Çizelge 4.16.	Önerilen yöntemin literatürde yer alan diğer çalışmaların performansları ile karşılaştırılması	85
Çizelge 4.17.	Tip 2 YSA modelinin mimarisi ve eğitim parametreleri	85
Çizelge 4.18.	Gabor dalgacık ve istatistiksel-dokusal özneliklere dayalı farklı sınıflandırıcıların sınıflandırma performans değerleri	90
Çizelge 4.19.	Farklı metodların sınıflandırma başarımları	91

SİMGELER VE KISALTMALAR

ADD	: Ayrık Dalgacık Dönüşümü
AÖM	: Aşırı Öğrenme Makineleri
BBA	: Bağımsız Bileşen Analizi
BCO	: Bulanık C Ortalamalar
BDOTS	: Bilgisayar Destekli Otomatik Tespit Sistemleri
BT	: Bilgisayarlı Tomografi
DDB	: Doğrultulmuş Doğrusal Birim
DDG	: Düşük Dereceli Gliomalar
DESA	: Derin Evrişimsel Sinir Ağı
DESSA	: Derin Evrişimsel Simetrik Sinir Ağları
DSA	: Derin Sinir Ağı
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makinaları
ESA	: Evrişimsel Sinir Ağları
GIÜ	: Grafik İşlemci Ünitesi
GSDUM	: Gri Seviye Dizi Uzunluğu Matrisi
GSEM	: Gri Seviye Eş Oluşum Matrisleri
KDH	: Kendini Düzenleyen Haritalar
k- EYK	: k-En Yakın Komşu
KYH	: Kendini Yineleyen Haritalar
KYM	: Kırmızı Yeşil Mavi
LAEA	: Lineer Ayırt Edici Analiz
LP	: Laplacian Piramid

MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme
NSCT	: NonSub sampled Contourlet Transform
OYÜÖ	: Olasılıksal Yerel Üçlü Örüntü
PSO	: Parçacık Sürü Optimizasyonu
RÇA-SAAÖ	: Rastgele Çoğunluk Aşağı Örnekleme-Sentetik Azınlık Aşırı Örnekleme
RDP	: Renk Özü, Doygunluk ve Parlaklık
TBA	: Temel Bileşen Analizi
UATBÇS	: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
YAK	: Yapay Arı Kolonisi
YDG	: Yüksek Dereceli Gliomalar
YFB	: Yönelimli Filtre Bankası
YGÖH	: Yönlendirilmiş Gradyan Özelliklerinin Histogram
YİÖ	: Yerel İkili Örüntü
YSA	: Yapay Sinir Ağları
μ	: Ortalama
σ^2	: Ortalama Kontrast
μ_3	: Çarpıklık
μ_4	: Basıklık
E	: Enerji
H	: Entropi
G	: Görüntünün maksimum gri seviyesi
$P(i)$: Elde edilen yoğunluk seviyelerinin olasılık yoğunluğu
$h(i)$: (i) yoğunluk seviyesindeki toplam piksel sayısı
N	: Görüntüdeki toplam piksel sayısı

C_c	: Kesme matrisi
$D_{C_c}, c \in \mathbb{R}$: Kesme operatörü
c	: Eğim değişkeni
T_s	: Çeviri operatörü
$SH(\gamma), \gamma \in L^2(\mathbb{R}^2)$: Sürekli kesme operatörü
f	: Sinüzoidin frekansı
θ	: Normalin bir Gabor fonksiyonunun paralel çizgilerine oryantasyonu
ϕ	: Faz kayması
σ	: Gauss zarfının standart sapması
γ	: Uzaysal en boy oranıdır ve Gabor fonksiyonu desteğinin elipslik düzeyi
τ	: Translasyon parametresi
$x[n]$: Kesikli bir zaman sinyali için
I	: Oktavlardaki dalgacık ayrışması
$c_{i,k} i = 1 \dots I$: Dalgacık katsayıları
$d_{i,k} i = 1 \dots I$: Ölçek katsayıları.
$g_i[n - 2^i k]$: Ayrık dalga izinleri
$h_l[n - 2^l k]$: Ölçekleme sekansları
$(*)$: Karmaşık konjugat
Y_a^1	: Y görüntüsünün birinci seviye bir yaklaşım bileşeni
Y_h^1, Y_v^1 ve Y_d^1	: Y görüntüsünün birinci seviye bir yaklaşım bileşeninin yatay, Dikey ve çapraz detayları
Num	: Eş-oluşum matrisindeki element sayısı
K	: Toplam piksel çifti sayısı
C_{ij}	: Eş oluşum matrisinin (i,j). elementi
$(\theta) = [r'(i, l \theta)]$: Gri seviye akış uzunluğu matrisinde,

$r'(i, l \theta)$: Görüntünün l uzunluğundaki, i gri seviyesi için, θ açısı yönündeki işlem içerme sayısı
G	: Gri seviyelerinin sayısı
NR	: Matristeki çalışma uzunluklarının sayısı
R	: YİÖ operatörünün çalışacağı uzaklık
P	: YİÖ operatörünün örnekleme noktalarının sayısı
N	: Sıfır olmayan özvektörleri
M	: İdeal özellik sayısı
(γ)	: Yeniden yapılanma oranı
λ_i	: Azalan büyüklükte sıralanmış özdeğerler
(S_w)	: Sınıf içi dağılım matrisi
μ	: Tüm sınıfların ortalamasını
v_i^j	: Yeni geliştirilmiş çözümü
$x = (x_1, x_2, x_m)$: Nörona uygulanan m adet giriş
w_i	: x_i girişi için ağırlıkları temsil eder
y_i	: Bias değeridir
$a(\cdot)$: Aktivasyon işlevidir
$x \in R^n$: Sınıflandırılacak bir desen
y	: Desenin sınıf etiketi olsun
$(y = \pm 1). \{(x_i, y_i), i = 1, 2, \dots, l\}$: Bir grup uygulama örneği
$\Phi(\cdot)$:	: Doğrusal olmayan bir operatör
(\cdot, \cdot)	: Çekirdeğin temeli
$p > 0$: Çekirdeğin sırasını ifade eden bir sabit
α_i	: Lagrange çarpanı,
x_i	: Destek vektörü
$K(x_i, x)$: Özellik alanındaki iç çarpımın konvolüsyonunu

L	: AÖM'nin gizli düğüm sayısı
H	: Gizli katman çıktı matrisi
T	: ELM'nin hedef matrisi
β	: Çıktı ağırlığı matrisi
C	: Genelleme performansını güçlendirmek için bir düzenleme faktörü
I	: Birim matris
A_i	: Düğüm işleviyle ilişkilendirilmiş dilsel bir etiket
O_i^1	: A_i 'nin üyelik işlevi
\bar{w}	: Kuralların normalize edilmiş ateş gücü
\bar{w}_i	: katman-3'ün çıktısı
$\{p, q, r\}$: parametre setidir.
γ	: Düzenleştirme sabiti
σ	: RTF Çekirdeğinin genişliği
p	: Bir görüntü parçacığı
i	: Optimizasyon işleminde yineleme
d	: Parçacığın arama alanındaki konumunu gösterir
w	: Atalet ağırlığı
Ppd	: Parçacığın en iyi kişisel pozisyonu olarak adlandırılan en iyi pozisyon
PGd	: En iyi global pozisyon
P_i	: Öngörülen değer
M_i	: Ölçülen değerler
n	: Örnekleme noktalarının sayısı
c	: Kazanan nöronun en iyi eşleşme birimi, c ile gösterilir
$h_{c,i}$: Gauss komşuluk fonksiyonudur

$\ r_c - r_i\ $: Nöron c ve nöron i kazanma pozisyonları arasındaki Öklid mesafesi
$\sigma(t)$: Gaussian'ın genişliği
$mag(\nabla f)$: Gradyanın boyu
w	: Filtre katsayıları başlangıçta rasgele seçilir
$\max(0, x)$: Doğrultulmuş Doğru Birim fonksiyonu
\hat{d}_i	: İndirgenmiş çıkışlar
d_i	: Hedef çıkışlar
p_j	: Girdinin j 'ninci sınıfına ait tahmin edilen olasılığı
o_j ;	: ESA'nın son katmanındaki j 'ninci çıktıyı,
e	: İse exponansiyel ifadeyi belirtmektedir.
P	: Tümörlü görüntülerin sayısı
N	: Tümörsüz görüntülerin sayısı
DP	: Doğru Pozitifler
DN	: Doğru Negatifler
YP	: Yanlış Pozitifler
YN	: Yanlış Negatifler

1. GİRİŞ

Organizmalarda, anormal hücrelerin hızlı bir şekilde çoğalması ile oluşan kitlelere tümör denir [1]. Beyin tümörlerinin oluşması, beyin hücrelerinden, beynin etrafındaki zarlardan, sinirlerden ve bezlerden başlayabilir. Beyin tümörleri beyin hücrelerini doğrudan tahrip edebilir veya beyin kafatasındaki dokulara basınç yaparak beyin hücrelerine zarar verebilir [2,3].

Genel olarak beyin tümörleri iyi - kötü huylu ve birincil - ikincil tümörler olarak sınıflandırılmaktadır. Birincil (primer) beyin tümörü, beyinde başlar ve burada yayılırken, ikincil beyin tümörleri (metastaz) insan vücudunun herhangi bir bölümünden başlayarak beyin dokularına yayılabilir [4].


İyi huylu tümörler homojen yapılara sahiptir ve büyümeleri yavaştır. Kötü huylu tümörler ise çevresindeki dokulara nüfuz ederek çok hızlı büyürler. Yetişkin insan beyinde en sık görülen kötü huylu tümörlerden olan gliomalar, glial hücrelerinden meydana gelir [4]. Glioma yetişkinleri hedef almasından dolayı tıp camiasının temel odak noktası olmuştur. Gliomanın tedavisi hücrelerin şekil, büyüklük ve pozisyonlarının değişkenliği nedeniyle uzmanlar için zorlu bir görevdir [5]. Gliomalar, Dünya Sağlık Örgütü (DSÖ) (World Health Organization-WHO) tümör derecelendirme şemasına göre temel olarak iki gruba ayrılabilir. Bunlar Yüksek Dereceli Gliomalar (YDG) ve Düşük Dereceli Gliomalar (DDG)'dir. Gliomalar yüksek insidanslı ve ölümcül olması nedeniyle insan sağlığına büyük tehdit oluşturmaktadır [6].

Tıpta bir uzmanlık alanı olan radyoloji bölümü içerisinde çeşitli problemlerin ve anormalliklerin tanımlanmasına yardımcı olmak için hekimlerin kullanabileceği birçok tanısal görüntüleme yöntemi vardır. Görüntüleme teknolojisinin seçimi, sergilenen semptomlara, incelenen bölgeye ve seçilen yöntemin maliyetine ve kullanılabilirliğine bağlıdır. Tümör hücreleri, boyut ve yoğunluk gibi farklı morfolojik özelliklere sahiptir. Beyin bölgesindeki tümör hücrelerinin çoğu, kendilerini çevreleyen diğer hücrelere kıyasla farklı yapıdadır. Beyin tümörlerinin incelenmesi ve araştırılması amacı ile Manyetik Rezonans Görüntüleme (MRG) taramaları ve Bilgisayarlı Tomografi (BT) taramaları sıklıkla kullanılan tanısal görüntüleme türleridir [7].

BT, X-ışını kullanılarak vücudun incelenen bölgesinin kesitsel görüntüsünü oluşturmaya yönelik radyolojik teşhis yöntemidir. BT taramaları, tümörün görüntüden ayırt edilebilmesi için gri skala şeklinde gösterilmektedir [7].

MRG, non-invaziv bir tekniktir ve radyo frekans dalgaları ile güçlü manyetik alan kullanarak yumuşak doku hakkında ayrıntılı bilgi verir. Günümüzde beyin MRG, tümörlerin tanı ve tedavi sonrası takiplerinde yaygın olarak kullanılmaktadır. Beyin Manyetik Rezonans (MR) görüntüleri, tümörleri ve çevresindeki anormal sinyal değişikliklerini kolaylıkla tespit edebilir. Bu nedenle, beyin tümörlerinin tespitinde MRG önemli bir araç olarak kabul edilir [8].


MRG'de organların üç farklı düzlemde görüntülenebilmesi uzmanlara organ hakkında daha çok bilgi verebilmektedir. Farklı düzlemlerde görüntüleme ile radyoloji uzmanları şekilsel, dokusal ve hacimsel olarak tümör hakkında daha doğru yorumlar yapabilir. Aksiyel düzlemde beynin üstten görünüşü, sagittal düzlemde yandan görünüşü, koronal düzlemde ise arkadan görünüşü elde edilir [9,10]. İlgili düzlemlere ait MR görüntüleri Şekil 1.1'de verilmiştir.



Şekil 1.1. Düzlemlere ait beyin MR görüntüleri: (a) aksiyel düzlem, (b) sagittal düzlem, (c) koronal düzlem[10]

Tümör birçok biyolojik dokudan oluştuğu için sadece tek bir sekansla çekim yapılan beyin MR görüntüleri tümör dokuları hakkında tüm bilgileri veremeyebilir [10–12]. Eğer MRG tetkiki uygun bir protokole uygulanmış ve deneyimli bir radyolog tarafından beyin tümörü varlığı açısından negatif olarak yorumlanmışsa, beyin tümörü olasılığı güvenli bir şekilde dışlanabilir. Tümör mevcut ise, tümörün kesin yerleşimi ve özellikleri tanımlanmalıdır. Tümörün histolojik tipi ve derecesi gibi kendine özgü özellikleri yanında tümörün komşu beyin yapılarında oluşturduğu etkiler de uygulanacak tedavi ve prognoz

tahmini bakımından oldukça önem taşımaktadır. Bu nedenle bir MRG'de aynı bölgeye ait en az üç farklı sekansa görüntüleme yapılır [10-12]. Bunlar T1 ağırlıklı, T2 ağırlıklı ve proton ağırlıklı görüntülerdir [13]. Aksiyel düzleme ait üç farklı sekans görüntüsü Şekil 1.2'de sunulmuştur. T1 ağırlıklı sekanslar çok iyi yumuşak doku kontrastı ve uzaysal çözünürlük sağlayarak anatomik değerlendirme için olanak sağlar. T2 ağırlıklı sekanslarda ise patolojik sinyal değişiklikleri ayırt edilir. Az sayıda kullanım alanı olan proton ağırlıklı görüntüler standart incelemelerden kaldırılmıştır. Su, T1 ağırlıklı görüntülerde siyah, T2 ağırlıklı görüntülerde beyaz, proton ağırlıklı görüntülerde ise gri tonlarda görülür [10, 12-14].



Şekil 1.2. Her bir sekansa ait MR görüntüleri (a) T1 ağırlıklı, (b) T2 ağırlıklı, (c) Proton ağırlıklı [10]

DSÖ'nün raporları beyin tümöründen etkilenen kişilerin sayısının dünya genelinde her yıl önemli ölçüde arttığını göstermektedir [15]. Tümörler farklı şekil ve büyüklüğe sahiptir ve beyin bölgesinde farklı alanlarda bulunabilirler; bu durum uzmanların tümörü tespit edebilme sürecini daha karmaşık hale getirmektedir. Uzmanlar tarafından beyin tümörünün tespit edilmesi zaman alıcı ve hataya açık bir süreçtir. Uzmanın deneyimi tespit sürecinin başarımını etkilemektedir. Beyin tümörünün manuel tespiti, hasta sayısının fazla olduğu durumlarda kullanışlı bir yöntem değildir. Bu nedenle, beyin tümörlerinin otomatik olarak tespit edilmesine ihtiyaç duyulmaktadır. Hekimlerin teşhis yeteneklerini arttırmak ve doğru teşhis için uzmanlar tarafından harcanan süreleri azaltmak, Bilgisayar Destekli Otomatik Tespit Sistemleri (BDOTS) ile mümkün olabilmektedir. Bu sistemlerin amacı, uzmanların hızlı ve doğru karar verebilmelerine destek olmaktır [10]. BDOTS'de aranan hız ve yüksek doğruluk oranı gibi özellikler bu tez çalışmasının odak noktasıdır.

BDOTS için görüntü işleme ve makine öğrenmesi temelli tümör tespiti yaklaşımları son yıllarda önemli bir araştırma konusu olmuştur. Bir BDOTS genellikle altı temel adımdan oluşur. Bunlar; ön işlemler, bölütleme, kenar tespiti, öznitelik çıkarımı, özniteliklerin boyut indirgenmesi ve sınıflandırmadır. Ön işlemler olarak, parlaklık artırma, filtreleme ve renk

uzayı deęiřtirme gibi iřlemler uygulanabilir. Ön iřlemlerin temel amacı bütün görüntülerden standart özniteliklerin doęru bir řekilde elde edilmesini saęlamaktır. Öznitelik, bir nesneyi karakterize eden ayırt edici niteliklerdir. Tümörlerin tespiti için genellikle řekilsel, renksel ve dokusal öznitelikler kullanılır. Literatürde bilgisayar görme uygulamalarında öznitelik çıkarım yöntemleri olarak dalgacık dönüşümü katsayılarından elde edilen entropi ve enerji öznitelikleri, Yerel İkili Örüntü (YİÖ) operatörleri, yüksek dereceli gradyanlar, ölçekten baęımsız öznitelik dönüřtürme, Gri Seviye Eř Oluřum Matrisleri (GSEM), Gri Seviye Dizi Uzunluęu Matrisi (GSDUM), Yönlendirilmiş Gradyan Özelliklerinin Histogramı (YGÖH) gibi öznitelikler sıklıkla kullanılmaktadır [16].

Tümörlerin kenarlarının tespiti, tümörün saęlıklı dokulardan doęru bir řekilde ayrılması aęısından önem arz etmektedir. Literatürde genellikle Sobel, Prewitt, Roberts ve Canny kenar çıkarım yöntemleri iře kořulmaktadır [12].

Tümörlü ve tümörsüz beyin MR görüntülerinin veya tümörlerin derecelerini ve türlerinin sınıflandırılması ařamasında Yapay Sinir Aęları (YSA), Destek Vektör Makinalar (DVM), k-En Yakın Komřu (k-EYK), Ařırı Öęrenme Makineleri (AÖM) gibi makine öęrenmesi yöntemleri arařtırmacılar tarafından tercih edilmektedir [17-19].

Literatürdeki bazı çalıřmalar incelenirse [1] nolu çalıřmada tümörlü ve tümörsüz beyin MR görüntülerini sınıflandırmak ve tümörleri tespit etmek amacıyla bir metot önerilmiřtir. İlk olarak beyin MR görüntülerine Ayrık Dalgacık Dönüřümü (ADD) uygulanarak beyin MR görüntüleri ön iřlemden geçirilmiřtir. Daha sonra öniřlemden geçirilen her bir beyin MR görüntüsünden GSEM'e ait Kontrast, Enerji, Homojenlik ve Korelasyon öznitelikleri çıkartılmıřtır. Çıkarılan bu öznitelikler Evriřimsel Sinir Aęlarına (ESA)'ya giriş olarak verilerek tümörlü ve tümörsüz beyin MR görüntülerinin sınıflandırılması saęlanmıřtır. Kullanılan ESA'da aktivasyon fonksiyonu olarak sigmoid fonksiyonu, havuzlama katmanında ise minimum havuzlama operatörü kullanılmıřtır. Son ařama olan tümör tespiti ise morfolojik iřlemlerden açma ve kapama operatörleri kullanılarak yapılmıřtır. Yapılan çalıřmada BRATS 2015 veri seti kullanılmıřtır [20] ve DVM ve ESA'nın sınıflandırma bařarım sonuçları duyarlılık, özgüllük ve doęruluk parametreleri kullanılarak karřılařtırılmıřtır. DVM kullanılarak bu parametreler sırası ile %96.10, %97, %96.90 olarak, ESA kullanılarak ise %97.30, %98.10, %98.70 olarak hesaplanmıřtır.

[2] nolu çalıřmada ilk olarak beyin MR görüntülerini iyileřtirmek amacıyla NonSub Sampled Contourlet Transform (NSCT) kullanılmıřtır. NSCT, Piramit Filtreler ve Yönlü

Filtreler kullanılarak yapılmaktadır. Daha sonra her bir beyin MR görüntüsünden GSEM'e ait kontrast, enerji, homojenlik ve korelasyon öznitelikleri ile Law'ın enerji yasasının dokusal öznitelikleri çıkarılmıştır. Çıkarılan bu öznitelikler ayrı ayrı ve kombine edilerek Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UTBÇS) (Adaptive-Network Based Fuzzy Inference Systems, (ANFIS)), sınıflandırıcısına giriş parametresi olarak verilerek Glioma olan ve olmayan beyin MR görüntüleri sınıflandırılmıştır. Son adım olan tümör tespiti, morfolojik operatörler yardımı ile gerçekleştirilmiştir. Yapılan çalışmada BRATS 2015 [20] veri tabanına ait beyin MR görüntülerinin bulunduğu Training, Leaderboard ve Challenge veri setleri kullanılmıştır. Önerilen yöntemin başarısını belirlemek amacıyla duyarlılık, özgüllük, pozitif tahmin değeri, negatif tahmin değeri, hassasiyet, doğruluk, yanlış pozitif değeri, yanlış negatif değeri parametreleri kullanılmış ve sırası ile ortalama %70.25, %99.71, %85.09, %99.58, %99.30, %82.09, 0.281, 29.73 olarak hesaplanmıştır.

[4] nolu çalışma da, MR görüntülerini Sıvı Zayıflaması İnverson Geri Kazanımı (SZİGK) modalitesinden, normal ve anormal dokular ve bu dokuları çevreleyen bölgeler için otomatik bir beyin dokusu sınıflandırma yöntemi sunulmaktadır. Önerilen bölgesel sınıflandırma metodu, tümörleri aynı anda hem tespit etme hem de piksel seviyesindeki doğruluğa ayırma özelliğine sahiptir. Bu çalışmada ele alınan bölgeye dayalı özellikler istatistiksel, doku histogramları ve fraktal özniteliklerdir. Bu, bölgesel düzeyde sınıf dengesizliği sorununu Rastgele Çoğunluk Aşağı Örnekleme-Sentetik Azınlık Aşırı Örnekleme (RÇA-SAAÖ) tekniği kullanarak ele alan ilk çalışmadır. Önerilen yöntemin performansı, beş standart kıyas ölçütü kullanılarak BRATS 2013 [21] veri setinde değerlendirilmiştir. Önerilen yöntemin sürekli olarak Dice skoru açısından DVM ve Adaboost sınıflandırma yöntemlerine göre daha iyi performans gösterdiğini ve %5 güven aralığında hassasiyet ve özgüllük açısından DVM ve AdaBoost'a kıyasla önemli ölçüde daha iyi sonuçlar elde ettiğini belirtmişlerdir.

[7] nolu çalışmada beyin MR görüntülerinde yer alan tümörlerin iyi huylu ve kötü huylu tümörler olarak sınıflandırılması yapılmıştır. İlk olarak .mha uzantılı beyin MR görüntüleri .jpg uzantılı formata dönüştürülmüştür. Entropi, pürüzsüzlük, basıklık, korelasyon değerleri hesaplanmış ve dalgacık dönüşümü ile elde edilen katsayılar ile birleştirilerek öznitelik vektörü elde edilmiştir. Genetik Algoritma kullanılarak öznitelik vektörünün boyut indirilmesi yapılmıştır. Daha sonra DVM kullanılarak 20 iyi huylu, 5 kötü huylu tümörlü beyin MR görüntüleri ortalama %89.56 doğruluk oranı ile sınıflandırılmıştır.

[8] nolu çalışmada beyin MR görüntülerinin tümörlü ve tümörsüz olarak sınıflandırılması için YSA tabanlı bir yöntem önerilmiştir. İlk olarak 256x256 boyutundaki beyin MR görüntüleri eğitim süresinin daha az sürmesi için 64x64 boyutunda yeniden boyutlandırılmış ve histogram eşitleme yöntemi ile ön işlemden geçirilmiştir. Giriş katmanı, gizli katman ve çıkış katmanından oluşan üç katmanlı ve sırası ile bu katmanlara ait 4096, 35, 2 adet nöron kullanarak ve sigmoid aktivasyon fonksiyonu ile YSA mimarisi inşa edilmiştir. Ön işlemden geçirilen beyin MR görüntülerinden tümörlü görüntüler [1 0], tümörsüz görüntüler ise [0 1] olarak etiketlenerek YSA'nın girişine verilmiştir. 20 görüntü eğitim için 30 görüntü ise test için kullanılmış olup %90 sınıflandırma başarısı elde edilmiştir.

[16] nolu çalışmada beynin MR görüntülerinin tümörlü olup olmadığını kolaylıkla ayırt eden otomatik metod önerilmiştir. Doku bölütlenmesi için farklı teknikler uygulanmıştır. Şekil, doku ve yoğunluk kullanılarak her bir tümör olabilecek dokuya ait öznelikler seçilmiştir. Daha sonra önerilen yöntemin doğruluğunu farklı çapraz doğrulamalarla kıyaslamak için DVM kullanılmıştır. Önerilen yöntem, Harvard [22], RIDER [23] gibi iki temel veri seti üzerinde test edilmiştir. Önerilen yöntemin veri setleri üzerindeki ortalama doğruluk, duyarlılık ve özgüllük parametreleri sırasıyla %97.10, %91.90, %98 olarak hesaplanmıştır.

[24] nolu çalışmada beyin MR görüntülerinden tümör tespiti yapılarak tümörün yatay ve dikey uzunlukları belirlenerek tümörün alanı hesaplanmıştır. İlk olarak beyin MR görüntüleri histogram eşitleme tekniği ile ön işlemden geçirilmiştir. Daha sonra Bilinear Interposyon tekniği ile görüntüler 250x250 boyutunda yeniden boyutlandırılmıştır. 32 bit renk derinliğine sahip beyin MR görüntüleri sekiz bite dönüştürülmüştür. Eşikleme metodu ile manuel eşikleme değerleri test edilerek tümör tespiti yapılmıştır. Elde edilen tümörün genişliği, boyu, alanı gibi geometrik değerler geliştirdikleri yazılım ile piksel cinsinden hesaplanmıştır. Önerilen yöntemde 120 adet beyin MR görüntüsü kullanılmıştır. Önerilen metodun sonucunda elde edilen tümörler *Grand True* görüntüleri ile test edilerek başarımları kriterleri olarak duyarlılık, özgüllük, doğruluk ve benzerlik indeksi kullanılmıştır. Bu değerler sırası ile %88.90, %90, %89.20, %93.02 olarak hesaplanmıştır.

[25] nolu çalışmada tümörlü ve tümörsüz beyin MR görüntülerinin sınıflandırılması ve tümör tespiti yapılmıştır. İlk olarak beyin MR görüntülerinde hastalara ait sıklıkla yer alan yaş, cinsiyet, adı tarih, vb. bilgilerin MR görüntülerinden çıkarılması amaçlanmıştır. Bu amaçla beyin MR görüntüleri 8 bit ile ifade edilerek görüntüye ait piksellerin değerlerinin 0

ile 255 arasında deęer alması saęlanmıřtır. Eřikleme deęeri 255 olarak seęilerek bu deęere denk gelen piksel deęerleri 0 yapılarak ilgili alanlar grntden silinmiřtir. İkinci ařamada beyin MR grntleri Gauss filtreleri kullanılarak n iřlemden geęirilmiřtir. Darwinian Paracak Sr Optimizasyonu (PSO) ile beyin MR grntleri bltlenmiř ve tmr olabilecek ve olmayan yapılar UTBCřS kullanılarak sınıflandırılmıřtır. Yapılan alıřmada 87 adet tmrl beyin MR grnts 14 adet ise tmrsz beyin MR grnts kullanılarak nerilen yntemin sınıflandırma bařarısı %95 olarak hesaplanmıřtır.

[26] nolu alıřmada tmrl ve tmrsz beyin MR grntlerinin sınıflandırılması amalanmıřtır. Veri seti olarak AANLIB veri setine ait [22] aksiyel dzleme ait T2 aęırlıklı olarak 46 adet tmrl 6 adet tmrsz beyin MRG grnts kullanılmıřtır. Grntlere ilk olarak  seviyeli AUB4 dalgacık dnřm uygulanmıř her seviyeden dalgacık katsayıları zellik olarak ıkarılmıřtır. Sınıflandırıcı olarak DVM ve YSA kullanılarak tmrl ve tmrsz beyin MR grntlerinin sınıflandırma bařarıları sırası ile %98 ve %94 olarak hesaplanmıřtır.

[27] nolu alıřmada aksiyel, koronal, saęital dzlemlere ait T1 aęırlıklı beyin MR grntlerinden tmr tespit edilmeye alıřılmıřtır. İlk olarak beyin MR grntleri 8x8'lik bloklara ayrılarak her bir bloęun ortalama, enerji ve entropi deęerleri hesaplanmıřtır. Akabinde her bir grnt iin bu deęerlerin ortalaması alınarak ortalama-eřik, enerji-eřik ve entropi-eřik deęerleri belirlenmiřtir. Beyin MR grntlerinden tmr tespiti bu eřik deęerlere gre yapılarak tmr tespit sonuları sayısal ve grsel olarak sunulmuřtur. nerilen yntemin bařarısı  farklı veri seti kullanılarak test edilmiř ve ortalama duyarlılık, zgllk ve doęruluk oranı sırası ile %90, %94 ve %94 olarak hesaplanmıřtır.

[28] nolu alıřmada beyin MR grntlerinin tmrl ve tmrsz olarak sınıflandırılması ve beyinin yapılarından olan beyaz madde, gri madde ve tmrlerin tespiti yapılmıřtır. Beyin MR grntleri ilk olarak histogram eřitleme iřlemi ve Anisotropic filtreler kullanılarak n iřlemden geęirilmiřtir. Daha sonra her bir grntden GSEM'e ait kontrast, enerji, homojenlik ve korelasyon deęerleri ile Law's enerji zellikleri ıkarılmıřtır. ıkarılan znitelikler birleřtirilerek UTBCřS'ye verilerek beyin MR grntleri %99.30 bařarım oranı ile sınıflandırılmıřtır. Son adımda ise tmrl beyin MR grntlerinden tmr tespiti morfolojik operatrlerden ama ve kapama iřlemi kullanılarak yapılmıřtır. nerilen yntemin tmr tespitinde, gri maddenin ve beyaz maddelerin bltlenmesindeki ortalama doęruluk oranları sırası ile %99.60, %93.54 ve %88.40 olarak hesaplanmıřtır.

[29] nolu çalışmada tümörlü ve tümörsüz beyin MR görüntülerinin sınıflandırılması ile tümörlerin tespiti yapılmıştır. İlk olarak beyin MR görüntüleri Hızlı Ayrık Curvelet dönüşümü kullanılarak ön işlemden geçirilmiştir. Daha sonra ortalama, varyans, basıklık, çarpıklık gibi istatistiksel öznitelikler ve GSEM'e ait dokusal öznitelikler çıkarılmıştır. Daha sonra istatistiki ve dokusal öznitelikler ayrı ayrı ve birleştirilerek DVM ve YSA sınıflandırıcılarına giriş olarak ayrı ayrı verilmiş ve sınıflandırma işlemi yapılmıştır. Daha sonra Bulanık C Ortalamalar (BCO) yöntemi ile tümör tespiti yapılmıştır. Önerilen yöntemin doğruluk oranı %99.47 olarak hesaplanmıştır.

[30] nolu çalışmada, çok sekanslı beyin MR görüntü veri setlerini kullanarak beyin tümörü tespiti için otomatik bir yöntem geliştirilmiştir. Önerilen yöntem üç aşamadan oluşmaktadır: tümör dilimi tespiti, tümör çıkarımı ve tümör alt yapılarının bölütlenmesidir. Birinci aşamada, öznitelik blokları ve DVM sınıflandırıcısı MR dilimlerini tümörlü veya tümörsüz olarak sınıflandırmak için kullanılmaktadır. İkinci aşamada, tümör bölgesini belirtilen dilimlerden çıkarmak için BCO algoritmasını içermektedir. Üçüncü aşama için, tümör alt yapılarını histogram kutularının olasılık yoğunluğu değerine göre bölütlemek için yeni bir Olasılıksal Yerel Üçlü Örüntü (OYÜÖ) tekniği kullanılmaktadır. Duyarlılık, özgüllük, doğruluk ve zar değerleri gibi niceliksel ölçüler, önerilen yöntemin performansını analiz etmek ve son teknolojik yöntemlerle karşılaştırmak için kullanılmaktadır. İşlem sonrası, tümörün doğasını ve yerini tıbbi uzmanlara analiz etmek için tümör hacmi tahmini ve 3 Boyut (3B) görselleştirme yapılmıştır.

[31] nolu çalışmada, beyin MR görüntülerinin tümörlü ve tümörsüz olarak sınıflandırılması ile beyin tümörleri tespit edilmeye çalışılmıştır. Önerilen yöntem, ön işlem, pencereleme, öznitelik çıkarımı, öznitelik vektörlerinin boyutlarının indirgenmesi, ve sınıflandırma işlemleri olarak beş temel adımdan oluşmaktadır. Histogram eşitleme yöntemi ile beyin MR görüntüleri ön işlemden geçirilmiştir. Daha sonra pencereleme yöntemi ile tümör olabilecek alanlar tespit edilmiştir. İki farklı öznitelik vektörü oluşturulmuştur. İlk öznitelik vektörü Gabor dalgacık dönüşümü kullanılarak elde edilen Gabor dalgacık özniteliklerini içerirken, ikinci öznitelik vektörü GSEM, GSDUM, HOG ve YiÖ gibi farklı doku bazlı öznitelik çıkarma teknikleri kullanılarak elde edilen istatistiksel özniteliklerden oluşmaktadır. Çıkarılan öznitelik vektörleri kullanılarak DVM, k En Yakın Komşu ve En Yakın Alt Uzay Sınıflandırıcılar ile T1 ve Flair ağırlıklı beyin MR görüntüleri tümörlü ve tümörsüz olarak sınıflandırılmıştır.

[32] nolu çalışmada beyin MR görüntülerinde yer alan tümörlerin tespiti ve tümörlerin iyi huylu ve kötü huylu olarak sınıflandırılması yapılmıştır. Beyin MR görüntüleri ilk olarak Anisotropik filtreleme ön işleminden geçirilmiştir. Daha sonra GSEM karesine ait kontrast, enerji, homojen ve korelasyon öznitelikleri ile dalgacık dönüşüm öznitelikleri ve Law'ın enerji öznitelikleri kullanılarak öznitelik vektörleri oluşturulmuştur. UTBCS ile beyin MR görüntüleri sınıflandırılmıştır. Tümör olabilecek yapılar bölge büyütme yöntemi ve morfolojik işlemler ile tespit edilmiştir. Veri seti olarak [33]' den alınan beyin MR görüntüleri kullanılmıştır. Önerilen yöntemin performansı benzerlik indeksi, örtüşme oranı, kesir oranı ve pozitif tahmin değerleri ile yapılmış olup bu değerler sırası ile %0.81, %0.81, %0.18 ve %0.81 olarak hesaplanmıştır.

[34] nolu çalışmada BRATS 2013 veri setinde [21] yer alan beyin MR görüntüleri kullanılarak beyin tümörleri tespit edilmeye çalışılmıştır. İlk olarak beyin MR görüntüleri 3x3 boyutunda medyan filtre kullanılarak ön işleminden geçirilmiştir. Daha sonra eşik değerler ile eşikleme işlemi yapılmıştır. Tümör olabilecek yapılar daha sonra açma ve kapama gibi morfolojik işlemler ile belirgin hale getirilmiştir. İlgili yapılardan YİÖ kullanılarak 256 adet öznitelik ve GSEM'e ait 13 farklı uzaklık mesafesi ve yönlendirme açısından entropi, enerji, homojenlik, kontrast değerleri hesaplanarak 52 adet öznitelik çıkarılmıştır. Bu öznitelikler kullanılarak Rastgele Orman (RO) sınıflandırıcısı ile tümör olabilecek yapılar tespit edilmiştir. Önerilen yöntemin tümör tespitindeki performansını değerlendirmek için Dice benzerlik indeks değeri ve Jaccard benzerlik indeks değeri kullanılmış olup bu değerler sırası ile 0.96 ± 0.01 , 0.93 ± 0.02 olarak hesaplanmıştır.

[35] nolu çalışmada Kırmızı Yeşil Mavi (KYM) renk uzayında yer alan beyin MR görüntüleri ilk olarak Renk Özü, Doygunluk ve Parlaklık (RDP) renk uzayına dönüştürülmüştür. Daha sonra histogram eşitleme yöntemi ile beyin MR görüntüleri ön işleminden geçirilmiştir. Watershed bölütleme yöntemi kullanılarak görüntü alt bileşenlere ayrıldıktan sonra eşik değer ile eşikleme işlemi yapılmıştır. Daha sonra Canny kenar tespiti operatörü ile tümörlerin kenarları tespit edilmiştir.

[36] nolu çalışmada beyin MR görüntülerinden tümör tespit edilmeye çalışılmıştır. İlk olarak 7x7 filtre boyutlarında medyan filtre ile görüntüler ön işleminden geçirilmiştir. Otsu bölütleme tekniği ile beyin MR görüntüleri bölütlenerek alt bileşenlerine ayrılmıştır. Daha sonra tümör olabilecek olan yapılar etiketlenerek her bir yapıdan alan, dairesellik, yuvarlaklık

ve çap değerleri hesaplanmıştır. Kontrollü sınıflandırma ile tümör olabilecek yapılar %92.50 doğruluk oranı ile tespit edilmiştir.

[37] nolu çalışmada, T1 ağırlıklı beyin MR görüntülerinden beyin tümörleri tespit edilmeye ve sınıflandırılmaya çalışılmıştır. İlk olarak beyin MR görüntüleri histogram eşitleme yöntemi ile ön işlemden geçirilmiştir. Daha sonra GSEM'e ait on yedi farklı öznelik çıkarılmıştır. Temel Bileşen Analizi (TBA) ile özellik vektörlerinin boyutları indirgenmiştir. Kendini Düzenleyen Haritalar (KDH) kümeleme tekniği ile %89 doğruluk oranı ile tümörler tespit edilmiş ve DVM kullanılarak tümörler %92 doğruluk oranı ile iyi huylu ve kötü huylu olarak sınıflandırılmıştır.

Diğer taraftan günümüzde hayli popüler olan derin öğrenme tabanlı yaklaşımlar da son yıllarda tümörlerin tespit edilmesi ve sınıflandırılması amacıyla kullanılmaya başlanmıştır. Derin öğrenme tabanlı yaklaşımlarda herhangi bir öznelik çıkarımına ve sınıflandırıcıya ihtiyaç duyulmaz. Öznelik çıkarımı ve sınıflandırma aynı derin mimaride birlikte bulunurlar. Fakat derin öğrenmede de en büyük zorluk çok sayıda veriye ihtiyaç duyulmasıdır. Ayrıca hesaplama yükü de oldukça ağırdır. Derin öğrenme tabanlı tümör tespiti ve sınıflandırılması için literatürde yer alan çalışmalardan;

[38] nolu çalışmada, öğrenilen hiyerarşik özelliklerin kalitesini artırmak için bir dizi yaklaşım önerilmektedir. İlk olarak, daha hassas bölütleme için çok seviyeli bilgiden faydalanmak amacıyla popüler DeepMedic modeli Multi-Level DeepMedic olarak genişletilmiştir. İkinci olarak, derin modellerden öğrenilen çok seviyeli özelliklerin kalitesini artırmak için yeni bir çift kuvvetli eğitim programı önerilmektedir. Üçüncüsü, derin modellerin üst düzey katmanlarını daha soyut bilgiler öğrenmeye teşvik etmek için yardımcı bir sınıflandırıcı olarak etiket dağılımına dayalı bir kayıp fonksiyon tasarlanmıştır. Son olarak, derin modellerin tahmin sonuçlarını geliştirmek için yeni bir Çok Katmanlı Algılayıcı tabanlı yaklaşım önerilmiştir. BRATS 2017 [39] ve BRATS 2015 [20] veri setleri kullanılarak önerilen yöntemin performansı değerlendirilmiştir.

[40] nolu çalışmada beyin MR görüntülerinden tümör tespiti ve tümörlerin sınıflandırılması yapılmıştır. [22] veri setinde Glioblastoma, Sarcoma, Metastatic bronchogenic carcinoma türlerinde tümörlü beyin MR görüntüleri yer almaktadır. Beyin MR görüntüleri ilk olarak BCO yöntemi ile bölütlenmiştir. Daha sonra ADD kullanılarak özellik çıkarımı yapılmış ve TBA ile çıkarılan öznelik vektörünün boyutu indirgenmiştir. Derin Sinir Ağı (DSA) ile sınıflandırma işlemi yapılmıştır. DSA, birçok alanda başarılı bir şekilde

sınıflandırma veya regresyon için yaygın olarak kullanılan derin öğrenme mimarisidir. Tümörleri sınıflandırma da farklı sınıflandırıcıların performansı DSA ile karşılaştırılmıştır. DSA, k-en yakın komşu (k=1, k=3), Doğrusal Ayırt Edici (DAE) analizinin sınıflandırma performansı sırası ile %96.47, %95.45, %86.36, %95.45 olarak hesaplanmıştır.

[41] nolu çalışmada, tümörlü ve tümörsüz beyin MR görüntülerini otomatik olarak sınıflandırmak için derin transfer öğrenmeyi kullanan bir yaklaşım önerilmiştir. Veri setinde normal beyin MR görüntüleri ile glioma-meningiom tümörleri, atak, Alzheimer vb. rahatsızlıkların yer aldığı beyin MR görüntüleri bulunmaktadır. Beyin MR görüntülerinin sınıflandırılmasında mevcut derin öğrenme tekniklerinden olan U-Net mimarisi kullanılmıştır. Önerilen mimari, 613 beyin MR görüntülerinde test edilmiş ve beşli çapraz geçerlilik testi sonucunda %100 sınıflandırma doğruluğu elde edilmiştir.

[42] nolu çalışmada glioma, meningioma ve hipofiz tümörlerinin yer aldığı beyin MR görüntülerinin sınıflandırılması ve beyin tümörleri tespit edilmeye çalışılmıştır. Çalışmada veri setinde [43] tümör seviyelerinin yer aldığı 121 adet beyin MR görüntüleri ve [33]'de yer alan T1 ağırlıklı 512x512 boyutlu 3064 adet beyin MR görüntüsü kullanılmıştır. Önerilen çalışmada ilk olarak InputCascadeCNN derin öğrenme tekniği ile tümör bölütlemesi yapılmıştır. Daha sonra beyin MR görüntülerinin sayısı, farklı açılarda döndürülmesi, Gauss gürültü eklenmesi yaklaşımı gibi sekiz farklı yöntem ile artırılmıştır. Beyin MR görüntülerini sınıflandırılması işlemi ise önceden eğitilmiş VGG19 mimarisi ile yapılmıştır. VGG19 derin öğrenme mimarisinin radiopedia veri setindeki [43] görüntülerin artırılması ile oluşan beyin MR görüntülerini sınıflandırma performansı, doğruluk, duyarlılık ve seçicilik değerleri için sırası ile %90.67, %88.41, %96.12, %90.67 olarak [33] veri setinde ise [44] %94.58, %88.41, %96.12 olarak hesaplanmıştır.

[45] nolu çalışmada beyin MR görüntülerinden ESA yardımıyla tümör tespit edilmeye çalışılmıştır. İlk olarak görüntüleri oluşturan her pikselden ortalama piksel değeri çıkarılarak ve daha sonra hesaplanan değerlerin standart sapma değerine bölünmesiyle beyin MR görüntüleri ön işlemden geçirilmiştir. Daha sonra beyin MR görüntülerinde beyni oluşturan gri madde, beyaz madde ve tümöre ait yapılar etiketlenerek her bir yapıya ait ESA mimarisi ile öznetelik çıkarımı yapılmıştır. [39] veri seti kullanılarak önerilen yöntemin tümör tespitindeki başarımı Dice benzerlik indeksine göre yapılmış olup 0.86 olarak hesaplanmıştır.

[46] nolu çalışmada beyin MR görüntülerinden tümör tespit edilmeye çalışılmıştır. Giriş verilerinin dört kanallı yani, (T1, T1c, T2, FLAIR) 3 boyutlu sekansların olduğu sıralı

bir 3B-ESA modeli kullanmışlardır. Ayrıca, ESA modellerinden bilindiği gibi, havuz katmanlarını kullanmamışlardır. Ek olarak, bir işlem sonrası adım kullanarak 3000 vokselin altındaki tüm bölgeler çıkarılmıştır. Önerilen yöntemin GPU uygulamasını kullanarak tüm beyni bileşenlerine ayırması işleminin yaklaşık bir dakika sürdüğünü bildirmişlerdir.

[47] nolu çalışmada beyin görüntülerinin bölütlenmesi için ESA mimarisi kullanılmıştır. Ağın giriş verileri 32×32 boyutlu gri seviye görüntüleridir. ESA mimarisi iki paralel yola ayrılmıştır; ilk yol klasik bir ESA mimarisidir (yani, evrişim ve havuzlama katmanları sonucu oluşan özellik haritalarıdır), ikinci yol ise tamamen bağlı katmana görüntünün doğrudan verilmesidir. Daha sonra bu iki yoldan gelen öznitelikler birleştirilerek bir softmax katmanına verilerek tümör tespiti yapılmıştır. Ayrıca, bu modelin GPU kullanarak tüm beyni yirmi dakika bölütlediğini rapor etmişlerdir.

[48] nolu çalışmada beyin MG görüntülerinden derin öğrenme tabanlı tümör tespit edilmeye çalışılmıştır. Öncelikle beyin MR görüntüleri farklı boyutlardaki ortalama filtreler ile ön işlemde geçirilmiştir. Daha sonra tümör olabilecek yapılar kutu içerisine alınarak etiketlenmiştir. Etiketlenen bölgeler AlexNet mimarisine giriş olarak verilerek tümöre ait bilgilerin öğrenilmesi işlemi gerçekleştirilmiştir. Önerilen yöntem [39] alınan beyin MR görüntüleri üzerinde test edilmiş olup malignant, benign, glial gibi tümörleri doğru tespit etmedeki doğrulukları sırası ile %99, %100, %99 olarak hesaplanmıştır.

[49] nolu çalışmada beyin MRG görüntülerinde bulunan Glioblastoma tümörlerinin tespiti ve sınıflandırması yapılmıştır. İlk olarak görüntüler ön işlemden geçirilmiştir. Daha sonra görüntüler ESA mimarisine verilerek tümör olabilecek yapılar tespit edilmeye çalışılmıştır. Tümörlere ait ortalama, standart sapma, entropi, varyans, basıklık, çarpıklık, homojenlik, kontrast, korelasyon gibi öznitelikler çıkarılarak DVM ile bu öznitelikler Glioblastoma tümörlerinin seviyelerine göre sınıflandırılmıştır. Önerilen yöntemin performans değerlendirmesi için pozitif tahmin değeri ve duyarlılık parametreleri kullanılmış olup sırası ile %99.41 ve %96.54 olarak hesaplanmıştır.

1.1. Önerilen Sistemin Genel Çerçevesi

1.1.1. Tezin Amacı

MRG'ler çok yönlü ve büyük hacimli 3B taramalardır; bu nedenle uzmanlar tarafından tümörlerin tespiti zaman alıcı ve meşakkatli bir işdir. İlk olarak, tümörlerin şekli ve içyapıları

değişken ve karmaşıktır. İkincisi, tümörü çevreleyen normal dokular, tümörlerin değişken lokasyonları ve sözde kitle etkisi nedeniyle çok çeşitli görünümde olabilmektedir.

Beyin MR görüntülerinden otomatik beyin tümör tespiti, çeşitli disiplinleri içeren zor bir iştir. Beyin tümörü bölütlenmesi ile ilgili birçok sorun ve zorluk mevcuttur. Beyin tümörleri herhangi bir boyutta ve çeşitli şekillerde olabilir, herhangi bir yerde ve farklı görüntü yoğunluklarında görünebilir. Bazı tümörler ayrıca diğer yapıları deforme eder ve yakındaki bölgenin yoğunluk özelliklerini değiştiren ödemle birlikte ortaya çıkar. Dahası normal dokular ve tümör dokular arasındaki sınırlar belirsiz olma eğilimindedir ve bu nedenle ayırt edilebilmeleri zordur ve ayrıca elle bölütlemeler, karar vericilerin kişisel deneyiminden etkilenebilir; dolayısıyla hata durumu söz konusudur.

Bu nedenle, beyin tümörü tespiti için tam otomatik ve doğru sistemlere pratikte ihtiyaç duyulmaktadır. Bu tez çalışmasının amacı beyin tümörünün tespitini ve türünü doğru ve hızlı bir şekilde gerçekleştirebilecek BDOTS'ların tasarlanmasıdır. Önerilen BDOTS'lar, farklı öznelilik çıkarma yöntemi ve sınıflandırıcı tabanlıdır. Tez kapsamında önerilen BDOTS ile uzmanların iş yükü hafifleyecek ve uzmanlar tümör tespit ve sınıflandırma işlemini daha hızlı gerçekleştireceklerdir.

1.1.2. Tezin Gerekçeleri

- DSÖ raporlarına göre beyin tümörlerinden etkilenen insanların sayısının her yıl artması.
- Alanında uzman kişilerin sayılarının yetersizliği,
- Tümörlerin tespit ve teşhisinin erken dönemde, hızlı ve doğru yapılmasının hasta sağlığı açısından önemli olması,
- Tümörlerin sürekli olarak değişik formlarda hastalarda görünmesinden dolayı sürekli olarak yeni BDOTS'ların tasarlanmasının gerekliliği,
- Literatüre sürekli olarak yeni makine öğrenmesi ve görüntü işleme yöntemlerinin eklenmesinden dolayı bu yöntemlerin BDOTS'larda hız, doğruluk ve verimlilik açısından değerlendirilme isteği.

1.1.3. Tezin Çıktıları

Makine öğrenmesi ve görüntü işleme teknikleri ile farklı BDOTS'lar tasarlanmıştır. BDOTS'lar ile tümörler gerçek değerlerine uygun şekilde tespit edilmeye çalışılmıştır. Ayrıca

tümörler iyi ve kötü huylu olmaları ve derecelerine göre BDOTS'lar ile sınıflandırılmıştır. Bu sayede uzmanlar tümörlerin boyutları, şekilleri, hacimleri, türleri gibi birçok bilgiye BDOTS'lar sayesinde daha hızlı ulaşarak uzmanların hızlı ve doğru verebilmeleri sağlanmıştır.

Tez kapsamında yapılan ve SCI kapsamındaki dergilerde yayınlanan makaleler:

- ARI ve D. Hanbay, “Bölgesel Evrişimsel Sinir Ağları Tabanlı MR Görüntülerinde Tümör Tespiti”, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Derg.*, c. 2018, sayı 18–2, ss. 1395–1408, 2018.
- Ari ve D. Hanbay, “Deep learning based brain tumor classification and detection system”, *Turkish J. Electr. Eng. Comput. Sci.*, c. 26, sayı 5, ss. 2275–2286, 2018.

Tez kapsamında yapılan ve alan indeksi kapsamındaki dergilerde yayınlanan makaleler:

- A. Ari ve D. Hanbay, “An Expert Systems for Brain MR Images Classification by Using Ensemble Neural Network”, *Bilgisayar Bilimleri Dergisi*, sayı 2, ss. 44–56, 2018.

Uluslararası sempozyumlarda yayınlanan bildiriler:

- Ari A, Alpaslan N, Hanbay D, “Computer-aided tumor detection system using brain MR images”, Tıp Teknolojileri Ulusal Kongresi (TIPTEKNO'15), 1-4, 2015, Bodrum, Turkey.
- Ari A, Hanbay D, “Detection of Brain Tumor from the MR Images by Using Hybrid Features”, International Conference on Natural Science and Engineering (ICNASE'16), 2016, Kilis, Türkiye.
- Ari A, Hanbay D, “MR Görüntülerinden Aşırı Öğrenme Makinesi Tabanlı Tümör Tespiti”, IMESET international Conference, 226, 2017, Bitlis, Türkiye.

1.1.4. Tezin Yenilikçi Yönü ve Ar-Ge Niteliği

Tez çalışmasında tasarlanan BDOTS'lar literatürde sıklıkla kullanılan veri tabanlarında test edilerek önerilen diğer yöntemler ile performansları karşılaştırılmıştır. Var olan birçok yöntemden daha başarılı sonuçlar elde edildiği gözlemlenmiştir. Tasarlanan BDOTS'lerin birçok farklı veri seti ile test edilmesi ve farklı performans kriterleri ile değerlendirilmesi sonucunda elde edilen değerler tasarlanan sistemlerin yüksek doğrulukta çalıştığını ve güvenilir olduğunu göstermektedir.

1.1.5. Tezin Organizasyonu

Bölüm 2'de beyin tümörlerinin tespiti ve sınıflandırılması amacıyla yapılan temel adımlar ve bu adımlarda kullanılan yöntem ve teknikler detaylı biçimde anlatılmıştır.

Bölüm 3'de derin öğrenme kavramından bahsedilerek derin öğrenme mimarileri anlatılmıştır.

Bölüm 4'de tez kapsamında tasarlanan BDOTS'lar tanıtılarak deneysel sonuçlar sunulmuştur.

Bölüm 5'de tez çalışmalarından elde edilen sonuçlar tartışılmıştır. Ayrıca elde edilen kazanımlar ve gelecekte yapılması planlanan çalışmalar hakkında bilgilere ve önerilere yer verilmiştir.

2. BEYİN TÜMÖRLERİNİN TESPİTİ VE SINIFLANDIRILMASI

Görüntü işleme ve makine öğrenmesi temelli tümör tespiti için önerilen yöntemler genellikle altı temel adımdan oluşur. Bunlar; ön işlemler, bölütleme, öznelik çıkarımı, öznelik vektörlerinin boyut indirgenmesi, kenar tespiti ve sınıflandırmadır. Bu bölümde altı temel adıma ait literatürde yer alan ve bu tez çalışmasında kullanılan yöntemler açıklanmıştır.

2.1. Ön İşlem

Beyin MRG veya BT çekimleri esnasında elde edilen görüntüler çeşitli gürültü kaynaklarından etkilenebilir. Uzmanlar, anormal ve normal dokular arasında var olan küçük farkları gürültü ile karıştırılabilir ve görüntüleri yorumlamada hata yapabilir. Ayrıca olabilecek gürültüler yanlış yoğunluk düzeylerine neden olur ve tasarlanan BDOTS'ların başarımını olumsuz etkiler. Bu yüzden beyin görüntüleri ön işleme tabi tutularak olabilecek gürültülerin kaldırılması gerekmektedir. Bu amaçla, doğrusal, doğrusal olmayan, sabit, uyarlanabilir, piksel tabanlı gibi çok çeşitli ön işleme teknikleri, farklı durumlar için uygulanabilir [44,45]. Literatürde ön işlem amacıyla Alçak geçiren filtre, Orta değer filtre, Gabor filtresi, Gauss filtresi, Normalizasyon, Histogram eşitleme, Eşyönsüz Yayınım Filtresi, Weiner Filtresi gibi yöntemler sıklıkla kullanılmaktadır [44,45]. Bu tez çalışmasında, orta değer filtresi, gauss filtresi, adaptif filtreler ve histogram germe ve eşitleme yöntemleri ile görüntüler ön işleminden geçirilmiştir.

Ayrıca ön işlem aşamasında beyin MR ve BT görüntülerinde yer alabilen hasta adı, tarih, saat gibi gereksiz kısımlar çıkarılmakta, görüntüdeki piksel değerlerinin belirli bir kontrast aralığında olması sağlanmalıdır. Bu amaçla beyin MR görüntüleri 8 bit ile ifade edilerek görüntüye ait piksellerin değerleri 0 ile 255 arasında değer alması sağlanmıştır. Eşikleme değeri 255 olarak seçilerek bu değere denk gelen piksel değerleri 0 yapılarak ilgili alanlar görüntüden silinmiştir.

2.1.1. Orta Değer Filtresi

Medyan filtreler doğrusal olmayan uzaysal filtrelerdir. Maskeyi oluşturan $m \times n$ boyuttaki görüntü piksel değerlerinin küçükten büyüğe doğru sıralanarak ortadaki değerlerin merkez piksel değerine atanmasıdır.

2.1.2. Gauss Filtresi

Gauss operatörü, ayrıntı ve gürültüyü ortadan kaldırmak için kullanılan 2 boyutlu evrişim (çekirdek matris ile resim üzerindeki piksellerin çarpımı işlemi) operatörüdür. Gauss'un çan şeklindeki grafiğini veren formül 2 boyutlu düzlem ve 3 boyutlu uzay için yazılırsa Denklem (2.1)'deki şekilde gösterilebilir [51]. Denklem (2.1)'de $G(x, y)$ Gauss filtresini, σ ise Gauss dağılımının standart sapmasını temsil etmektedir.

$$G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.1)$$

2.1.3. Adaptif Filtreler

Adaptif Filtreler maskesi altında gri ton değerlerine göre özelliklerini değiştirebilen filtre sınıfındandır. Bu filtreler görüntü içinde buldukları yere bağlı olarak orta değer filtre veya ortalama filtreler gibi hareket edebilirler. Filtre davranışının temel kriteri yerel karakteristiklerdir ve genelde yerel gri seviyesi istatistikleri ile ölçülürler [52].

Minimum Hataların Karelerinin Ortalaması (MHKO) adaptif filtrelere uygun bir örnektir ve doğrusal değildir. Bu filtre yerel görüntü istatistiklerine göre değişim göstermektedir. MHKO filtresi en iyi sonuçlarını gauss ve uniform gürültülerde vermektedir. Denklem (2.2)'de MHKO'nun fazla kullanılan bir versiyonunun bağıntısı verilmektedir [52].

$$MHKO = d(r, c) - \frac{\sigma_n^2}{\sigma_l^2} [d(r, c) - m_l(r, c)] \quad (2.2)$$

σ_n^2 = Gürültü değişimi (Gürültü varyansı)

σ_l^2 = Yerel Değişim

m_l = Yerel ortalama

$d(r, c)$ = Orijinal görüntü

2.1.4. Histogram Germe

Gürültü etkisinin minimize edilmesi için histogram germe işlemi uygulanmıştır. Histogram germe işlemi, histogram eşitlemeye benzer bir işlevi yerine getirir. Histogram germe işleminde, histogram daha geniş bir alana yayılır. Böylece renk seviyelerinin aralığı genişlediğinden MR görüntülerinin analizi daha iyi yapılabilir [10]. Histogram germe işlemi Denklem (2.3)'deki eşitliğe göre yapılır.

$$x_{yeni} = (A - B) \frac{x_{eski} - a}{b - a} + B \quad (2,3)$$

Denklem (2.3)'de verilen a değışkeni, görüntü içerisindeki en küçük gri-ton değeri, b ise en büyük gri-ton değeri sırası ile göstermektedir. Histogram eğrisini 0–255 gri-ton değeri arasına germek için $A=255$ ve $B=0$ olarak seçilmelidir [10].

2.2. Bölütleme

Beyin birçok doku ve yapıdan oluşmasından dolayı uzmanlar için tümörlerin beyin görüntülerinden tespit edilmesi oldukça zor bir iştir. Bu yüzden beyin tümörlerinin tespitinde beyin görüntülerinin doğru olarak bölütlenmesi önem arz etmektedir. Literatüre beyin bölütlenmesi için birçok yöntem sunulmuştur. Literatürde beyin bölütleme ile ilgili önerilen yöntemleri altı başlıkta kategorize edilebilir. İlk kategori başlığı şekil ve kontür tabanlı (Deforme edilebilir modeller [53], Aktif konturler [54], Seviye setleri [55], Atlas tabanlı [56]) bölütleme teknikleridir. İkinci kategori başlığı bölge tabanlı (Eşikleme [57], Kenar Tabanlı [57], Watershed [58], Çekirdek Bölge[59]) bölütleme teknikleridir. Üçüncü kategori istatistiksel tabanlı (Beklenti maksimizasyonu [60], Markov Rastgele Alanı [61], Gauss Karışım Modeli [62]) bölütleme teknikleridir. Dördüncü kategori başlığı çoklu çözünürlüklü (Ayrık Dalgacık Dönüşüm [32]) bölütleme teknikleridir. Beşinci kategori makine öğrenmesi tabanlı (Yapay Sinir Ağları [63], Destek Vektör Makineleri [64], Karar Ağaçları [54], k- en yakın komşu [65], Bulanık C ortalamalar [66], k-ortalama [67], öz düzenleyici haritalar [68]) bölütleme teknikleridir. Son kategori ise yapay zeka metotlarının birleştirilerek kullanıldığı (Stanlet Dönüşümü + BCO [58], Nöro Bulanık Yaklaşımlar [44], Seviye Seti + Yapay sinir ağları [68]) bölütleme teknikleridir.

2.2.1. Eşikleme

Eşikleme, görüntü bölütleme işlemlerinde sıklıkla kullanılmaktadır. Eşikleme işleminde amaç görüntü içerisindeki nesnelere, görüntü arka planından ayırmaktır. Eşikleme için, görüntüdeki gri seviye dağılımlarını gösteren görüntü histogramından faydalanılır. Bu histograma göre, arka plan ve nesnelere iki grup olarak düşünülebilir. Bu durumda nesnelere arka plandan ayırmak için en kolay yol, histogramdan göreceli olarak belirlenen bir T eşik değeri ile görüntüdeki piksel değerlerini karşılaştırmak olacaktır. Buna göre, görüntüdeki herhangi bir piksel değeri eşik değerden büyük ise nesneye ait bir nokta küçük veya eşit ise arka plana ait bir nokta olacaktır.

2.2.2. Otsu Bölütleme

Otsu'nun ikili eşikleme yöntemi, görüntü eşikleme alanında yapılan ilk çalışmalardan biri olan ve Otsu (1979) tarafından önerilen topaklamaya dayalı eşikleme yöntemidir [69]. Otsu yönteminde gri seviye görüntüler üzerinde çalışmakta ve sadece renklerin görüntü üzerinde bulunma sıklığına bakmaktadır [70]. Güçlü ve stabil bir yöntem olması sebebiyle görüntü eşikleme alanında gerçekleştirilen çalışmalarda referans olarak alınmakta ve kullanılmaktadır [71].

Otsu görüntü üzerinde iki ayrı sınıf olduğunu kabul ederek, bu iki sınıf arasındaki varyansı maksimum yapacak değeri bulmaya çalışır. Varyans ortalamasının etrafındaki yoğunluk değişimlerini gösterir [69-71].

Denklem (2.4)'de N uzunluklu dizi için varyans hesaplama formülü verilmiştir. $P(x)$ ifadesi x_i 'nin gelme olasılığıdır. Düzgün dağılımlı N uzunluklu bir dizi için bu değer $1/N$ dir. $M \times N$ boyutlu bir görüntü için histogram dizisi hesaplandıktan sonra i tonunun gelme olasılığı $histogram[i]/(M \times N)$ 'dir [69-71]. Sınıflar arası varyans Denklem (2.5)'deki gibi hesaplanır.

$$\sigma^2 = \sum_{i=0}^{N-1} (x_i - \bar{x}) P(x_i) \quad (2.4)$$

$$\sigma_s(t) = \sigma - \sigma_b(t) = w_1(t) * w_2(t) (\mu_1(t) - \mu_2(t)) \quad (2.5)$$

$$w_1(t) = \sum_0^t P(i) \quad w_2(t) = \sum_{t+1}^{255} P(i) \quad (2.6)$$

$$\mu_1(t) = \sum_0^t P(i) x_i \quad (2.7)$$

$$\mu_2(t) = \sum_{t+1}^{255} P(i) x_i \quad (2.8)$$

Denklem (2.5-2.8)'de w : sınıfların olma olasılığını, μ : sınıf ortalamalarını ifade etmektedir. x_i , i . renk seviyesini belirtmektedir.

2.2.3. Havza Bölütleme

Vincent ve Soille tarafından önerilen havza bölütleme tekniği [71] görüntü üzerindeki nesnenin topolojik yapısını kullanarak, gri seviye değerler ile işlem yapar ve nesnenin sınırlarını belirler. Görüntü, vadi ve dağları içeren topoğrafik bir yüzey olarak değerlendirilir. Bölgesel minimumdaki noktalar, toplama havuzundaki noktalar ve havza kenarındaki noktalar olarak üç farklı bölge arasındaki yoğunluk geçişlerine göre görüntü segmente edilir.

2.3. Öznitelik Çıkarımı

Öznitelik, bir nesneyi karakterize edebilen ayırt edici niteliklerdir. Tümör dokusunun yeri, büyüklüğü, şekli ve dokusundaki geniş çeşitlilikten dolayı öznitelik çıkarımının etkin ve amaca uygun yapılması tümörlerin tespiti ve sınıflandırması için hayati öneme sahiptir. Literatürde genellikle öznitelikler çıkarımı için istatistiksel, dokusal ve renksel öznitelikler belirlenmeye çalışılmıştır.

2.3.1. İstatistik Temelli Özellik Çıkarım Teknikleri

Ortalama, varyans, ortalama kontrast, enerji, entropi, çarpıklık ve basıklık birinci dereceden faydalı istatistiksel özelliklerdir. *Ortalama*, görüntü yoğunluğunun ortalama değeridir. *Varyans*, ortalamanın etrafındaki yoğunluk değişimlerini gösterir. *Çarpıklık*, ortalamanın etrafındaki histogramın asimetrisini belirler. *Basıklık*, histogramın düzlüğüdür. *Entropi*, yoğunluk değerlerinin rastgele durumunu ortaya koymaktadır. Bu özelliklere ait denklemler Denklem (2.9–2.14)'deki gibi listelenmiştir [16].

$$\text{Ortalama: } \mu = \sum_{i=0}^{G-1} iP(i) \quad (2.9)$$

$$\text{Ortalama Kontrast: } \sigma^2 = \sum_{i=0}^{G-1} (i - \mu)^2 P(i) \quad (2.10)$$

$$\text{Çarpıklık: } \mu_3 = \sigma^{-3} \sum_{i=0}^{G-1} (i - \mu)^3 P(i) \quad (2.11)$$

$$\text{Basıklık: } \mu_4 = \sigma^{-4} \sum_{i=0}^{G-1} (i - \mu)^4 P(i) - 3 \quad (2.12)$$

$$\text{Enerji: } E = \sum_{i=0}^{G-1} [P(i)]^2 \quad (2.13)$$

$$\text{Entropi: } H = - \sum_{i=0}^{G-1} P(i) \log_2 [P(i)] \quad (2.14)$$

Denklem (2.9–2.14) arasında ifade edilen G, görüntünün maksimum gri seviyesidir. P(i) ise elde edilen yoğunluk seviyelerinin olasılık yoğunluğudur ve Denklem (2.15)'den elde edilir.

$$P(i) = h(i) / N \quad (2.15)$$

Denklem (2.15)'de h(i), (i) yoğunluk seviyesindeki toplam piksel sayısıdır ve N, görüntüdeki toplam piksel sayısını ifade eder.

2.3.2. Doku Temelli Öznitelik Çıkarım Teknikleri

Doku, desen ya da desenlerin belirli bir bölge üzerinde tekrarlanmasıdır. Bu desenler nitelik bakımından ince, kaba, pürüzsüz, rasgele ya da çizgili gibi değişik özelliklerde olabilirler [72]. Doku özellikleri ikinci dereceden bir istatistik türüdür ve pikseller arasındaki gri seviyesi farklılıklarını belirtir.

2.3.2.1. Gabor Dalgacık Öznitelikleri


Gabor dalgacıklar, uzamsal frekansa (ölçekler), uzamsal lokalizasyona ve yönelim seçiciliğine karşılık gelen görüntünün yerel yapısını yakalar [73]. Bu nedenle, doku analizi ve görüntü segmentasyonu dahil birçok araştırma alanına yoğun olarak uygulanırlar. Uzamsal alanda, iki boyutlu bir Gabor filtresi, karmaşık bir sinüzoidal düzlem dalgası tarafından modüle edilmiş bir Gauss çekirdek işlevidir ve Denklem (2.16)'daki şekilde tanımlanır:

$$G(x, y) = \frac{f^2}{\pi\gamma\eta} \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp(j2\pi f x' + \phi) \quad (2.16)$$

Burada x' ve y' aşağıdaki şekilde ifade edilir:

$$\begin{aligned} x' &= x \cos \theta + y \sin \theta, \\ y' &= -x \sin \theta + y \cos \theta \end{aligned} \quad (2.17)$$

Denklem (2.17)'de f , sinüzoidin frekansı, θ , normalin bir Gabor fonksiyonunun paralel çizgilerine oryantasyonu, ϕ , faz kayması, σ , Gauss zarfının standart sapması ve γ , uzaysal en boy oranıdır ve Gabor fonksiyonu desteğinin elipslik düzeyini ifade eder. Tipik olarak araştırmacılar Şekil 2.1'de verildiği gibi Gabor dalgacık filtrelerini beş farklı ölçekte ve sekiz yönde kullanırlar [29].



Şekil 2.1. Beş farklı ölçekte ve sekiz yönde Gabor dalgacık taneleri [31]

2.3.2.2. Dalgacık Tabanlı Özellik Çıkarımı

Dalgacıklar, verileri farklı frekans bileşenlerine ayıran ve daha sonra her bir bileşeni kendi ölçeğine uygun bir çözünürlükte inceleyen matematiksel fonksiyonlardır. Dalgacık, karmaşık veri setlerinin analizi için güçlü yöntem olarak ortaya çıkmıştır. Fourier dönüşümü, yalnızca frekans içeriğine bağlı olarak bir görüntünün yeniden hazırlanmasını sağlar. Dolayısıyla, bu temsil uzamsal olarak konumlandırılmazken, dalgacık işlevleri uzayda konumlandırılır. Fourier dönüşümü bir sinyali bir frekans spektrumuna ayırırken, dalgacık analizi, bir sinyali kaba ölçek seviyesinden değişen bir ölçek hiyerarşisine dönüştürür. Bu nedenle, bir resmin çeşitli çözünürlüklerde gösterimini sağlayan Dalgacık dönüşümü, görüntülerden özellik çıkarımı için daha iyi bir araçtır [26].

2.3.2.2.1. Ayrık Dalgacık Dönüşümü

ADD, belirli bir dalgacık ölçeği ve translasyon kümesini, önceden belirlenmiş bazı kurallara uyarak kullanan bir dalgacık dönüşümü uygulamasıdır. Pratik hesaplamalar için dalgacık dönüşümünün ayrıklaştırılması gerekir. Ölçek parametresi veya parametreleri bir logaritmik ızgara üzerinde ayrılmıştır. Translasyon parametresi (τ) ise ölçek parametresine göre ayrıştırılır, yani örnekleme ikili örnekleme ızgarası üzerinde yapılır (logaritmanın tabanı genellikle iki olarak seçilir). Ayrıklaştırılmış ölçek ve translasyon parametreleri, $s = 2^{-m}$ ve $\tau = n2^{-m}$ m olarak verilmiştir, burada $m, n \in Z$ olarak kabul edilir. Böylelikle, dalgacık fonksiyonları ailesi, Denklem (2.18)'da gösterildiği gibidir [26].

$$\psi_{m,n}(t) = 2^{m/2}\psi(2^m t - n) \quad (2.18)$$

Dalgacık dönüşümü, Denklem (2.19) ve Denklem (2.20)'de verilen bir $x(t)$ sinyalinin bir sentez dalgacıkları ailesine dönüştürür.

$$x(t) = \sum_m \sum_n c_{m,n} \psi_{m,n}(t) \quad (2.19)$$

$$c_{m,n} = \langle x(t), \psi_{m,n}(t) \rangle \quad (2.20)$$

Kesikli bir zaman sinyali $x[n]$ için, I oktavlardaki dalgacık ayrışması Denklem (2.21)'de verilmiştir:

$$x[n] = \sum_{i=1 \text{ to } I} \sum_{k \in \mathbb{Z}} c_{i,k} g[n - 2^i k] + \sum_{k \in \mathbb{Z}} d_{i,k} h_I[n - 2^i k] \quad (2.21)$$

Burada $c_{i,k}$ $i = 1 \dots I$: dalgacık katsayıları ve $d_{i,k}$ $i = 1 \dots I$: ölçek katsayılarıdır.

Dalgacık ve ölçek katsayıları Denklem (2.22) ve Denklem (2.23)'deki gibi tanımlanmaktadır:

$$c_{i,k} = \sum_n x[n] g_i^*[n - 2^i k] \quad (2.22)$$

$$d_{i,k} = \sum_n x[n] h_I^*[n - 2^i k] \quad (2.23)$$

Burada $g_i[n - 2^i k]$ ve $h_I[n - 2^i k]$ sırasıyla ayırık dalga izinleri ve ölçekleme sekanslarını temsil eder ve (*) karmaşık konjugatı belirtir.

2.3.2.2.2. İki boyutta Ayırık Dalgacık Dönüşümü

Görüntülerde, ADD her boyuta ayrı ayrı uygulanır. Bu, bir Y görüntüsünün birinci seviye bir yaklaşım bileşeni Y_a^1 ve ayrıntılı bileşenler Y_h^1 , Y_v^1 ve Y_d^1 ; yatay, dikey ve çapraz detaylara karşılık gelmesine neden olur [74].

Yaklaşım bileşeni (Y_a) görüntünün düşük frekanslı bileşenlerini içerirken, ayrıntılı bileşenler (Y_h , Y_v ve Y_d) yüksek frekanslı bileşenler içerir. Böylelikle

$$Y = Y_a^1 + \{Y_h^1 + Y_v^1 + Y_d^1\} \quad (2.24)$$

ADD Y_a^1 'e uygulanırsa, ikinci seviye yaklaşımı ve ayrıntılı bileşenler elde edilir. Yüksek seviye ayrışma benzer şekilde gerçekleştirilir. İşlem N seviyesine kadar tekrarlanırsa, Y görüntüsü, N 'inci yaklaşım bileşeni (Y_a^N) ve aşağıda Denklem (2.25)'de verilen tüm ayrıntılı bileşenler açısından yazılabilir:

$$Y = Y_a^N + \sum_{i=1}^{to N} \{Y_h^i + Y_v^i + Y_d^i\} \quad (2.25)$$

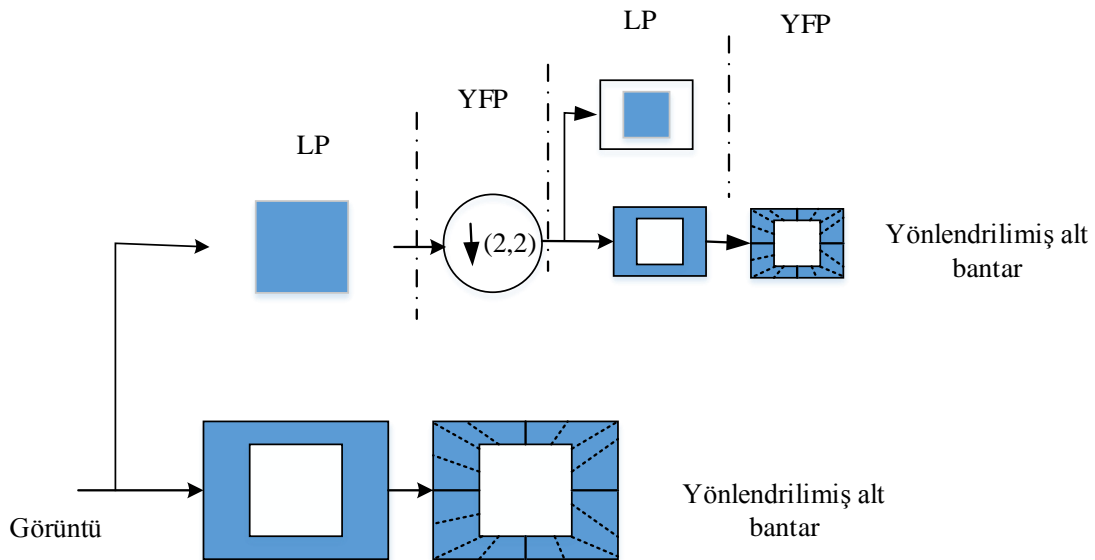
Her ayrışma seviyesinde, ayrıştırılan sinyallerin uzunluğu önceki aşamadaki sinyalin uzunluğunun yarısıdır. Dolayısıyla, bir $N \times N$ görüntüsünün birinci seviye ayrışmasından elde edilen yaklaşım bileşeninin boyutu $N/2 \times N/2$, ikinci seviye $N/4 \times N/4$ vb. Ayrışma seviyesi arttıkça, görüntünün daha küçük fakat karmaşık bir yaklaşımı elde edilir. Bu nedenle dalgacıklar, görüntü bilgisini yorumlamak için basit bir hiyerarşik çerçeve sağlar [26].

2.3.2.3. Contourlet dönüşümü

2000 yılında [75] Contourlet'i (CNT) dalgacıkların basit bir yönelimi olarak tanıtmışlardır. Dalgacıklar, pürüzsüz konturlu görüntüleri farklı yönlerde göstermek için etkili değildir. Yönlülük ve anizotropi özellikleri Contourlet tarafından çok ölçekli ve yönlü ayrışma sağlayarak ele alınır ve görüntülerin çok ölçekli ayrıştırılması için Laplacian Piramid (LP) yapısını ortaya koymuştur.[76].

Her seviyede LP şeması, orijinal görüntünün aşağı örneklenmiş düşük geçişli versiyonunu ve orijinal ve düşük geçişli görüntü arasındaki farkı oluşturarak bir bant geçişli görüntü oluşturur. Daha sonra elde edilen bant geçiş görüntüsü, Yönelimli Filtre Bankası (YFB) aracılığıyla daha da işlenir. YFB, görüntülerin düzgün kontur ve kenar bilgileri gibi yüksek frekans bilgilerini içerir. K-seviyeli ikili ağaç ayrıştırma yöntemi ve ardından k'nin pozitif bir tamsayı olduğu $2k$ yönlü alt-bantlar tarafından uygulanır.

Contourlet dönüşümü Şekil (2.2).de gösterildiği gibi iki ana adımdan oluşur:



Şekil 2.2. CNT'nin ayrışma şeması

İlk önce giriş yüzü görüntüsü düşük geçişli görüntü ve bant geçişli görüntüye, ardından her bant geçişli görüntüye bölünür YFB tarafından ayrıca ayrıştırılır. Bir sonraki ayrışma seviyesi için, ilk düşük geçişli görüntü aşağı örneklenir ve aynı çift filtre bankası yapısından geçirilir. Böylece aynı yapı her bir ayrışma seviyesi için tekrarlanır [77].

2.3.2.4. Shearlet dönüşümü

Son yıllarda frekans alanındaki sinyal ve görüntü analiz metotları oldukça yoğun kullanılmaktadır. Bu metotlardan biri olan dalgacık dönüşümü görüntülerdeki kenar ve köşe bilgileri gibi geometrik özellikleri tam olarak ortaya çıkaramamaktadır. Ayrıca dalgacık dönüşümü ve Fourier dönüşümü yüksek boyutlu sinyal ve görüntü verileri için uygun dönüşümler değildir. Çünkü bu metotlar özellikle görüntülerin çok yönlü olarak analiz edilmesinde yeterli bilgi elde edememektedir. Bundan dolayı dalgacık dönüşümünde pratikte en çok üç seviyeli olarak yapılmakta ve görüntünün sadece yatay, dikey ve diyagonal yönlerdeki frekans bileşenleri kodlanabilmektedir [77,78].

Shearlet dönüşümleri dalgacık dönüşümü metodunun yönsel olarak geliştirilmiş modelleridir. Shearlet dönüşümü görüntülerin analiz edilmesinde kullanılan çok ölçekli bir matematiksel yapı sunmaktadır. Görüntülerin istenen ölçek ve yönde frekans bileşenlerini basit matematiksel yaklaşımlarla ortaya çıkararak detaylı bir analiz imkânı sağlar Kesmeler (shearlets), çeşitli güçlü uygulamalarla, son dönemlerde ortaya çıkmıştır [68–70,78]. Anizotropik destekli dalga formları üretmek için ölçeklendirme operatörü gereklidir. Dalgacıklardaki dilatasyon operatörü gibi kabul edilebilir.

Parabolik ölçeklendirme matrisleri $B_b = \begin{pmatrix} b & 0 \\ 0 & \sqrt{b} \end{pmatrix}$ ile ilgili, $D_{B_b}, b > 0$ dilatasyon operatörlerini kullanılır. Dalga biçimlerinin yönelimleri ortogonal bir dönüşümle değiştirilebilir [78,80].

$C_c = \begin{pmatrix} 1 & c \\ 0 & 1 \end{pmatrix}$, ortogonal dönüşüm için verilen C_c kesme matrisi iken, kesme operatörünü $D_{C_c}, c \in \mathbb{R}$ seçiyoruz. Kesme matrisi, eğimlerle bağlantılı c değişkenini kullanır. Son olarak, çeviri operatörü için T_s kullanılır. Böylelikle, sürekli kesme sistemi $SH(\gamma), \gamma \in L^2(\mathbb{R}^2)$ iken, bu üç operatörün bir kombinasyonu olarak tanımlanabilir [78,79]:

$$SH(\gamma) = \{\gamma_{b,c,s} = T_s D_{B_b} D_{C_c} \gamma : b > 0, c \in \mathbb{R}, s \in \mathbb{R}^2\} \quad (2.26)$$

Shearlet dönüşümü uygulanırken ölçek sayısı dört olarak alınmıştır. Ölçek değerlerindeki kesme sayısı her bir $\alpha = 1,2,3,4$ değerini kullanarak $2(\alpha-1)+2$ formülü ile hesaplanmaktadır [78,101]. Her bir ölçek sayı değeri için hesaplandığında [4 8 16 32] olmak üzere toplam 60 tane kesme sayısı hesaplanır. Bu sayıya bir tane alçak geçiren filtre de eklenerek toplam kesme sayısı 61 olarak belirlenir. 256×256 boyutundaki her bir beyin MR görüntüsü 61 frekans dilimi ile farklı açılarda filtre edilerek bir görüntü için $256 \times 256 \times 61$ boyutunda Shearlet katsayı matrisleri hesaplanır.

Fourier dönüşümü ve dalgacık dönüşümü metotlarında olduğu gibi, Shearlet dönüşümünden elde edilen frekans katsayı matrislerinin istatistiksel analizleri yapılmaktadır. Tümör tespit çalışmalarında her bir Shearlet katsayı matrisinin ortalama ve varyans değerleri hesaplanmıştır. Dolayısıyla her bir görüntünün öznelik vektör boyutu 1×122 olarak elde edilmiştir.

2.3.2.5. Curvelet dönüşümü

Curvelet dönüşümü ilk olarak Starck ve ark. tarafından, görüntüden gürültü arındırma işlemi için kullanılmıştır [82]. Yaygın dalgacık dönüşümlerine alternatif sağlamak için tasarlanmıştır, çünkü dalgacık dönüşümlerinin keyfi yönelimli kenarları temsil ederken bozulmuş olduğu düşünülmüştür [83]. Dahası, dalgacık dönüşümü genellikle görüntüdeki belirgin kenarları temsil etmek için çok sayıda katsayı verir [84]. Konumlu bir Fourier dönüşümü genellemesi olan yönelimli dalgacık dönüşümünün aksine, Curvelet dönüşümü ölçeğe göre oryantasyonda değişen lokalizasyon derecesine sahiptir. Bu özellik, uyarlamalı olmayan bir şekilde çok ölçekli nesne gösterimi yapabilen curvelet dönüşümü sağlar.

Curvelet dönüşümü, Radon dönüşümü için dalgacık dönüşümü uygulanarak elde edilebilecek olan ridgelet dönüşümünün bir uzantısı olarak düşünülebilir. Noktaları saptamak için kullanılan dalgacık dönüşümlerinden farklı olarak, çizgileri saptamak için Radon dönüşümü kullanılır. Ayrıca, bir görüntünün 2B ayrık Fourier dönüşümü radyal çizgilerinin 1B ters Fourier dönüşümü alınarak hesaplanabilir.

Matematiksel olarak, bir $I(x, y)$ görüntüsünün ridgelet dönüşümü aşağıdaki gibi tanımlanabilir:

$$R(a, b, \theta) = \iint \psi_{a,b,\theta}(x, y) I(x, y) dx dy \quad (2.27)$$

Burada a, b ve θ , $a > 0$, $b \in \mathbb{R}$ ve $\theta \in [0, 2\pi]$ olmak üzere sırayla ölçek, konum ve yönelimdir. $\psi_{a,b,\theta}(x, y)$ ridgelet baz fonksiyonunu ifade eder ve aşağıdaki gibi tanımlanır:

$$\psi_{a,b,\theta}(x, y) = a^{-1/2} \psi\left(\frac{x \cos \theta + y \sin \theta - b}{a}\right) \quad (2.28)$$

Ayrık curvelet dönüşümü aşağıdaki gibi tanımlanabilir:

$$C_{a,b,\theta}^D = \sum_{x=0}^X \sum_{y=0}^Y I[x, y] \psi_{a,b,\theta}[x, y] \quad (2.29)$$

Denklem (2.29) alternatif olarak şu şekilde de tanımlanabilir:


$$C_{a,b,\theta}^D = \text{IFFT}(\text{FFT}(I[x, y]) \times \text{FFT}(\psi_{a,b,\theta}^D[x, y])) \quad (2.30)$$

2.3.2.6. Gri Seviye Eş Oluşum Matrisi

Haralick tarafından tanımlanan Gri Seviye Eş Oluşumu (GSEM), pikseller veya piksel grupları arasındaki ilişkiyi yansıtan ikinci dereceden istatistiklerle ilgili görüntü özelliklerini tahmin eder [85]. GSEM, belli bir d mesafesiyle ayrılmış piksel çiftlerinin oluşumunu açıklayan iki boyutlu bir histogramdır. $I(x, y)$, $N \times M$ boyutunda ve G gri seviyelerinde bir görüntüdür. (x_1, y_1) ve (x_2, y_2) de sırasıyla i ve j gri seviye yoğunluklarında iki piksel olsun. x yönündeki Δ 'yı $\Delta x = x_2 - x_1$ ve y yönündeki Δ 'yı $\Delta y = y_2 - y_1$ aldığımızda; düz bağlantı hattı, $\arctan(\Delta x / \Delta y)$ 'ye eşit bir θ yönüne sahiptir. Standardize edilmiş eş oluşum matrisi $C_{\theta,d}$ Denklem (2.31)'deki gibi tanımlanabilir:


$$C_{\theta,d}(i, j) = (\text{Num}\{((x_1, y_1), (x_2, y_2)) \in (N \times M) \times (N \times M) | A\}) / K \quad (2.31)$$

Burada A , $(\Delta x = d \sin \theta)$, $(\Delta y = d \cos \theta)$, $(I(x_1, y_1) = i)$ ve $(I(x_2, y_2) = j)$ gibi önceden verilmiş bir koşuldur. Num ise eş-oluşum matrisindeki element sayısını ve K , toplam piksel çifti sayısını temsil eder [34]. İşlem karmaşıklığı düşülerek genellikle hesaplamalarda, $d = 1, 2$ ve $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° olarak seçilir.



Şekil 2.3. Seçilen piksel için açılarının sunumu

Şekil 2.4.'de $\theta = 0^\circ$, $d = 1$ kabul edilerek oluşan örnek GSEM karesi sunulmuştur.



Şekil 2.4. GSEM karesinin oluşturulması

Bu tez çalışmasında kullanılan sekiz farklı doku özneliği, Denklem (2.32-2.39)'daki gibi eş oluşum matrisi kullanılarak tanımlanır:

$$\text{Entropi: } - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} C_{ij} \log_2 C_{ij} \quad (2.32)$$

$$\text{Korelasyon: } \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{ijC_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.33)$$

$$\text{Homojenlik: } \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{C_{ij}}{1+|i-j|} \quad (2.34)$$

$$\text{Mutlak Değer: } \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} |i-j| C_{ij} \quad (2.35)$$

$$\text{Eylemsizlik (kontrast): } \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i-j)^2 C_{ij} \quad (2.36)$$

$$\text{Ters Fark: } \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{C_{ij}}{1+(i-j)^2} \quad (2.37)$$

$$\text{Maksimum olasılık: } \max_{ij} C_{ij} \quad (2.38)$$

$$\text{Açısal ikinci an (enerji): } \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} C_{ij}^2 \quad (2.39)$$

Burada C_{ij} , eş oluşum matrisinin (i,j). elementidir.

2.3.2.7. Gri Seviye Dizi Uzunluğu Matrisi

Gri Seviye Dizi Uzunluğu Matrisi (GSDUM), gri seviyesi değerine nicel bir parametre atayan ikinci dereceden istatistiksel yöntemdir. GSDUM'da, gri seviye çalışma uzunluğu olarak adlandırılan bir doku ilkeli, aynı gri seviyesine sahip maksimum koline bağlı piksel seti olarak kabul edilir. Gri seviye koşulları, belirli bir gri değer için çalışma uzunluğu ve yönü ile karakterize edilir [86]. GSDUM'u hesaplamak için, çeşitli uzunluklardaki gri seviye koşullarının sayısı tespit edilmelidir. $R(\theta) = [r'(i, l|\theta)]$ gri seviye akış uzunluğu matrisinde, $r'(i, l|\theta)$ elementi, bir görüntünün l uzunluğundaki, i gri seviyesi için, θ açısı yönündeki işlem içermeye sayısını gösterir. Gri seviye akış uzunluğu matrisleri $R(\theta)$, 0° , 45° , 90° ve 135° için hesaplanır. Bu çalışmada kullanılan beş GSDUM özelliği, bu matrisler kullanılarak hesaplanır:

Kısa Dönem Vurgu:

$$RF_1(R(\theta)) = \frac{1}{T_p} \sum_{i=0}^{G-1} \sum_{l=1}^{N_R} \frac{r'(i, l|\theta)}{l^2} \quad (2.40)$$

Uzun Dönem Vurgu:

$$RF_2(R(\theta)) = \frac{1}{T_p} \sum_{i=0}^{G-1} \sum_{l=1}^{N_R} j^2 r'(i, l|\theta) \quad (2.41)$$

$$\text{Gri Seviye Dağılımı: } RF_3(R(\theta)) = \frac{1}{T_p} \sum_{i=0}^{G-1} [\sum_{l=1}^{N_R} r'(i, l|\theta)]^2 \quad (2.42)$$

$$\text{Akış Uzunluğu Dağılımı: } RF_4(R(\theta)) = \frac{1}{T_p} \sum_{i=0}^{N_R} [\sum_{l=1}^{G-1} r'(i, l|\theta)]^2 \quad (2.43)$$

$$\text{Çalışma Yüzdesi: } RF_5(R(\theta)) = \frac{1}{T_p} \sum_{i=0}^{G-1} \sum_{l=1}^{N_R} r'(i, l|\theta) \quad (2.44)$$

Burada G , gri seviyelerinin sayısı, N_R matristeki çalışma uzunluklarının sayısıdır. T_P ise Denklem (2.45)'deki şekilde ifade edilebilir:

$$T_P = \sum_{i=0}^{G-1} \sum_{l=1}^{N_R} r'(i, l|\theta) \quad (2.45)$$

2.3.2.8. Yönlendirilmiş gradyan özelliklerinin histogramı

Yönlendirilmiş Gradyan Özelliklerinin Histogram (YGÖH) özellikleri, bilgisayarlı görme alanında nesne algılama amacıyla sıklıkla kullanılan tanımlayıcılardır. Bu tanımlayıcıların arkasındaki mantık, yerel nesne görünümünün ve şeklinin, yoğunluk gradyanlarının veya kenar çizgilerinin bir dağılımı ile tanımlanabilmesidir [87]. YGÖH

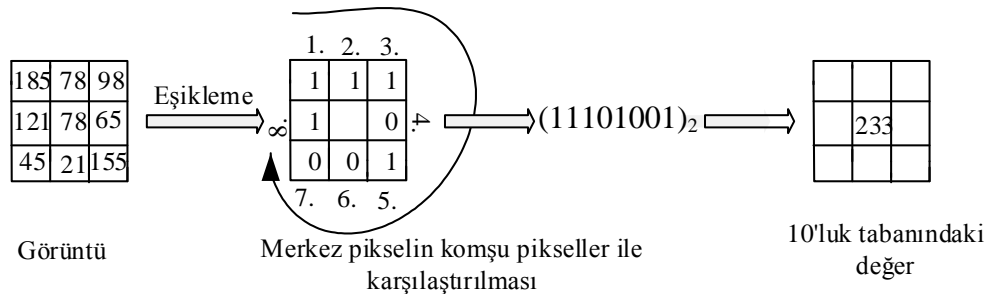
homojen olarak aralıklı hücrelerin yoğun olduğu bir ızgara üzerinde hesaplanır ve daha yüksek doğruluk için örtüşen yerel kontrast normalizasyonunu kullanır. YGÖH'da bir görüntü, hücreler adı verilen küçük, bağlı bölgelere bölünür ve her hücre için hücre içindeki pikseller için gradyan yönlerin veya kenar yönlerinin bir histogramı derlenir. Bu histogramların kombinasyonu daha sonra tanımlayıcıyı oluşturur. Geliştirilmiş doğruluk için, yerel histogramlar blok olarak adlandırılan daha büyük bir bölgedeki yoğunluğun bir ölçüsünü hesaplayarak ve ardından blok içindeki tüm hücreleri normalize etmek için bu değer kullanılır ve böylece kontrast normalizasyonu sağlanır. Bu normalizasyon aydınlatma veya gölgelenme değişikliklerine karşı daha düşük hassasiyet sunar [31].

2.3.2.9. Yerel İkili Örüntü Özellikleri

Yerel İkili Örüntü (YİÖ) operatörü, görüntü üzerinde pencereler tarar ve komşu piksellerini merkez pikselin değerleriyle karşılaştırarak ve komşuları için ikili sayılar belirleyerek etiketler verir [88]. Daha sonra YİÖ operatörü, ikili sayının değerini saat yönünde veya saat yönünün tersine artan ikinin katları ile çarparak hesaplar. Bu 256 farklı etiketin histogramı bir doku tanımlayıcısı olarak kullanılır. Düşünülen çevre merkezden uzakta farklı boyutlarda olabilir. Çevredeki herhangi bir yarıçap ve herhangi bir sayıda piksel kullanılabilir. Denklem, (P, R) notasyonu piksel çevreleri için kullanılacaktır; bu, R yarıçaplı bir dairede P örnekleme noktaları anlamına gelir. Bir (x_c, y_c) pikselinin YİÖ değeri aşağıdaki şekilde hesaplanır:

$$YİÖ_{P,R} = \sum_{p=0}^{P-1} S(g_p - g_c) 2^p$$


$$S(x) = \begin{cases} 1, & \text{if } x \geq 0 \\ 0, & \text{aksitakdirde} \end{cases} \quad (2,46)$$



Şekil 2.5. YİÖ operatörünün uygulanışı

Burada g piksel yoğunluk değerini ifade etmektedir. Bu çalışmada $P = 8$ ve 16 , $R = 1$ ve 2 alınarak çalışmalar yapılmıştır.

Yapılan çalışmalarda, görüntülerin doku yüzeylerinin büyük bir kısmının tekdüzen kalıplardan oluştuğu gözlemlenmiştir. Tek tip dokularda, YİÖ operatörüyle elde edilen değerlerde 0 – 1 ve 1 – 0 arası geçiş sayısı ikiden azdır. 00000000 ve 11111111 modellerinde sıfır geçiş ve 01100000 ve 11000011 örüntüleri iki geçişlidir de tek tip dokulardır [22]. Tek tip kalıplar nokta, kenar ve köşe gibi basit dokuları açıklayabilir. Toplamda tek tip desen sayısı $P*(P-1)+2$ hesaplanarak bulunur. Tekdüze olmayan piksellerin değerleri bir alanda tutulduğu için tekdüze histogramında 59 kutu bulunur [88]. YİÖ tekdüze histogramının sunumu Şekil 2.6’da verilmiştir.



Şekil 2.6. Tekdüze YİÖ'nün görsel sunumu.

2.4. Boyut İndirgeme

2.4.1. Temel Bileşen Analizi

Özellik boyutluluğunu azaltmak için Temel Bileşen Analizi (TBA) literatürde sıklıkla kullanılmaktadır. TBA, muhtemelen birbiriyle ilişkilendirilmiş değişkenler kümesini doğrusal olarak ilişkili olmayan gruplara yansıtmak için ortogonal bir dönüşüm kullanan matematiksel bir araçtır [89]. Temel bileşenler, verilerin değişkenliğinin çoğunu korumaya çalışır. TBA, çıkarılan özelliklerin her birine uygulanır ve en yüksek özdeğerlere sahip olan ana özellik vektörleri elde edilir. N sıfır olmayan özvektörleri, M İdeal özellik sayısını ifade ederken, yeniden yapılanma oranı (γ) Denklem (2.47)'a göre hesaplanarak elde edilir. γ , seçilen M özdeğerlerinin toplamının, tüm özdeğerlerin toplamına oranı olarak tanımlanır:

$$\gamma = \frac{\sum_{i=1}^M \lambda_i}{\sum_{i=1}^N \lambda_i} \quad (2.47)$$

Burada, λ_i 'ler, azalan büyüklükte sıralanmış özdeğerlerdir.

2.4.2. Doğrusal Ayırt Edici Analiz

DAE analizi temel alandaki sınıfları en iyi ayırt eden vektörleri (verileri en iyi tanımlayanlar yerine) arar [90]. Verinin tarif edildiğine ilişkin bir dizi bağımsız özellik verildiğinde DAE analiz, bunların istenen sınıflar arasında en büyük ortalama farkları veren doğrusal bir kombinasyonunu yaratır. Matematiksel olarak tüm sınıfların tüm örnekleri için iki ölçü tanımlanır.

Bunlardan birine sınıf içi dağılım matrisi (S_w) denir ve Denklem (2.48)'deki gibi tanımlanır.

$$S_w = \sum_{j=1}^c \sum_{i=1}^{N_j} (x_i^j - \mu_j)(x_i^j - \mu_j)^T \quad (2.48)$$

Burada μ , tüm sınıfların ortalamasını ifade etmektedir.

Amaç, sınıf içi ölçümü en aza indirirken sınıflar arası ölçümü en üst düzeye çıkarmaktır. Bunu yapmanın bir yolu, $\frac{\det|S_b|}{\det|S_w|}$ oranını en üst düzeye çıkarmaktır.

Bu oranı kullanmanın avantajı, S_w 'in tekil olmayan bir matris olması durumunda projeksiyon matrisinin W vektörlerinin $S_w^{-1}S_b$ 'nin özvektörleri olması durumunda bu oranın maksimize edildiğinin kanıtlanmış [90] olmasıdır. Şunlara dikkat edilmelidir en çok $c - 1$ sıfır genelleştirilmiş özvektörler vardır ve bu nedenle f 'ye bir üst sınır $c - 1$ ve 2 'dir) S_w 'in tekilleşmediğini garanti etmek için en az $t + c$ örneğe ihtiyaç duyulmaktadır (ki herhangi bir gerçekçi uygulamada bu neredeyse imkansızdır). Bunu çözmek için [91] bir ara boşluğu önermektedir. Her iki durumda da, bu ara alan TBA alanı olarak seçilir. Böylece, orijinal t -boyutlu uzay, TBA kullanılarak bir ara g -boyutlu uzaya ve ardından DAE analiz kullanarak bir nihai f -boyutlu uzaya yansıtılır.

2.4.3. Bağımsız Bileşen Analizi

Bağımsız Bileşen Analizi (BBA) gauss dışı süreçlerin tipik problemini çözmek için önerilen ve farklı alanlarda başarıyla uygulanmış bir özellik çıkarma tekniğidir [92]. BBA algoritması, TBA algoritmasına çok benzer. TBA, verileri ana bileşen yardımıyla başka bir alana eşler. Asıl bileşen yerine, BBA algoritması Gauss olmayan verilerin doğrusal gösterimini bulur, böylece çıkarılan bileşenler istatistiksel olarak bağımsızdır [93].

2.4.4. YAK'a göre özellik seçimi

Yapay Arı Kolonisi (YAK), en iyi özellik alt kümesini seçmek için kullanılan evrimsel bir özellik seçim algoritmasıdır. YAK algoritması, 2005 yılında Dervis Karaboga tarafından sunulan, özellik alt kümesinin optimizasyonu için bal arısı kümelerinin akıllı arama davranışının görünümünü ortaya koymaktadır [94]. ABC algoritması, üç arı sınıfı (çalışan, izleyici ve izci) tarafından yönetilen yerel arama ve küresel arama yönteminin bir birleşimidir [95]. Arama alanındaki (koloni) farklı çalışmalara sahip olan bu üç arı sınıfı, problemin optimal çözüme yakın olduğunu bulmaktadır.

Çalışan arılar: Bu arılar kovanlarının çevresinde yeni mahalle yiyecekleri ararlar. Daha sonra, yeni besin kaynağını eski besin kaynağı ile Denklem (2.49)'ı kullanarak kıyaslarlar.

$$v_i^j = x_i^j + \varphi_i^j(x_i^j - x_k^j) \quad (2.49)$$

Burada v_i^j yeni geliştirilmiş çözümü ifade eder, ve $k \neq i$. φ_i^j $[-1,1]$ aralığında rasgele bir sayıdır. v_i^j 'nin uyum değeri x_i^j 'den daha iyi ise, x_i^j , v_i^j ile değişir. Aksi halde değişmeden kalır [86].

İzleyici arılar: Çalışan arılar, bu çözüm bilgisini izleyici arılarla paylaşırlar. Daha sonra, çalışan arılardan gelen bilgiyi kullanarak seyirci arılar, nektar miktarı ile ilgili olasılıkları hesaplayıp bir besin kaynağı bulurlar. Besin kaynağını bulma olasılığı, Denklem (2.50)'de hesaplanmıştır.

$$P_i = \frac{fit_i}{\sum_{k=1}^{NB} fit_k} \quad (2.50)$$


İzci arılar: Eğer çözümün (fit_i) uygunluk değeri "limit" olarak adlandırılan önceden tanımlanmış bir sayı boyunca daha uzun süre iyileştirilemezse, o zaman bu kriterlere "terk etme kriterleri" denir. Bu tür kriterler için izci arılar, Denklem (2.51)'i kullanarak alternatif çözümler üretir.

$$x_i^j = x_{min}^j + rand(0,1)(x_{max}^j - x_{min}^j) \quad (2.51)$$

2.5. Sınıflandırma

2.5.1. Yapay Sinir Ağları

YSA'lar insan beyninin biyolojik yapısından esinlenilerek tasarlanmıştır. YSA'lar basit işlemler yapabilen çok sayıda nöronlardan oluşmaktadır. Bu nöronlar birbirleri ile bağlantılıdır ve her bağlantının kendi ağırlığı vardır. Her bir nöron, çıkışı belirlemek için bir aktivasyon fonksiyonuna sahiptir ve genellikle sigmoid, adım gibi doğrusal olmayan aktivasyon fonksiyonları kullanılır. YSA'lar eğitilerek ağa bilinmeyen bir giriş yapıldığında, eğitilmiş deneyimlerinden genellenebilir ve yeni bir sonuç üretebilir [96]. Genel bir YSA modelinin yapısı Şekil 2.7'de verilmiştir.



Şekil 2.7. Yapay Sinir Ağlarının temel yapısı

Nöronların çıkış değeri Denklem (2.52)'te göre hesaplanır[96].

$$y(k + 1) = a\left(\sum_{j=1}^m w_{ij}x_j(k) - \theta_i\right) \text{ ve } f_i \Delta net_i = \sum_{j=1}^m w_{ij}x_j - \theta_i \quad (2.52)$$

Denklem (2.52)'de, $x = (x_1, x_2, x_m)$, nörona uygulanan m girişini temsil eder, w_i , x_i girişi için ağırlıkları temsil eder, y_i ise bias değeridir, $a(.)$ ise aktivasyon işlevidir.

YSA modelleri, desen eşleştirme, doğrusal olmayan sistem modellemesi, iletişim, elektrik ve elektronik endüstrisi, enerji üretimi, kimya endüstrisi, tıbbi uygulamalar gibi birçok alanda paralel işleme yetenekleri nedeniyle sıklıkla kullanılmaktadır.

Bir YSA modelini tasarlariken bir takım hususlar dikkate alınmalıdır. Öncelikle YSA modelinin uygun yapısı seçilmeli, aktivasyon fonksiyonu ve aktivasyon değerlerinin belirlenmesi gerekir. Katman sayısı ve her katmandaki birim sayısı seçilmelidir. Genellikle istenen model birkaç katmandan oluşur. En genel model, tüm birimler arasında tam bağlantılar olduğunu varsayar. Bu bağlantılar çift yönlü veya tek yönlü olabilir.

2.5.2. Destek Vektör Makinesi

DVM, iki sınıftan etiketli verileri girdi olarak alan ve yeni etiketlenmemiş / etiketli verileri iki sınıftan birine sınıflandırmak için bir model dosyası çıktısını alan ikili bir sınıflandırma yöntemidir. DVM, Vapnik tarafından geliştirilen yapısal risk azaltma fikrinden esinlenerek tasarlanmıştır [17]. Destek vektör makineleri öncelikle doğrusal veya doğrusal olmayan sınıf sınırlarını öğrenmede çekici ve daha sistematik olduğu gösterilen iki sınıf sınıflandırıcısıdır. DVM'nin kullanımı, diğer herhangi bir makine öğrenim tekniği gibi, uygulama ve test olmak üzere iki temel adımı içerir. Bir DVM'nin uygulanması, önceden bilinen karar değerleriyle birlikte bilinen verilerin DVM'ye beslenmesini ve böylece sonlu bir uygulama seti oluşturulmasını içerir. Bu, DVM'nin bilinmeyen verileri sınıflandırmak için bilgileri aldığı uygulama setidir.

2.5.2.1. DVM Sınıflandırıcısının incelenmesi

$x \in R^n$ sınıflandırılacak bir desen ve y ölçeği bu desenin sınıf etiketi olsun, ($y = \pm 1$). $\{(x_i, y_i), i = 1, 2, \dots, l\}$ de bir grup uygulama örneği olsun. Burada problem, uygulama setinden olması gerekmeyen bir 'x' giriş desenini doğru şekilde sınıflandırabilen bir sınıflandırıcının (yani bir $f(x)$ karar fonksiyonunun) oluşturulmasıdır.

2.5.2.2. Doğrusal DVM sınıflandırıcı

Bu, giriş desenlerinin doğrusal olarak ayrılabilir olduğu en basit durumdur. Bu formun doğrusal bir fonksiyonu vardır:

$$f(x) = W^T x + b \quad (2.53)$$

öyle ki, her bir uygulama örneği x_i için, fonksiyon $y_i = +1$ için $f(x_i) \geq 0$ ve $y_i = -1$ için $f(x_i) < 0$ verir. Dolayısıyla, iki farklı sınıftan uygulama örnekleri hiper düzlem tarafından ayrılır,

$$f(x) = W^T x + b = 0 \quad (2.54)$$

Belirli bir küme için, iki sınıfı ayıran birçok hiper düzlem vardır. Ancak DVM sınıflandırıcısı, iki sınıf arasındaki ayırma marjını maksimize eden bir hiper düzleme dayanmaktadır [97].

2.5.2.3. Doğrusal olmayan DVM sınıflandırıcısı

Doğrusal bir DVM sınıflandırıcısı, ilk önce x giriş modelini daha yüksek boyutlu alana eşlemek için doğrusal olmayan bir operatör $\Phi(\cdot)$ kullanılarak doğrusal olmayan bir sınıflandırıcıya kolayca genişletilebilir. Bu şekilde elde edilen doğrusal olmayan sınıflandırıcı Denklem (2.55)'de tanımlandığı gibidir [98]:

$$f(x) = W^T \Phi(x) + b \quad (2.55)$$

Bu, dönüştürülmüş veri $\Phi(x)$ açısından doğrusaldır, ancak $x \in R^n$ 'deki orijinal veri yönünden doğrusal değildir. Doğrusal olmayan dönüşümün ardından, $f(x)$ karar fonksiyonunun parametreleri, aşağıdaki minimize etme kriterleri ile belirlenir:

$$\text{Min}J(W, \xi) = \frac{1}{2} \|W\|^2 + C \sum \xi_i, \quad i = 0, 1, \dots, l \quad (2.56)$$

$$y_i(W^T \phi(x_i) + b) \geq 1 - \xi_i, \quad \xi_i \geq 0; \quad i = 1, 2, \dots, l \quad (2.57)$$

2.5.2.4. DVM çekirdek fonksiyonları

Bir DVM'deki çekirdek işlevi, giriş vektörünü (bir iç çarpım aracılığıyla) örtük olarak yüksek boyutlu bir özellik alanına yerleştirmenin merkezi rolünü oynar. Veri noktalarının doğrusal olarak ayrılmaması normaldir, bu durumda doğrusal bir işlev iyi bir şekilde sınıflandırılmaz. Bu, çekirdeğin sınırlarının genişletilmesi ile çözülür, böylece bazı noktalar karşı sınırı işgal eder. Bununla birlikte, bir çekirdek işlevi seçerken, bunun doğrusal olmayan bir eşlemenin iç çarpımıyla ilişkili olup olmadığını kontrol etmek gerekir. Mercer'in teoremi, böyle bir eşleştirmenin gerçekten de, $K(\cdot, \cdot)$ pozitif bir integrallenebilir operatör olması şartıyla, bir $K(\cdot, \cdot)$ çekirdeğin temelini belirtir; yani, çekirdek $K(\cdot, \cdot)$ 'de tanımlanan integrallenebilir $g(\cdot)$ fonksiyonunun her bir karesi için çekirdek aşağıdaki koşulu sağlar [99]:

$$\int \int K(x, y) g(x) g(y) dx dy \geq 0 \quad (2.58)$$

Mercer'in koşulunu sağlayan çekirdeklere verilebilecek örnekler arasında polinomlar ve Radyal Temel Fonksiyonlar (RTF)'ler bulunmaktadır. Bunlar DVM araştırmalarında en sık kullanılan çekirdekler arasındadır. Polinom çekirdeği aşağıdaki gibi tanımlanır:

$$K(x, y) = (x^T y + 1)^P \quad (2.59)$$

Burada $p > 0$ çekirdeğin sırasını ifade eden bir sabittir.

Polinom ve RTF gibi birkaç çekirdek öğrenme yöntemi türü vardır. Özellik vektörlerinin iç çarpımının evrimi, giriş alanında doğrusal olmayan karar fonksiyonlarının oluşturulmasına izin verir. Karar fonksiyonu aşağıdaki gibi tanımlanır:

$$f(x) = \text{sign}(\sum_{\text{destek}} y_i \alpha_i K(x_i, x) - b) \quad (2.60)$$

Burada α_i Lagrange çarpanı, x_i destek vektörü, $K(x_i, x)$ ise özellik alanındaki iç çarpımın konvolüsyonunu ifade eder. Ayrıca destek vektörleri, yüksek boyutlu özellik alanındaki $(\psi_1(x), \psi_2(x), \dots, \psi_N(x))$ doğrusal karar fonksiyonlarına eşdeğerdir. İç çarpım $K(x, x_i)$ 'nin dönüşümü için farklı fonksiyonlar kullanılarak, giriş alanında farklı tipte doğrusal olmayan karar yüzeyleri olan öğrenme makineleri yapılabilir [87].

2.5.3. Aşırı Öğrenme Makineleri

AÖM, Huang tarafından tek bir gizli katmana sahip ileri beslemeli yapay sinir ağlarını eğitmek için önerilmiş bir yöntemdir [19]. $X \subset R^n$ girişi ve $T \subset R^m$ çıkışı arasındaki bilinmeyen bir ilişki ile rastgele bir hedef fonksiyonunu tahmin etmeyi öğrenen bir öğrenme problemi göz önüne alındığında, öğrenme probleminin amacı, verilen $\{(x_i, t_i)\}_{i=1}^N \subset R^n \times R^m$ veri setinde, N bağımsız ve eşit dağıtılmış örnekleme, $\tilde{f}(x) \approx t(x \in X, t \in T)$ şeklinde uygun bir doğrusal olmayan haritalama bulmaktır [100].

Üç katmanlı bir yapı üstlenen AÖM, başlangıçta Tek Gizli Katmanlı İleri Beslemeli Ağ (TKİBA) için önerilmiş ve gizli katmanın aynı olması gerekmeyen genelleştirilmiş TKİBA'lara genişletilmiştir. TKİBA'ların uygulaması için diğer geleneksel yaklaşımlardan farklı olarak, gizli katman parametreleri (a_i, b_i) rastgele üretilir, bu nedenle öğrenme, optimum çıkış ağırlığı β 'yı analitik yolla hesaplama işlemine indirgenebilir[101].

Genel olarak, AÖM, L aktivasyon fonksiyonlarının doğrusal bir kombinasyonu olarak ele alınabilir:

$$f_L(x) = \sum_{i=1}^L \beta_i h_i(x) = h(x)\beta \quad (2.61)$$

Burada L , AÖM'nin gizli düğüm sayısını gösterir ve $h_i(x) = g(x, a_i, b_i)$ dir. Denklem (2.61) matris biçiminde Denklem (2.62) gibi yeniden yazılabilir:

$$H\beta = T \quad (2.62)$$

H , gizli katman çıktı matrisidir,

$$H = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} h_1(x_1) & \cdots & h_L(x_1) \\ \vdots & \ddots & \vdots \\ h_1(x_N) & \cdots & h_L(x_N) \end{bmatrix} \quad (2.63)$$

T ağın çıkış ağırlığı β ise gizli katmanın çıkış ağırlığıdır.

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix} \text{ ve } \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix} \quad (2.64)$$

Bazı geleneksel makine öğrenme yaklaşımlarından farklı olarak, AÖM, çıktı ağırlıklarını minimize edebildiği gibi, minimum eğitim hatasına da ulaşmayı hedeflemektedir. Bu nedenle amaç fonksiyonu matematiksel olarak aşağıdaki gibi ifade edilebilir:

$$\min: L_{ELM} = \frac{1}{2} \|\beta\|^2 + \frac{1}{2} C \sum_{i=1}^N \xi_i^2 \quad (2.64)$$

$$h(x_i)\beta = t_i - \xi_i, i = 1, \dots, N$$

Burada $\xi_i = [\xi_{1,m}, \dots, \xi_{i,m}]$, m çıkış düğümlerinin x_i uygulama örneğine göre hata vektörüdür; C genelleme performansını güçlendirmek için bir düzenleme faktörüdür [102].

Karush Kuhn – Tucker (KKT) teoremine dayanarak, aşağıdaki ifadeyi elde ederiz:

$$\beta = \begin{cases} H^T \left(\frac{I}{C} + HH^T \right)^{-1} T, & N < L \\ \left(\frac{I}{C} + H^T H \right)^{-1} H^T T, & N > L \end{cases} \quad (2.66)$$

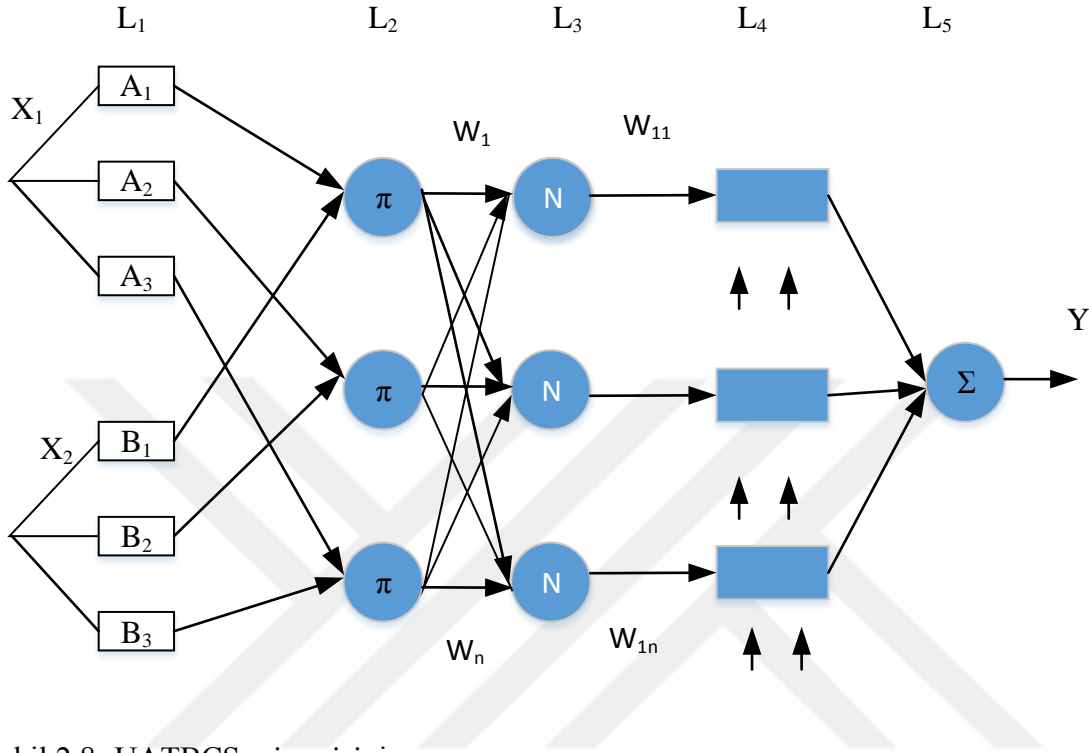
Denklem (2.66)'da I , birim matristir.

2.5.4. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi

UATBÇS mimarisi ve öğrenme kuralı [103]'te ayrıntılı olarak açıklanmıştır. ANFIS, her bir düğümün gelen sinyaller üzerinde belirli bir işlevi yerine getirdiği çok katmanlı bir ileri besleme ağıdır. Hem kare hem de daire düğümü sembolleri, uyarlamalı öğrenmenin farklı özelliklerini temsil etmek için kullanılır. İstenilen girdi-çıkış karakteristiklerini gerçekleştirmek için, adaptif öğrenme parametreleri gradyan öğrenme kurallarına göre güncellenir [103]. ANFIS modeli, birinci dereceden bir Sugeno bulanık çıkarım sisteminin uygulanmalarından biridir [104]. Kurallar Denklem (2.67)'deki gibidir. Bu sistemde,

$$\text{If } x_1 \text{ is } A_1, x_2 \text{ is } A_2, \text{ then } y = px_1 + qx_2 + r \quad (2.67)$$

Burada x_1 ve x_2 girdileri A_1 ve A_2 'ye karşılık gelen terim seti, y çıktı, p, q, r ise sabittir. Bir ANFIS modeli Şekil 2.8'de gösterilmektedir. Bu çok girişli, tek çıkışlı bir modeldir; çok çıkışlı bir model, birkaç çıkışlı modeli birbirine bağlayarak tasarlanabilir. Aynı katmandaki düğüm işlevleri benzerdir ve aşağıda açıklandığı gibidir.



Şekil 2.8. UATBÇS mimarisinin yapısı

Katman-1: Bu katmandaki her düğüm, düğüm işlevine sahip kare bir düğümdür. Katman 1'deki düğümler bulanık üyelik işlevlerini uygulayarak girdi değişkenlerini bulanık üyelik değerleriyle eşleştirir [105]. Bu katmanın çıkışları Denklem (2.68)'deki gibi tanımlanabilir.

$$O_i^1 = \mu_{A_i}(x) \quad (2.68)$$

Burada x, i düğümüne girer ve A_i , bu düğüm işleviyle ilişkilendirilmiş dilsel bir etikettir. O_i^1 , A_i 'nin üyelik işlevidir; bulanık üyelik işlevleri, üçgen, Gaussian gibi herhangi bir şekilde olabilir, ancak genellikle $\mu_{A_i}(x)$, 1'e kadar ve minimum 0'a eşit olacak şekilde seçilir. Üyelik fonksiyonlarının türleri hakkında ayrıntılı bilgi [106] tarafından tanımlanmıştır.

Katman-2: Bu katmandaki her düğüm etiketli bir daire düğümüdür. Gelen sinyalleri çarpır ve ürünü gönderir [105]. Örneğin,

$$w_i = \mu_{A_1}(x)\mu_{A_2}(y) \dots \quad i = 1,2,3, \dots, N \quad (2.69)$$

Her düğüm çıkışı, bir kuralın ateşleme gücünü gösterir.

Katman-3: Bu katmandaki her düğüm N etiketli bir daire düğümüdür. Düğüm, i'nci kuralın ateşleme gücünün, tüm kuralların ateşleme kuvvetlerinin toplamına oranını hesaplar [103]. Kuralların normalize edilmiş ateş gücü olan \bar{w} ise,

$$\bar{w} = \frac{w_i}{w_1 + w_2 + \dots + w_N} \quad i = 1, 2, 3, \dots, N \quad (2.70)$$

Katman-4: Bu katmandaki her düğüm bir düğüm işlevine sahip bir kare düğümdür.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (px + qy + \dots + r) \quad i = 1, 2, 3, \dots, N \quad (2.71)$$

Burada \bar{w}_i , katman-3'ün çıktısıdır ve $\{p, q, r\}$, parametre setidir. Bu katmandaki parametreler sonuçta ortaya çıkan parametreler olarak anılacaktır [105].

Katman-5: Bu katmandaki tek düğüm, gelen tüm sinyallerin etiketli toplamı olarak UATBÇS'nin toplam çıktısını hesaplayan Σ işaretli bir düğümdür [103].

$$O_i^5 = \Sigma_i \bar{w}_i f_i = \frac{\Sigma_i w_i f_i}{\Sigma_i w_i} \quad (2.72)$$

2.5.5. En Küçük Kareler Destek Vektör Makinesi

DVM, doğrusal ve doğrusal olmayan fonksiyon tahminleri için de kullanılmıştır. DVM sınıflandırıcısının en küçük kareler versiyonu Suykens ve Vandewalle (1999) tarafından tanımlanmıştır [107]. EK -DVM, klasik DVM yaklaşımındaki gibi eşitsizlikler yerine eşitlik tipi kısıtlamaları göz önünde bulundurur. Bu reformülasyon, EK- DVM çözümünün doğrudan dışbükey bir ikinci dereceden programdan ziyade bir dizi doğrusal denklemin çözümünün takip ettiği bir sorunu büyük ölçüde basitleştirir [108]. Bir EK-DVM sınıfı, Denklem (2.73)'deki formu alır,

$$y(x) = \text{sign}[w^T x + b] \quad (2.73)$$

Burada b gerçekte bir sabittir. Doğrusal olmayan sınıflandırma için, ikili alandaki EK-DVM sınıflandırıcısı, Denklem (2.74)'deki formu alır,

$$y(x) = \text{sign}[\Sigma_{k=1}^N \alpha_k y_k K(x, x_k) + b] \quad (2.74)$$

Burada α_i 'ler pozitif gerçekte sabitlerdir ve b gerçekte bir sabittir. Genellikle, $K(x_i, x) = \langle \phi(x_i), \phi(x) \rangle$, $\langle \cdot, \cdot \rangle$ iç çarpım ve $\phi(x)$ orijinal uzaydan yüksek boyutlu uzaya doğrusal olmayan haritadır. Fonksiyon tahmini için, EK-DVM modeli Denklem (2.75)'teki formu alır [107],

$$y(x) = \sum_{k=1}^N \alpha_k K(x, x_k) + b \quad (2.75)$$

RTF çekirdekleri kullanıldığında, iki ayar parametresi (γ, σ) eklenir. γ düzenleme sabiti ve σ ise RTF çekirdeğinin genişliğidir.

2.5.6. Parçacık Sürü Optimizasyonu

Parçacık Sürü Optimizasyonu (PSO), bazı hayvanların sürü hareketlerini ve sosyal etkileşimlerini simüle eden yüksek performanslı bir optimizasyon tekniğidir. Belirli bir alanda rastgele yiyecek arayan kuşlar söz konusu olduğunda, her bir kuş tek bir çözelti ile ilişkilendirilebilir ve sürüde bir parçacık olarak kabul edilebilir. Her bir parçacık, “en iyi” çözümü arayan arama alanında hareket eder [109]. Tüm parçacıklar, arama parçacıklarındaki birikmiş deneyimlerine dayanarak güncellenen ve komşularının deneyimlerini dikkate alarak daha da geliştirilmiş olan arama alanındaki hem konum hem de hızlarıyla tanımlanırlar [110].

PSO uygulaması, değişkenlerin alt ve üst sınırlarını ayarlayarak çalışma alanı sınırlarını tanımlayarak başlar. Ardından, popülasyon büyüklüğünü, maksimum ve minimum atalet ağırlığını, hızlanma sabitini ve maksimum yineleme sayısı başlatılır.

Konum ve hızın ilk değerleri rastgele oluşturulur. Her yineleme için, her parçacığın atalet ağırlığı ve hızı, Denklem (2.76-2.77)’e göre güncellenir [110]:

$$w(i) = w_{max} - \frac{(w_{max} - w_{min}) \cdot i}{l_{max}} \quad (2.76)$$

$$V_{pd}(i+1) = w \cdot V_{pd}(i) + (c \cdot r_1 (P_{pd}(i) - x_{pd}(i))) + (c \cdot r_2 (PG_d - x_{pd}(i))) \quad (2.77)$$

Burada p , bir parçacığı i , optimizasyon işleminde yinelemeyi temsil eder ve d , parçacığın arama alanındaki konumunu gösterir. Atalet ağırlığı w , önceki hızların mevcut hız üzerindeki etkisini değerlendirmek için kullanılır. r_1 ve r_2 $[0, 1]$ aralığında rastgele değişkenlerdir. P_{pd} parametresi, parçacığın en iyi kişisel pozisyonu olarak adlandırılan en iyi pozisyonudur ve PG_d , en iyi global pozisyon olarak adlandırılan popülasyon tarafından elde edilen en iyi pozisyonudur [109].

Her parçacığın konumu, Denklem (2.78) kullanılarak güncellenir:

$$x_{pd}(i+1) = x_{pd}(i) + V_{pd}(i+1) \quad (2.78)$$


PSO'nun ortalama karesel hata olarak minimize etmeyi amaçladığı hata fonksiyonunu E (amaç fonksiyonu) olarak tanımlarız [110].

$$E = \sqrt{\frac{\sum_{i=1}^n (P_i - M_i)^2}{n}} \quad (2.79)$$

Burada P_i ve M_i sırasıyla öngörülen ve ölçülen değerlerdir ve n örnekleme noktalarının sayısıdır [109].

2.5.7. Kendini Yineleyen Haritalar

Kendini Yineleyen Haritalar (KYH) mimarisi, her bir bağlantının bir ağırlık ile ilişkilendirildiği, birbirine bağlı bir giriş ve çıkış katmanından oluşur. KYH haritası için kullanılan nöron bağlantılarının topolojileri altıgen ve dikdörtgendir [99,100]. $n \times m$ nöronlardan oluşan KYH çıkış katmanları iki boyutlu bir ızgarada düzenlenir. KYH'nin amacı, orijinal n -boyutlu verileri, Şekil 2.9'da gösterildiği gibi iki boyutlu bir haritaya aktarmaktır. KYH giriş vektörü, $x_i = \{x_1, x_2, \dots, x_n\}$, $i = 1, 2, \dots, n$ ile gösterilir. Burada i , giriş vektörlerinin sayısıdır ve n , giriş birimlerinin sayısıdır. Her bir i , KYH haritasıyla $w = \{w_{n1}, w_{n2}, \dots, w_{nm}\}$ ağırlık vektörü ile ilişkilendirilir [111].



Şekil 2.9. KYH'nin gösterimi

Konvansiyonel bir KYH'nin öğrenme süreci aşağıdaki adımlardan oluşur: İlk olarak, ağırlık vektörünü rasgele bir $n \times m$ nöron ızgarası olarak başlatılır. İkinci olarak, KYH ağını bir veri kümesinden x girdi vektörüyle beslenir. Girdi vektörü x , tüm nöronlara senkron olarak beslenir. Üçüncüsü, giriş ve çıkış nöronları arasındaki mesafeyi hesapladıktan sonra, en iyi

eşleşme birimi olarak adlandırılan girişe en yakın nöron (en küçük mesafe) bulunur. Kazanan nöronun en iyi eşleşme birimi, c ile gösterilir ve Öklid mesafesi kullanılarak hesaplanır [112].

$$c = \arg_i \min(\|w_i(t) - x(t)\|) \quad (2.80)$$

Bu işlem, veri kümesindeki tüm diğer giriş vektörleri için tekrarlanır. Son olarak, kazanan nöronun ağırlık vektörleri, öğrenme sürecinin her bir yinelemesinde güncellenir [111],

$$w_i(t + 1) = w_i(t) + \alpha(t) \cdot [x(t) - w_i(t)] \quad (2.81)$$

Burada $\alpha(t)$ öğrenme oranıdır. KYH algoritmasının bir varyantı, kendi kendini düzenleyen harita algoritması ile Gauss fonksiyonudur (GF-KYH). Birçok uygulamada komşuluk işlevi olarak yaygın şekilde kullanılmaktadır. GF-KYH için ağırlık vektörlerinin güncellenmesi aşağıdaki eşitlik ile, [112]

$$w_i(t + 1) = w_i(t) + h_{c,i}(t) \cdot [x(t) - w_i(t)] \quad (2.82)$$

Burada $h_{c,i}$ Gauss komşuluk fonksiyonudur ve aşağıdaki gibi tanımlanır:

$$h_{c,i} = \alpha(t) \cdot \exp\left(-\frac{\|r_c - r_i\|}{2\sigma^2(t)}\right) \quad (2.83)$$

Burada $\|r_c - r_i\|$ her bir güncellenmiş ağırlıktaki ızgara üzerinde nöron c ve nöron i kazanma pozisyonları arasındaki Öklid mesafesi ve $\sigma(t)$ Gaussian'ın genişliğidir. $\alpha(t)$ ve $\sigma(t)$, öğrenme sürecinde sırasıyla δ_α ve δ_σ sabit faktörleri ile kademeli olarak azalır; [99, 100].

$$\alpha(t) = \delta_\alpha \cdot \alpha(t) \quad (2.84)$$

$$\sigma(t) = \delta_\sigma \cdot \sigma(t) \quad (2.85)$$

2.6. Morfolojik işlemler

Morfolojik görüntü işleme, bir görüntüdeki özelliklerin şekli veya morfolojisi ile ilgili doğrusal olmayan işlemlerin bir koleksiyonudur. Morfoloji çalışılan görüntü üzerindeki şekillerin yorumlanması, analiz edilmesi, istenilen bilginin çıkartılması, inceltme, görüntü sıkıştırma, köşe analizi, bozuk görüntü onarma (eksik veya fazla piksellerin çıkarılması, eklenmesi), dokuların tespiti gibi işlemlerde sıklıkla başvurulmaktadır [113].

İkili görüntü yapısında, görüntü renk değerleri 1 bit ile ifade edilir. Dolayısıyla renk değeri (0 siyah 1 beyazı ifade eder) sunar. Genellikle '0' arka plan piksellerini, 1 de nesne


piksellerini oluşturur. İkili görüntü yapısı görüntüdeki bazı özellikleri çıkarmak için kullanılabilir. 8 bit gri düzey görüntü ikili görüntü yapısına dönüştürüldükten sonra değişik işlemlere tabi tutularak istenen alan, kütle merkezi vb. nesneye ait özellikler görüntüden çıkartılabilir. İkili görüntü üzerinde uygulanan mantıksal işlemler Denklem (2.86)'daki gibidir ve görüntü üzerinde gösterimi Şekil 2.10'da görülmektedir.

$$A \text{ or } B = A \cup B$$

$$A \text{ and } B = A \cap B \tag{2.86}$$

$$\text{not } A = A^c$$


$$A \text{ and } (\text{not } B) = A - B$$



Şekil 2.10. İkili görüntü üzerinde uygulanan mantıksal işlemlerin gösterimi [114,115]

2.6.1. Genişletme İşlemi


İkili moda dönüştürülen görüntü üzerinde büyütme ya da kalınlaştırma işlemlerinin yapıldığı morfolojik işlemleri kapsamaktadır. Sayısal bir resmi genişletmek resmi yapısal elemanla kesiştiği bölümler kadar büyütme demektir [116,117].



Şekil 2.11. Genişletme işleminin gösterimi [117]

2.6.2. Aşındırma İşlemi


Aşındırma işlemi ikili moda dönüştürülen görüntü üzerinde küçültme ya da inceltme işlemlerinin yapıldığı morfolojik işlemleri kapsamaktadır. Aşındırma işlemi bir bakıma genişletme işleminin tersidir. Aşındırma işlemi ile sayısal resim üzerinde inceltme yapılmış dolayısıyla görüntüde tahribat meydana gelmiş olur. Aşındırmadan kaynaklı bu tahribat sonucunda resim içerisindeki nesnelere boyutsal olarak daralır, delik varsa genişler ve bağlı nesnelere ayrılma eğilimi gösterir [116,117].




Şekil 2.12. Aşındırma işleminin gösterimi[117]

Eğer sayısal bir görüntüye genişletme ve aşındırma işleminin ardışık olarak uygulanırsa görüntüde açma işlemi meydana gelmektedir. Açma işleminde birbirine yakın iki nesne görüntüde fazla değişime sebebiyet vermeden ayrılmış olurlar. Açmanın tersi olarak sayısal görüntü üzerinde aşındırma ve genişletme işleminin ardışık uygulanmasıyla da

kapama işlemi meydana gelmektedir. Dolayısıyla birbirine yakın iki nesne görüntüde fazla değişiklik yapılmadan birbirine bağlanmış olur [116,117].



Şekil 2.13. Açma işlemi [117]



Şekil 2.14. Kapama işlemi [117]

2.6.3. Boşluk doldurma

Boşluk doldurma (Hole Filling) nesne içindeki boşlukların doldurulması için uygulanır. Öncelikle belirlenen iterasyon sayısı kadar genişleme işlemi yapılır. Daha sonra elde edilen sonuç 1 iterasyon aşınma işlemine tabi tutulur. Aşınma sonucu giriş görüntüsüyle lojik VE işlemine tabi tutulur. Aşınma ve lojik VE işlemi görüntü değişmeyinceye kadar uygulanır. Sonuç olarak, görüntünün içindeki boşluklar doldurulur [114].

2.7. Kenar Bulma

Bir kenar, esas olarak iki farklı bölgeyi birbirinden ayıran sınırdır. Kenar bulma işlemi, bir görüntünün şiddet düzeyindeki belirgin lokal değişiklikleri tespit etme işlemidir [115,118]. Çoğu kenar bulma algoritmalarının amacı yerel türevleri hesaplamaktır. Kenarla yüksek bağlantılı benek değerleri değiştiğinde, yerel gradyan işlecin sonucu kenarın

belirlenmesinde kullanılan yüksek değere sahiptir. Görüntü, $f(x,y)$ şeklinde bir fonksiyon olarak ifade edildiğinden, görüntünün gradyanı Denklem (2.87) ile gösterilir [116,117].

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} df/dx \\ df/dy \end{bmatrix} \quad (2.87)$$

Gradyanın boyu,

$$mag(\nabla f) = \sqrt{G_x^2 + G_y^2} \quad (2.88)$$

$$mag(\nabla_f) = |G_x + G_y| \quad (2.89)$$

olarak hesaplanır.

Gradyanın yönü ise Denklem (2.90)'a göre hesaplanır.

$$\theta(x, y) = \tan^{-1} \left(\frac{G_y}{G_x} \right) \quad (2.90)$$

Gradyan işlemi için x eksen ve y eksen yönündeki gradyanı hesaplamak için iki maske gerektirmektedir. Görüntüde gradyan yaklaşık olarak,

$$G_x = f(i + 1, j) - f(i, j)$$

$$G_y = f(i, j + 1) - f(i, j) \quad (2.91)$$

şeklinde hesaplanabilir.

Literatürde türeve bağlı birçok kenar algılayıcılar geliştirilmiştir. Literatürde sıklıkla kullanılan kenar algılayıcıları Roberts, Sobel, Prewitt ve Canny kenar algılayıcılarıdır [115].

2.7.1. Roberts Operatörü

Roberts operatörü çapraz farkları hesaplamak için 2x2'lik komşuları kullanır ve operatörün maskeleri aşağıdaki gibidir [116,117].

$$\begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \text{ ve } \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} \quad (2.92)$$

Bu maskeler, sol üst elemanı işlenmekte olan piksel üzerine gelecek şekilde oturtulur. Bu iki maskenin mutlak değerlerinin toplamı ile gradyan boyu hesaplanır [115].

$$mag(\nabla f) = |f(i + 1, j + 1) - f(i, j)| + |f(i + 1, j) - f(i, j + 1)| \quad (2.93)$$

2.7.2. Sobel Operatörü

3x3'lük komşulukları kullanan bir operatördür. Sobel operatörü evrişim maskeleri Denklem (2.94)'deki gibidir [116,117].

$$\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \text{ ve } \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (2.94)$$

Bu iki maske görüntüye ayrı ayrı uygulanır, böylece G_x ve G_y değerleri aşağıdaki gibi bulunur [115].

$$\begin{aligned} G_x &= [f(i-1, j-1) + 2f(i-1, j) + f(i-1, j+1)] - [f(i+1, j-1) + 2f(i+1, j) \\ &\quad + f(i+1, j+1)] \\ G_y &= [f(i-1, j-1) + 2f(i, j-1) + f(i+1, j-1)] - [f(i-1, j+1) + 2f(i, j+1) \\ &\quad + f(i+1, j+1)] \quad (3.18) \end{aligned}$$

Gradyan boyu, $|G_x| + |G_y|$ şeklinde hesaplanabilir .

2.7.3. Prewitt operatörü

Sobel Operatörüne benzemektedir. Farklı maske katsayıları vardır [115,118].

$$\begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \text{ ve } \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad (2.95)$$

Bir görüntüdeki kenarları bulmanın temel amacı, görüntü içerisinde istenilen detayları ortaya çıkarmak, istenmeyen detayları ise ortadan kaldırmaktır. Ayrıca görüntüye kenar bulma algoritmalarını uygulamak suretiyle görüntüdeki renk geçişlerini keskinleştirmek ve böylece görüntü içindeki objeleri ya da farklılıkları elde etmek mümkün olmaktadır. Görüntü keskinleştirme; elektronik baskı, medikal görüntüleme, endüstriyel muayene, güçlü silahların otomatik hedef tayini gibi pek çok alanda kullanılan bir görüntü işleme tekniğidir [114,115].

3. DERİN ÖĞRENME

Son yıllarda yapay zeka, gerek akademik dünyada, gerekse iş dünyasında ve daha birçok alanda popüler bir araştırma konusu haline gelmiştir. Yapay zeka, uzun yıllardır birçok alanda kullanılmasına rağmen günümüzde sıklıkla anılmasının ve ilgi çekici bir araştırma konusu haline gelmesinin nedenlerinden biri olarak derin öğrenme kavramının olduğu düşünülebilir. Derin öğrenme, insan beyninin yapısından esinlenerek, sinir ağlarının bir uyarlaması ve makine öğrenmesi algoritmalarından birisidir [110]. Geleneksel olarak, makine öğrenmesi algoritmaları, ham verilerden çıkarılan özellikler veya bu özelliklerin dönüşümünden elde edilen özellikler kullanılarak eğitilir. Derin öğrenme algoritmaları ise doğrudan ham verilerden otomatik olarak anlamlı özellikleri öğrenirler. Bu durum, derin öğrenme yaklaşımları ve klasik makine öğrenmesi yaklaşımları arasındaki temel farktır.

Derin öğrenme kavramı, literatürde yapılmış olan tanımlara dayanılarak genelleştirilecek olursa, insan beyninin karmaşık problemleri analiz etme, inceleme, öğrenme ve karar verme gibi becerilerine sahip, kontrollü veya kontrolsüz olarak özellik çıkarımı ve sınıflandırma işlemlerini büyük miktarlardaki verileri kullanarak yapabilen makine öğrenmesi algoritmaları olarak tanımlanabilir. Ayrıca derin öğrenme algoritmaları YSA'ların yapısal olarak daha karmaşık hali olarak düşünülebilir. Algoritma bu sayede; öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesi gibi özellikler ile donatılarak geliştirilebilir bir hale gelmiştir [119].

Derin öğrenme algoritmalarının dezavantajı büyük miktarda veriye ve büyük miktardaki veriyi işleyebilecek hesaplama gücü yüksek olan donanım birimlerine ihtiyaç duymasıdır. Endüstri ve akademik çevrelerdeki veri bilimciler görüntü sınıflandırma, video analizi, konuşma tanıma ve doğal dil öğrenme süreci dâhil olmak üzere çeşitli uygulamalarda Grafik İşlemci Üniteleri (GIÜ) kullanmaktadır. Özellikle büyük miktarlarda etiketlenmiş eğitim verilerinden özellik çıkarımı yapabilen derin öğrenme sistemleri için yüksek bütçeler gerekmektedir [120].

Düşük seviyeli özelliklerden, yüksek seviyeli özellikler türeterek verileri sınıflandırmayı ve tanımayı amaçlayan derin öğrenme algoritmaları, geleneksel makine öğrenme yöntemlerinin aksine, muazzam büyüklükteki veriler üzerinde problemleri çözmede ve bu verilerin analizinde büyük bir avantaj sağlamaktadır[121].

3.1. Veri Arttırma

Bu bölümde veri artırma süreci ayrıntılı olarak ele alınmıştır. Yüksek kaliteli ve bol veri, çeşitli derin öğrenme mimarilerinin etkili bir şekilde koşturulması için bir anahtardır. Yapılan çalışmalarda, kullanılan veri setleri, derin öğrenme mimarisini besleyecek ve istenen doğruluğu sağlayacak yeterli miktarda veriden yoksundur [42]. Veri tabanında ki verileri arttırmak ve istenen doğruluğu elde etmek için mevcut verileri Çizelge 3.1’de sunulan sekiz farklı veri artırma tekniğini kullanılarak veri tabanı genişletilebilir. Genelde kullanılan veri artırma yöntemleri; döndürme, çevirme, çarpıklık ve geometrik dönüşümlerdir. Gürültü değişmezliği için Gaussian bulanıklık, keskinleştirme, kenar algılama ve kabartma gibi dört yöntem kullanılır[122].

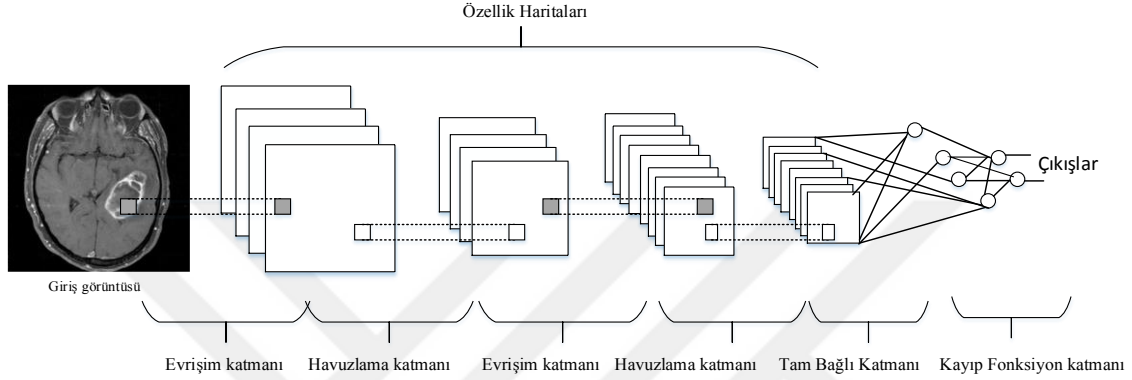
Çizelge 3.1. İlgili parametreler ile veri arttırma teknikleri

Sıra no	Veri artırma tekniği	Parametreler
1	Döndürme (açı)	-90°, -45°, 45°, 90°
2	Çevirme	Yukarı, Aşağı, Sağ, Sol
3	Gaussian bulanıklık (sigma değeri)	0.25, 0.50, 1.0, 2.0
4	Keskinleştirme	0.50, 1.00, 1.50, 2.0
5	Kenar algılama (alfa değeri)	0.25, 0.50, 0.75, 1.00
6	Kabartma (güç değeri)	0.50, 1.00, 1.50, 2.0
7	Çarpıklık (eğimlilik)	Sol, Sağ, İleri, Geri
8	Kırpma (eksen & değer)	X-ekseni 10°, Y-ekseni 10°

3.2. Evrişimsel Sinir Ağları

Son zamanlarda, popüler derin öğrenme sinir ağları yöntemlerinden olan Convolutional Neural Networks (CNN) ifadesi Türkçe olarak yapılan bilimsel çalışmalarda Evrişimsel Sinir Ağları (ESA) ya da Konvülyasyon Sinir Ağları (KSA) olarak adlandırılmaktadır. ESA, tıbbi görüntülerden hastalık teşhisi, sınıflandırma, nesne tanımlama, ses tanıma, metin ve video işleme, görüntü bölütleme, yüz bilgisi çıkarma, otomatik video sınıflandırma gibi pek çok bilgisayarlı görme çalışmalarında üstün performansından dolayı oldukça fazla kullanılmaktadır.

İnsanlar bir görüntüye baktığında görüntüde bulunan nesnelere, nesnelere renklerini ve şekillerini, aynı tipteki nesnelere sayısını ve pozisyonları gibi özelliklerini kolayca ifade edebilmektedir. Aynı görüntüye ait belirtilen ifadeler bilgisayar görme sistemleri tarafından ise sayı matrisleri olarak görülmektedir. ESA, çok sayıda gizli katman kullanarak görüntülerdeki farklı özelliklerin algılanmasını sağlamaktadır. Bundan dolayı görüntülerdeki nesnelere hangi nitelikte olduğu (canlı, cansız, insan, kuş, ağaç vb.) kolay bir şekilde ayırt edilebilmektedir.



Şekil 3.1. ESA'nın çalışma prensibi

ESA, görüntüye uygularken, ilke olarak, ileri beslemeli yapay sinir ağı kullanabilmektedir. Bununla birlikte, bir katmanın tüm düğümlerinden bir sonrakindeki tüm düğümlere olan bağlantıların olması son derece yetersizdir. Etki alanı bilgisine, yani görüntülerin yapısına dayanan bağlantıların dikkatli bir şekilde elenmesi, çok daha iyi performans sağlamaktadır. Bir ESA, verilerdeki mekansal ilişkileri korumaya yönelik, katmanlar arasında çok az bağlantı olan belirli bir yapay sinir ağı türüdür. ESA'ya giriş katmanı düzenlenir, her katman önceki katmanın küçük bir bölgesinde çalışır. İleri-Beslemeli Yapay Sinir Ağları'nın bir modeli olan ESA mimarisi Şekil 3.1'de verilmiştir. ESA mimarisi giriş katmanı, evrişim katmanları, havuzlama katmanları, tam bağlantılı katman ve çıkış katmanı olmak üzere beş temel işlemden oluşmaktadır. Şekil 3.1.'de gösterilen tipik ESA mimarisinde her bir evrişim katmanını, doğrusal olmayan bir fonksiyon olan Doğrultulmuş Lineer Birim (DLB) ve sonrasında havuzlama katmanı takip etmektedir. Bu mimari katmanları şu şekilde özetlenebilir:

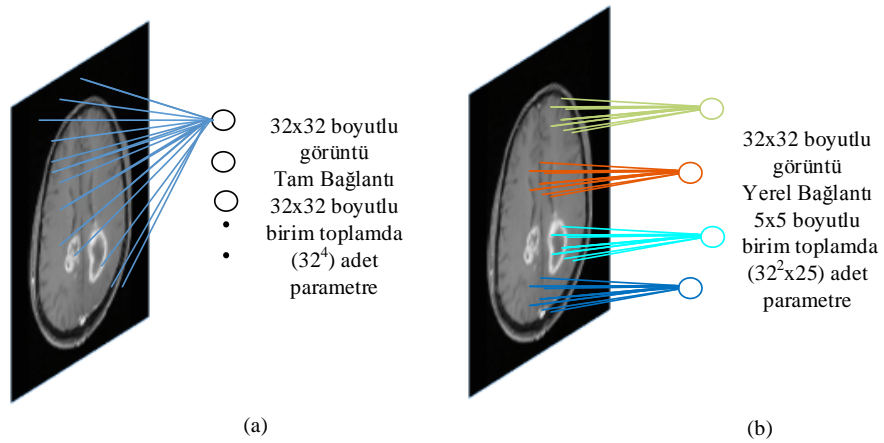
3.2.1. Girdi Katmanı

Bu katman mimarideki ilk katmandır. Bu katmanda veri ham olarak ağına verilmektedir. Tasarlanacak modelin başarımı için bu katmandaki verinin boyutu önem arz etmektedir. Giriş

görüntü boyutunun yüksek seçilmesi hem yüksek bellek ihtiyacını hem eğitim süresini hem de görüntü başına düşen test süresini uzatabilir. Bunun yanında ağ başarısını arttırabilir. Giriş görüntü boyutunun düşük seçilmesi bellek ihtiyacını azaltır ve eğitim süresini kısaltır. Fakat kurulacak ağın derinliği azalır ve performansı düşük olabilir. Görüntü analizinde hem ağ derinliği hem donanımsal hesaplama maliyeti hem de ağ başarısı için uygun bir giriş görüntü boyutu seçilmelidir.

3.2.2. Evrişim katmanları

Evrişim işlemi, başlangıçta rastgele değerlere sahip görüntü filtresi ile giriş görüntüsün evrişim edilmesi işlemidir. Evrişim katmanı geleneksel YSA'da bulunmayan ESA'nın temel yapı taşıdır. Tüm katmanlarda yer alan hücrelerin birbirleri ile bağlantılı olması ve bağlantı ağırlıklarının yenilenmesi yerine küçük boyutta evrişim işlemi kullanılmaktadır. ESA'nın en büyük avantajlarından biri evrişim katmanlarında paylaşılan ağırlıklardır. Bu da aynı özellik haritasında aynı filtreleri uygulamak demektir. Her filtrenin tüm girdi alanı boyunca aynı ağırlıkları paylaşmasını sağlayarak, yani her bir katmandaki translasyonel denkliği sağlayarak, öğrenilmesi gereken ağırlık sayısında ciddi bir azalma elde edilir. Bu ağırlık paylaşımının motivasyonu, görüntünün bir bölümünde görünen özelliklerin muhtemelen diğer kısımlarda da görünmesidir [10]. Ağırlık paylaşımı, gerekli olan bilgisayar belleğini azaltmaya ve bilgisayarlı görme görevlerindeki ESA performansını artırmaya yardımcı olmaktadır[123]. Şekil 3.2'de parametrelerin azaltılmasıyla ilgili ağırlık paylaşımını gösterilmektedir[10].



Şekil 3.2. Ağırlığı paylaşılan evrişim katmanları ile tam bağlı katmanın karşılaştırılması: (a) Tam bağlı katman parametre sayısı, (b) Ağırlığı paylaşılan evrişim katmanı parametre sayısı

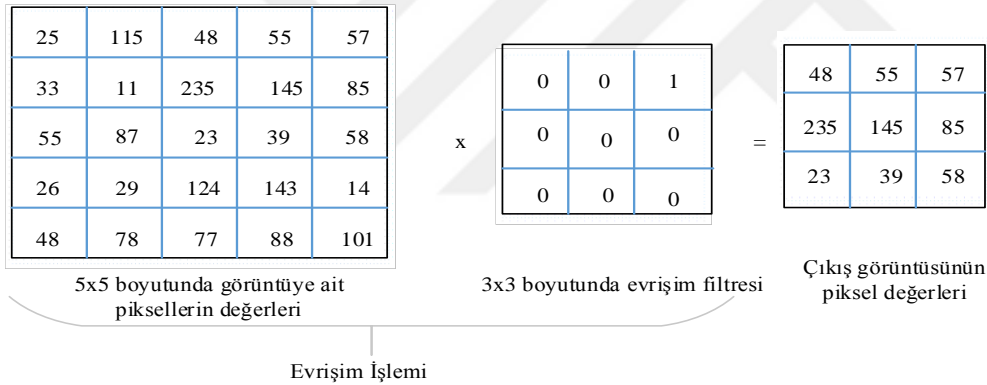
Görüntü üzerine uygulanacak evrişim işlemi $n \times n$ boyutundaki filtre w ile gösterilmektedir.

Evrişim işlem sonucu x , her resimdeki $l-1$ katmanındaki y piksel değerinin, filtre katsayıları ve sonuçları evrensel toplam şeklinde Denklem (3.1)'de gösterilmiştir [26].

$$x_{i,j}^l = \sum_a^n \sum_b^n w_{ab} \cdot y_{(i+a)(j+b)}^{l-1} \quad (3.1)$$

Denklem (3.1)'de kullanılan 'w' filtre katsayıları başlangıçta rasgele seçilir ve ağırlık eğitimi sırasında giriş-çıkış ilişkisine göre ayarlanır. Böylece filtre katsayıları eldeki problemi modelleyen katsayılar olarak ifade edilir.


Şekil 3.3'de, 5×5 boyutundaki girdi verisi üzerinde 3×3 boyutundaki evrişim filtresi gezdirilerek evrişim operatörünün uygulanışı ve çıkış görüntüsünün piksel değerleri gösterilmiştir.



Şekil 3.3. Evrişim operatörünün uygulanışı

3.2.3. Havuzlama Katmanı

ESA'nın havuzlama katmanında kullanılan filtreler ya ortalama değer ya da maksimum değer hesaplama prensibine göre çalışır. Havuzlama işlemi genellikle $2 \times 2, 3 \times 3, \dots, n \times n$ boyutunda filtreler uygulanarak yapılır. Ortalama havuzlama, filtre boyutunun alanına giren piksel değerlerin toplamının filtre pencere boyutuna bölünmesi prensibiyle çalışır. Maksimum havuzlama, filtre boyutunun alanına giren piksel değerlerinden en büyük olan değer belirlenmesi işlemidir. Minimum havuzlama ise filtre boyutunun alanına giren piksel değerlerinden en küçük olan değer belirlenmesidir. Havuzlama katmanlarına ait işlemlerin uygulanması Şekil 3.4'de gösterilmiştir [10].



Şekil 3.4. Ortalama ve maksimum havuzlama işlemi örneği

Evrişim işleminden sonraki resme havuzlama işlemi uygulanarak özellik vektöründe boyut indirgenmiş olur. Filtre boyutu F ve adım sayısı S olsun ve veri girdi boyutu $X \times Y \times Z$ olarak kabul edilsin. $\hat{X} \times \hat{Y} \times \hat{Z}$ boyutlu bir çıkış özellik haritası üretmek için Denklem (3.2) kullanılmaktadır [28].

$$\hat{X} = \frac{X - F + S}{S}, \hat{Y} = \frac{Y - F + S}{S}, Z = \hat{Z} \quad (3.2)$$

3.2.4. Aktivasyon Fonksiyonu

ESA'da en önemli işlemlerden birisi de aktivasyon fonksiyonunun uygulanmasıdır. Aktivasyon fonksiyonları, giriş yığınının yüksek düzeyde anlaşılmasını sağlayan ağlardaki doğrusalsızlıkları arttırmaktadır [10,114,115]. Ayrıca aktivasyon fonksiyonu, aşırı veri değerleri olmadan bir sonraki katmandaki nöronların bağımsızlığını arttıran bir özellik haritası çıkarmaktadır ve bu sayede tüm ağın istikrarı arttırılmaktadır. Aktivasyon işlemi için kullanılan Sigmoid fonksiyonu, piksel değerlerini 0 ile 1 aralığına bastırmaktadır. Özellikle büyük negatif değerler 0, büyük pozitif değerler ise 1 olma eğilimindedirler. Hiperbolik Tanjant fonksiyonu, Sigmoid fonksiyonuna benzer şekilde piksel değerlerini $[-1, 1]$ sayı aralığındaki bir reel değere bastırmaktadır. Bu fonksiyonda da doymuş aktivasyon problemi mevcuttur. Tanjant fonksiyonu, Sigmoid fonksiyonundan daha başarılı olmasına rağmen, uygulamada hala iyi performans göstermemektedir. Doğrultulmuş Doğru Birim fonksiyonu $\max(0, x)$ şeklinde tanımlanmaktadır [10,114,115]. Bu aktivasyon son zamanlarda ESA mimarisinde en çok kullanılan aktivasyon fonksiyonudur.

3.2.5. Çıktı Katmanı

Çıktı, büyük sinir ağının genel hatasını azaltan aşırı öğrenme problemini çözmek için sunulan güçlü bir algoritmadır [123]. Bir bırakma algoritmasında tek bir nöron diğer

nöronların oluşumlarına güvenmeyeceği için nöronların uyum karmaşıklıklarını azaltır. Böylece bırakma, daha sağlam özellikleri ve istikrarlı yapıyı öğrenebilmek için ESA'yı geliştirmiştir [10,114,115]. Bu durumda bırakma terimi bir sinir ağındaki birimlerin bazılarını bir sonraki katmana dâhil etmeme anlamına gelmektedir [125].

3.2.6. Kayıp Fonksiyonu

ESA'lardaki farklı görevler için farklı kayıp fonksiyonları seçilmektedir.

3.2.6.1. Öklid Fonksiyonu

Öklid kaybı, gerçek değerli regresyon görevleri için kullanılmaktadır. Tek bir reel sayı olduğu için Öklid kaybı ile ESA'nın son katmanı 1x1 boyutlu olmaktadır. Öklid kaybının matematiksel fonksiyonu Denklem (3.3)'de verilmiştir [10,116].

$$L = \frac{1}{2N} \sum_{i=1}^N \left\| \hat{d}_i - d_i \right\|^2 \quad (3.3)$$

\hat{d}_i ; indirgenmiş çıkışları, d_i ; hedef çıkışları ve N ise çıkış sayısını göstermektedir.

3.2.6.2. Softmax Fonksiyonu

Softmax kaybı, karşılıklı olarak k kadar sınıfı tahmin etmek için kullanılır ve $1 \times k$ boyutlu olasılık vektörünü çıkarır. Vektöre ait tüm olasılıkların toplamı bire eşit olmaktadır [10,116].

$$L = - \sum_j y_j \log(p_j) \quad (3.4)$$

Burada y_j ; j ' ninci sınıfa ait hedef $y_j=1$ olduğunda kesin doğrudur. Aksi halde $y_j=0$ ' dir. p_j , girdinin j ' ninci sınıfına ait tahmin edilen olasılığını belirtir. Tahmin edilen olasılık vektörü çıkarıldığında, Softmax fonksiyonunun matematiksel fonksiyonu Denklem (3.5)'de verilmiştir [10,116].

$$p_j = \frac{e^{o_j}}{\sum_k e^{o_j}} \quad (3.5)$$

Denklem (3.5)'deki o_j ; ESA'nın son katmanındaki j ' ninci çıktıyı, e ; ise exponansiyel ifadeyi belirtmektedir.

3.3. ESA Mimarileri

Yeni ve geliştirilmiş ESA mimarilerinin tasarımında, bu bileşenler giderek daha karmaşık ve birbirine bağlı şekillerde birleştirilmekte, hatta daha uygun işlemlerle değiştirilmektedir. Belirli bir görev için bir ESA tasarlarken, çözülmesi gereken görevin ve yerine getirilmesi gereken gereksinimlerin anlaşılması, verilerin ağa en iyi şekilde nasıl uygulanacağı ve bellek kullanımı da dâhil olmak üzere dikkate alınması gereken birden fazla faktör vardır.

Modern ESA'lerin diğer yaygın bileşenleri şunlardır:

Brakma düzenlenmesi: ESA'lerin performansında büyük bir artış sağlayan basit bir fikirdir. Bir takımdaki birkaç modelin ortalaması alınarak, tekli modellerin kullanılmasından daha iyi performans elde edilir. Brakma[126], sinir ağlarının stokastik örneklemesine dayanan ortalama bir tekniktir. Uygulama sırasında nöronları rasgele çıkararak, her uygulama verisi grubu için farklı ağlar kullanılarak biter ve uygulanan ağın ağırlıkları, ağın çoklu varyasyonlarının optimizasyonuna göre ayarlanmıştır.


Toplu normalleştirme: Bu katmanlar genellikle, ortalamayı çıkartarak ve her bir uygulama grubu için standart sapmaya bölünerek normalleştirilmiş aktivasyon haritaları üreterek, aktivasyon katmanlarından sonra konumlandırılır. Dahili toplu normalleştirme katmanları, ağı periyodik olarak aktivasyonlarını sıfır ortalamaya ve birim standart sapmasını değiştirmeye zorlar, çünkü uygulama grubu ağ için bir düzenleyici olarak çalışan bu katmanları vurur, uygulamayı hızlandırır ve daha dikkatli parametre başlatmaya daha az bağımlı hale getirir[127].

Modern derin öğrenmenin ilk günlerinde, Lenet [125] ve AlexNet [128] 'de olduğu gibi, yapı bloklarının çok basit kombinasyonları kullanılmaya eğilimindeydi. Daha sonraki ağ mimarileri çok daha karmaşıktır, her nesil önceki mimarilerden gelen fikirler ve içgörüler üzerine inşa edilir ve son teknoloji güncellemelerle sonuçlanır.

Bu sinir ağları tipik olarak, tümü NVIDIA'nın CUDA platformu ve CUDNN kütüphanesi üzerine kurulu makine öğrenme araştırmalarına hâkim olan az sayıda yazılım çerçevesinden birine veya bir kaçına uygulanır. Çerçeveler açık kaynak kodlu ve aktif gelişme altındadır.

3.3.1. AlexNet

Bilgisayarlı görmede derin öğrenmenin ilk popüler kullanımı AlexNet mimarisi ile başlamıştır. 10 milyon görüntü ve 1000 farklı görüntü kategorisi olan ImageNet veri tabanındaki görüntüleri sınıflandırmayı amaçlamıştır [129]. 2012 yılında ImageNet yarışmasını, derin öğrenme mimarisi ile tasarlanan AlexNet mimarisi kazanmıştır. AlexNet'in bu başarısı herkesi heyecanlandırmıştı ve görüntü sınıflandırma performansı açıkça önceki yöntemlerden daha üstündü. 25 katmandan oluşan Derin Evrişimsel Sinir Ağı (DESA)'da 5 adet evrişim katmanı, 3 adet maksimum havuzlama katmanı, 2 adet çıktı katmanı, 3 adet tam bağlı katman, 7 adet relu katmanı, 2 adet normalizasyon katmanı, softmax katmanı, giriş ve sınıflandırma(çıkış) katmanından oluşmaktadır. Giriş katmanında yer alacak olan görüntü 227x227x3 boyutlarındadır. Son katmanda ise sınıflandırma yapılarak giriş görüntüsündeki sınıflandırma sayısı değeri verilir. Şekil (3.5)'de AlexNet'e ait katmanlar gösterilmektedir. ImageNet veritabanı için %80 doğruluğu yakalamış bir derin öğrenme algoritmasıdır.




Şekil 3.5. Alexnet mimarisinin dizilimi

Havuzlama adımında pikseller maksimum değere göre değerlendirilir. En son katman 1000 sınıfı temsil etmektedir. AlexNet, 60 milyon parametre ve 650.000 nöron içeren büyük bir ağ yapısıdır. Bu parametreleri eğitmek için Krizhevski [26] birçok iyileştirme yapmıştır. AlexNet ayrıca ReLU aktivasyon fonksiyonu ve dropout tekniğinin derin sinir ağlarında kullanımının öncüsüdür [123].

3.3.2. VGG16

VGG16 derin öğrenme mimarisi daha derin ağların daha iyi ağlar olduğu fikrine dayanarak tasarlanmıştır. AlexNet'e göre daha yüksek doğruluk performansı sağlasa da çok fazla parametresi olduğundan (yaklaşık 140 milyon) çok fazla bellek kullanım ihtiyacı olmuştur. Diğer yandan AlexNet'e göre daha küçük filtreler kullanılmıştır. Bu mimari tüm evrişim katmanlarında değişken sayıda 64, 128, 256 filtre sayısı ile sabit 3x3 boyutlu filtreler kullanılmaktadır. VGG16, 13 evrişim 3 tam bağlı katmanından oluşan bir ağıdır. Maksimum

havuzlama, tam bağı katman, Relu katmanı, çıktı katmanı ve Softmax katmanlarıyla birlikte toplamda 41 katmandan oluşmaktadır [126]. Girdi katmanında yer alacak görüntü 224x224x3 boyutundadır. Son katman ise sınıflandırma katmanıdır. Şekil 3.6'da VGG-16 derin öğrenme mimarisinin çalışma prensibi verilmiştir.



Şekil 3.6. VGG16 derin öğrenme mimarisinin çalışma prensibi

3.3.3. Yerel Alıcı Alanlar - Aşırı Öğrenme Makinesi

Geriye yayılım öğrenme algoritması kullanan ESA ile literatürde çok sayıda nesne tespit çalışması bulunmaktadır. ESA'nın eğitim sürecinin uzun olması ve eğitim sürecinde tek bir çözüme takılma ihtimali önemli dezavantajdır [129]. Yerel alıcı alanlar (YAA) bilgisinin AÖM içine entegre edildiği YAA-AÖM yapısı, ESA'ya alternatif bir model olarak önerilmiştir [130,132]. Yerel Alıcı Alanlar Aşırı Öğrenme Makinesi (YAA-AÖM), temel olarak birbirinden bağımsız iki farklı yapıyı bünyesinde barındırmaktadır [130,131]. İlk yapı, öğrenmenin olmadığı, evrişim ve havuzlama katmanlarının yer aldığı yapıdır. İkinci yapı ise en küçük kareler çözümü ile β 'nin analitik olarak hesaplandığı yapıdır. Birinci yapıda kullanılan havuzlama için kare/karekök işlevi kullanılmaktadır.

Birinci yapı: Bu yapıda öğrenme olmamaktadır yani bu yapıda ağırlık değerlerinin yenilenmesine ihtiyaç duyulmamaktadır. Kullanılan K adet evrişim filtresinin katsayıları başlangıçta rasgele seçilir. Eğer öznitelikleri çıkarılacak giriş görüntüsünün boyutu $d \times d$ ve evrişim filtresi boyutu $r \times r$ ise, evrişim katmanı sonunda $(d - r + 1) \times (d - r + 1) \times K$ boyutlu öznitelik haritası elde edilir [130,133]. Havuzlama katmanında, pencere boyutuna göre öznitelikler havuzlanır. Evrişim katmanında Y sonraki evrişim katmanının değerini, X de önceki katmanın değeri olarak varsayırsa evrişim denklemi Denklem (3.6)'daki gibi ifade edilir. Evrişim işleminden sonra yapılan havuzlama işlemi verinin boyutunu indirgemek için kullanılmaktadır.

$$y_{ij} = g\left(\sum_{m=1}^r \sum_{n=1}^r x_{i+m-1, j+n-1} \cdot w_{m,n} + b\right), \quad i, j = 1, \dots, (d - r + 1) \quad (3.6)$$


İkinci yapı: Birinci yapıda her bir giriş görüntüsü için elde edilen öznelikler bir matriste birleştirilmiş ve veri seti oluşturulmuştur. Bu yapıda ise sadece AÖM'nin gizli katman ile çıkış arasındaki ağırlık vektörü β 'nin analitik olarak hesaplanması yapılmaktadır [135]. Diğer bir ifade ile önceki aşamada elde edilen öznelik matrisi, $H \in R^{N \times (d-r+1)^2}$ matrisi olarak kabul edilir ve β analitik olarak Denklem (3.7)'deki gibi hesaplanır;

$$\beta = \begin{cases} H^T \left(\frac{I}{C} + HH^T \right)^{-1} T & \text{eğer } N \leq K \cdot (d-r+1)^2 \\ \left(\frac{I}{C} + HH^T \right)^{-1} H^T T & \text{eğer } N > K \cdot (d-r+1)^2 \end{cases} \quad (3.7)$$

Denklem (3.7)'de eğitim veri seti için sınıf etiketleri T, birim matrisi I ve regülasyon katsayısı C olarak adlandırılır.

3.3.4. GoogleNet

GoogleNet yapısındaki Inception modüllerinden dolayı karmaşık bir mimaridir. GoogleNet 22 katmanlı ve %5.7 hata oranı ile ImageNet 2014 yarışmasının kazananı olmuştur. VGG16 derin öğrenme algoritmasından daha hızlı olduğu görülmektedir. Alexnet'ten 12 kat daha fazla parametre içermektedir. Bu mimarinin en büyük katkısı toplam 22 katman ile parametre sayısı 60 milyon olan AlexNet mimarisine karşılık parametre sayısını 5 milyona düşürmesidir (yaklaşık 12 kat daha az parametre). Girdi katmanında yer alacak görüntü 224x224x3 boyutundadır. Evrişim katmanında 1x1, 3x3 ve 5x5 boyutunda filtreler kullanılmaktadır. 3x3 boyutunda havuzlama kullanılmaktadır. Aktivasyon için doğrusal aktivasyon kullanılmaktadır. Inception-v1, Inception-v2, Inception-v3 ve Inception-v4 olmak üzere dört versiyonu vardır. GoogleNet mimarisinin çalışma prensibi Şekil 3.7'de gösterilmiştir.




Şekil 3.7. GoogleNet mimarisinin çalışma prensibi [122]

3.3.5. U-NET

Olaf Ronneberger, Thomas Brox, Philipp Fischer ve diğeri, tam bir evrişim ağından geliştirilen ve daha küçük eğitim setleri üzerinde iyi bir etkisi olan U-NET ağ yapısını önermişlerdir [130,131]. U-NET'in eğitim süresi nispeten kısadır, basit bir yapıya ve daha az parametreye sahiptir ve diğeri ağlara kıyasla daha az uygulama verisi talep etmektedir. U-NET mimarisi 19 evrişim katmanı dâhil olmak üzere toplam 45 katmana sahiptir. Genişleme ağı ve daralan ağ, U-NET'te birbirleriyle ilişkilidir. Evrişim ağı esas olarak, alt-örnekleme işleminden sorumlu olan yüksek boyuttaki özellik bilgisini alır. Aşağı örnekleme işlemi, esas olarak 3x3'lük iki evrişim tabakasından ve 2x2'lik bir havuzlama tabakasından oluşur ve Relu fonksiyonu, aktivasyon fonksiyonu olarak alınır. Aşağı örnekleme aksine, görüntü boyutu örneklemeden iki kat daha büyüktür, ancak özelliklerin sayısı yarı yarıya azalır. Örnekleme yaparken, her bir çıktı özellik haritası, eksik sınır bilgisini doldurmak için daralma ağının alt-örneklemelerinin her biri için ilgili özellik haritası ile birleştirilir. Son olarak, 1 x 1 evrişim katmanı tarafından elde edilen özellik haritası ilgili kategoriye eşlenir.

3.3.6. ResNet

Derin öğrenme üzerine araştırma yapan uzmanlar derin ESA mimarisi oluştururken katman sayısından kaynaklı problemler ile karşılaşmışlardır. Önceden tasarlanan derin öğrenme mimarilerinde katmanlar eklendikçe belirli bir seviyeye kadar mimarilerin performansları artarken bir noktadan sonra performanslarında hızlı bir düşüş görülmüştür. Sıfırlanan gradyan olarak bilinen bu problem ağ eğitimleri esnasında geriye yayılımdan kaynaklanmaktadır. Görüntü tanımadaki en son teknoloji ResNet mimarisi de önceki mimariler gibi “ağ ne kadar derin olursa performans o kadar artar” fikri üzerine kurulmuştur. Ancak artan ağ derinliği ile birlikte, bir önceki katmandan gelen gradyanlara göre her katmanın gradyanı zincirleme kuralı ile hesaplandığından sıfırlanan gradyan problemi de artmaktadır. Böylece katman sayısı arttıkça gradyan değerleri küçülür ve sıfıra yaklaşır. Bu problemi çözmek için Residual (artık) bloklardan oluşan ResNet mimarisinde, gradyan hesaplamak yerine $f(x)$ fonksiyonuna aritmetik olarak x girdisi ekleyerek kısa yol bağlantısı sunmaktadır. Böylece, artık blokta x girişinin evrişim-DAE-evrişim serisinden sonra bir $f(x)$ sonucu vermektedir. Şekil 3.8 de gösterildiği gibi bu sonuç daha sonra orijinal x girişine eklenir ve $f(x)+x$ olarak bir sonraki katmana kaybolmadan geçilmesi sağlanır.



řekil 3.9. ResNet mimarisinin alıřma prensibi

izelge 3.2, yapı bloklarının nasıl birleřtirilebileceđini ve alanın nasıl hareket ettiđini gsteren bazı bilinen ESA mimarilerinin kısa bir listesini iermektedir.

Çizelge 3.2. ESA mimarilerinin kapsamlı olmaktan uzak, kronolojik olmayan bir listesi ve bazı üst düzey açıklamalar.

AlexNet	[128]	2012 Imagenet yarışmasını büyük bir farkla kazanarak mevcut derin öğrenme akımını başlatan ağıdır. Dikkate değer özellikleri arasında RELU'ların kullanımı, bırakma düzenlenmesi, birden fazla GPU'ya hesapların bölünmesi ve eğitim sırasında veri artırmanın kullanılması sayılabilir. AlexNet'in nispeten küçük bir modifikasyonu olan ZFNet [130], 2013 ILSVRC yarışmasını kazanmıştır.
VGG	[131]	Daha küçük filtre çekirdekleri ve dolayısıyla daha derin ağlar kullanılması ve daha derin ağların sığ sürümlerde ön eğitim kullanarak eğitilmesi fikri yaygınlaşmıştır.
GoogLeNet	[127]	[132] fikrine dayanarak, ağlardaki ağlar gibi ESA'lerde katmanları daha yaratıcı bir şekilde yığılma fikrini desteklemiştir. Nispeten standart bir mimaride (gövde adı verilen), GoogLeNet, girişe çoklu farklı filtre boyutlarının uygulandığı ve sonuçlarının birleştirildiği çoklu başlangıç modülleri içerir. Bu çok ölçekli işleme, modülün aynı anda farklı detay seviyelerinde özellikler çıkarmasını sağlar.
ResNet	[133]	Daha derin ağları eğitmeyi mümkün kılan atlamalı bağlantılar olarak tanımlanabilir. 152 kat derinliğinde bir ResNet, 2015 ILSVRC yarışmasını kazanmış ve 1001 katmanı olan bir sürümü başarıyla eğitmiştir. Standart yola ek olarak bağlantıların atlanması, ağa aktivasyonları katmandan katmana (daha doğrusu ResNet bloğundan ResNet bloğuna kadar) kopyalamak için bir seçenek sunar, veriler katmanlardan geçerken bilgileri korur. Bazı özellikler en iyi şekilde sığ ağlarda üretilirken, diğerleri için daha fazla derinlik gerekir. Bağlantı atlama, aynı anda her ikisini de kolaylaştırır, böylece girdi verilerinin beslenmesi sırasında ağın esnekliğini artırır.
Highway nets	[134]	Yolluk ünitelerine dayanarak derinliği arttırmanın bir başka yolu, Uzun Kısa Süreli Bellek (UKSB) tekrarlayan ağlarından bir fikir olan ve ağıdaki atlama bağlantılarının optimizasyonunu sağlayan bir fikirdir.
DenseNet	[135]	ResNet'in fikirlerine dayanır, ancak bir katman tarafından üretilen aktivasyonları daha sonraki katmanlara eklemek yerine, basit bir şekilde bir araya getirilir. Bu nedenle, önceki katmanlardan gelen aktivasyonlara ek olarak orijinal girdiler, her tür katmanda tutulur. Bu özellik yeniden kullanımını teşvik eder ve verilen bir derinlik için parametre sayısını azaltır. Bu nedenle, DenseNets daha küçük veri kümeleri için özellikle uygundur (örneğin, Cifar-10 ve Cifar-100'de diğerlerinden daha iyi performans gösterir).
SENet	[136]	ILSVRC 2017 yarışmasını kazanan Sıkıştırma ve Uyarma Ağları, ResNext üzerine inşa edilir, ancak ağı daha önceki ağların eklediği her özellik haritasını tartmak için kullanabileceği eğitilebilir parametreler ekler. Bu SE-blokları, ağı kanal ve mekansal bilgiyi ayrı ayrı modellemesini sağlar ve model kapasitesini artırır. SE-blokları, herhangi bir ESA modeline kolayca eklenebilerek hesaplama maliyetlerinde düşüş olabilir.
NASNet	[137]	Bir sinir ağı tarafından tasarlanan, daha önceki insan yapımı tüm ağları ILSVRC yarışmasında yenen bir ESA mimarisidir. Bir Google Brain'in mimarlık tasarımına yönelik takviye öğrenme yaklaşımı olan AutoML kullanılarak yaratılmıştır [138]. Bir kontrolör ağı (tekrarlayan bir sinir ağı), belirli bir görev için belirli bir seviyede performans göstermeyi amaçlayan mimariler önerir ve deneme yanılma yoluyla daha iyi ve daha iyi modeller önermeyi öğrenir. NASNet, Cifar-10'a dayanıyordu ve nispeten mütevazî hesaplama taleplerine sahipti, ancak yine de ILSVRC verilerinde önceki teknolojiden daha iyi performans göstermiştir.

Çizelge 3.2. ESA mimarilerinin kapsamlı olmaktan uzak, kronolojik olmayan bir listesi ve bazı üst düzey açıklamalar. (devamı)

YOLO	[139]	Görüntülerde eşzamanlı nesne algılama ve sınıflandırma yapmak için yeni, basitleştirilmiş bir yol sunmuştur. Doğrudan görüntü üzerinde çalışan sınırlayıcı kutuları ve sınıf olasılıklarını veren tek bir ESA kullanır. Başlangıç modülleri ve ağı daha küçük bir versiyonunun ön hazırlığı dâhil olmak üzere yukarıdaki ağlardan birkaç eleman içerir. Gerçek zamanlı işlemeyi sağlamak için yeterince hızlıdır. YOLO, model boyutunu küçülterek hız için kesin işlem yapmayı kolaylaştırmaktadır. YOLOv3-tiny, standart bir benchmark veri setinde saniyede 200 kare üzerindeki görüntüleri işlerken, yine de makul tahminler üretmeyi başarmıştır.
U-net	[130,131]	2B görüntülerde segmentasyon için çok popüler ve başarılı bir ağıdır. Bir giriş görüntüsüyle beslendiğinde, devir evrişimler kullanılarak orijinal boyutuna ulaşana kadar örneklemeden önce, ilk önce geleneksel boyutta bir ESA içinden alt örnekleme yapılır. Ayrıca, ResNet'in fikirlerine dayanarak, alt örneklemeden örnekleme yollarına özellikleri birleştiren atlama bağlantıları vardır.

4. UYGULAMALAR

Yapılan bu tez çalışmasında beyin MR görüntülerinden tümör tespiti ve tümörlerin türlerine ve seviyelerine göre sınıflandırılması yapılmıştır. Yapılan çalışmaları iki ana başlıkta gruplayabiliriz. İlk grup beş aşamadan oluşmaktadır. Bunlar ön işlem, bölütleme, özellik çıkarımı, kenar tespiti ve sınıflandırma aşamalarıdır. İkinci grup ise iki aşamadan oluşmaktadır. Bunlar derin öğrenme tabanlı tümör tespiti ve tümörlerin sınıflandırılmasıdır.

Programların koşturulduğu bilgisayar, Intel Core i7-4810 MİB ve 8 GB bellek özelliklerine sahiptir. Program kodlamaları MATLAB 2017-b ortamında yapılmıştır

4.1. Kullanılan Veri Setleri

Tez kapsamında kullanılan ilk veri seti BRATS 2015 arşivinde yer alan Benchmark veri setidir [20]. Benchmark veri seti; BRATS 2012, 2013 ve NIH Kanser Görüntüleme Arşivi (TCIA)'dan alınan verileri içermektedir. Her hastaya ait T1, T2, T1c (Kontrast ağırlığı arttırılmış) ve Flair ağırlıklı beyin MR görüntüleri yer almaktadır. MR görüntüleri 1mm kalınlığında ve 256x256 piksel çözünürlüğündedir. Veri seti tümör çeşitleri ve hastalık seviyelerine göre kategorize edilmiştir. Aynı zamanda uzmanlar tarafından doğrulanmış beyin tümör görüntüleri de yer almaktadır.

Kullanılan ikinci veri seti REMBREDANT veri setidir [23]. REMBREDANT veri seti National Cancer Institute tarafından paylaşılan The Cancer Imaging Archive (TCIA) veri tabanına ait bir veri setidir. TCIA medikal görüntüler içeren paylaşıma açık geniş bir arşivdir. REMBRANDT veri setine ait tüm görüntüler 256x256 piksel çözünürlüğünde ve 16 bit gri seviyede dijital hale getirilmiştir. Her bir kesit 5 mm kalınlığındadır. Görüntüler DICOM ve JPG formatındadır.

Kullanılan üçüncü veri seti ise Harvard veri setidir [22]. Harvard veri seti; T1, T2, Flair ağırlıklı olmak üzere 3 boyutlu MR görüntülerinin yer aldığı veri setidir. Arşivdeki görüntüler hastalık ve görüntüleme yöntemine göre organize edilmiştir. Veri setine ait tüm görüntüler 256x256 piksel çözünürlüğünde ve DICOM dosya formatındadır [37].

Kullanılan dördüncü veri seti, National Cancer Institute tarafından paylaşılan The Cancer Imaging Archive (TCIA) veri tabanına ait RIDER adlı veri setidir. Bu sette 126 hastaya ait beyin MR görüntüleri yer almaktadır. Veriler Henry Ford Hastanesi (RETRO) ve TJU Enstitüsü tarafından hazırlanmıştır. Astrocytoma, GBM, ve Oligodendrogliomas

rahatsızlıklarına ve dört farklı tümör seviyelerine ait beyin MR görüntüleri yer almaktadır [135,136].

Kullanılan beşinci veri seti, Figshare adlı beyin MR görüntülerinin yer aldığı veri setidir. 233 hastadan alınan üç farklı tümöre ait T1 ağırlıklı 3064 adet görüntü yer almaktadır [143]. Meningioma tümörlerine ait 708, glioma tümörlerine ait 1426, ve hipofiz tümörlerine ait 930 adet beyin MR görüntüsü yer almaktadır.

Kullanılan son veri seti farklı hastalıklar ile glioma tümörlerine ait beyin MR görüntülerinin yer aldığı AANLIB veri setidir [22].

4.2. Kullanılan Performans Kriterleri

Tez çalışmasında önerilen yöntemlerin tümör tespitindeki performansını hesaplamak için kullanılan benzerlik başarımları kriterleri Denklem (4.1-4.5)'deki doğruluk, duyarlılık, özgüllük, yanlış pozitif oranı ve yanlış negatif oranlarıdır [1]. Tümör piksellerinin doğru yeri (DP) ile ifade edilmiştir. Doğru Negatif (DN) tümör dışı pikselleri belirtmektedir. Yanlış Pozitif (YP), sağlıklı piksellerin tümör dokusu pikseli gibi algılanmasını temsil etmektedir. Tasarlanan sistem tarafından tespit edilmeyen tümör pikselleri Yanlış Negatif (YN) olarak gösterilmiştir [1].

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4.1)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4.2)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (4.3)$$

$$\text{Yanlış pozitif oran} = 1 - \text{Özgüllük} \quad (4.4)$$

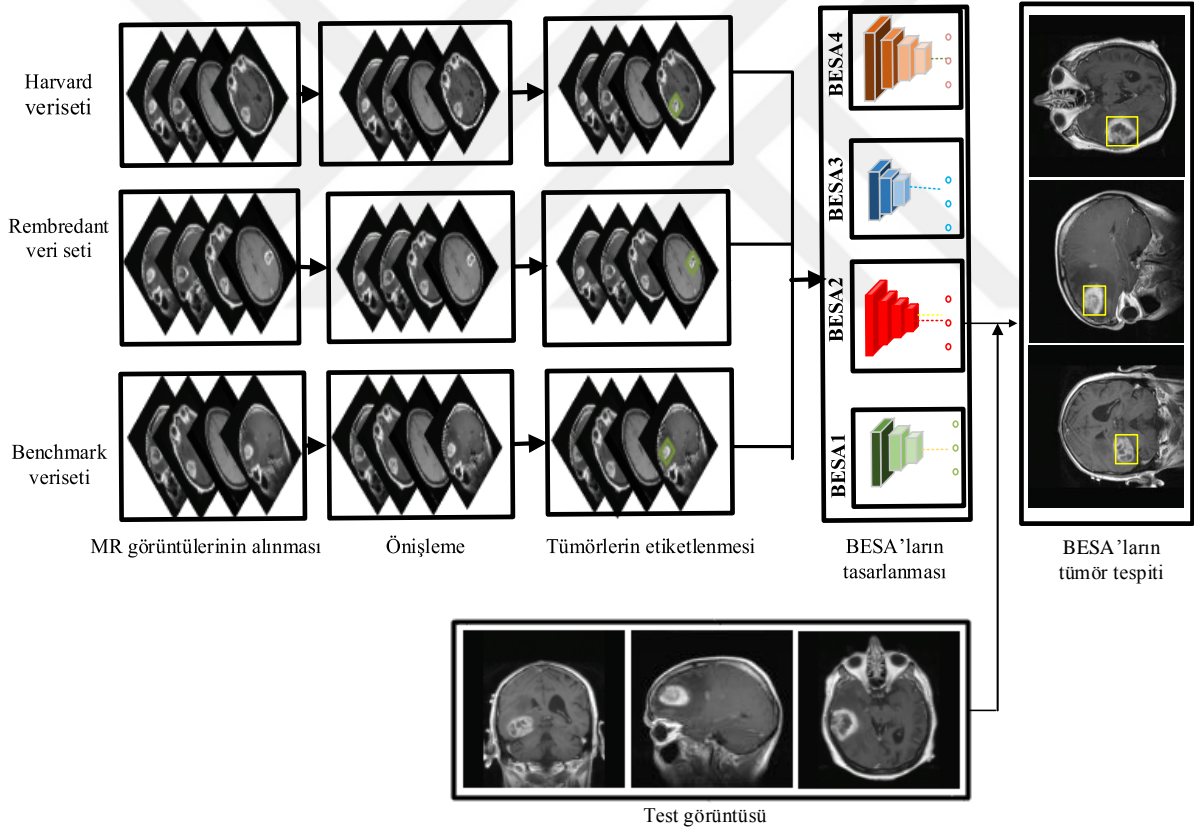
$$\text{Yanlış negatif oran} = 1 - \text{Duyarlılık} \quad (4.5)$$

$$J_{sim} = \frac{|G \cap S|}{|G \cup S|} = \frac{b}{a+b+c} \quad (4.6)$$

Ayrıca tasarlanan sistemlerin beyin MR görüntülerini sınıflandırma başarımları da Denklem (4.1-4.6)'daki kriterlere göre yapılmıştır. Sınıflandırmada P bir tümör türünü N ise diğer tümör türü ya da türleri olarak kabul edilmiştir.

4.3. Uygulama 1: Bölgesel Evrimsel Sinir Ağları ile Beyin MR Görüntülerinden Tümör Tespiti

Yapılan bu çalışmada [10] Bölgesel Evrimsel Sinir Ağları (BESA) tabanlı beyin MR görüntülerinden otomatik tümör tespit sistemi geliştirilmiştir. BESA, ESA mimarisini kullanan bir yapı olmakla birlikte giriş görüntüsüne ek olarak ilgilenilen bölgenin de giriş olarak verildiği bir yapı olarak düşünülebilir. Önerilen beyin tümörü tespit yöntemi, beş ana adımdan oluşmaktadır. Adımlar; veri setinin yüklenmesi, ön işlem, MR görüntülerinden tümörlerin manuel olarak etiketlenmesi, BESA'ların tasarımı ile tümör detektörünün elde edilmesi ve elde edilen tümör detektörünün değerlendirilmesidir. Önerilen yöntemin çalışma prensibi Şekil 4.1'de gösterilmiştir. Sistemin testi için asıl görüntü üzerinde tarama işlemi seçici arama (selective search) yöntemi ile gerçekleştirilmiştir.



Şekil 4.1. Önerilen yöntemin çalışma prensibi

İlk olarak MR görüntüleri ön işleme tabii tutulmuştur. MRG esnasında MR görüntüleri çeşitli gürültü kaynaklarından etkilenebilir. Olabilecek gürültüler yanlış yoğunluk düzeylerine neden olur ve sistemin başarımını olumsuz etkiler. Gürültü etkisinin minimize edilmesi için histogram germe işlemi uygulanmıştır.

Daha sonra tümörler, görüntü üzerinde manuel olarak etiketlenerek tümörlerin konumları ve büyüklükleri belirlenmiştir. Deneysel çalışmalarda Benchmark veri setinden 170 adet tümörlü beyin MR görüntüsü, REMBREDANT veri setinden 125 adet tümörlü beyin MR görüntüsü Harvard veri setinden 65 adet tümörlü beyin MR görüntüsü olmak üzere toplam 360 adet beyin MR görüntüsü kullanılmıştır. Bu görüntülere ait toplam 252 adet beyin MR görüntüsünde mevcut olan tümörlü bölgelerin manuel olarak işaretlenmesi gerçekleştirilmiştir.

Etiketlenen görüntüler 32x32 boyutunda yeniden boyutlandırılarak tasarlanan farklı BESA mimarilerinin girişine uygulanmıştır. Tasarlanan BESA'lara ait parametreler ve değerleri Çizelge 4.1'de sunulmuştur.

Çizelge 4.1. Tasarlanan BESA'ların parametreleri ve değerleri

Tasarlanan BESA	Evrişim filtre boyutu	Havuzlama filtre boyutu	Havuzlama operatörü	Aktivasyon Fonksiyonu	Çıktı katmanı	Kayıp Fonksiyon
BESA1	Mimari 7 katmandan oluşmaktadır. İlk katman giriş katmanıdır. İkinci katman 7 adet evrişim filtresinin bulunduğu evrişim katmanıdır. Daha sonraki katman havuzlama katmanı olup, havuzlama işlemi için 4x4'lük pencere boyutu seçilmiş ve maksimum değeri alan operatör kullanılmıştır. Dördüncü katman yine bir evrişim katmanı olup, 12 adet evrişim filtresi içermektedir. Beşinci katman yine bir havuzlama katmanı olup, havuzlama işlemi için 3x3'lük pencere boyutu seçilmiş ve maksimum değeri alan operatör kullanılmıştır. Evrişim katmanında kullanılan filtrelerin boyutu 5x5 olarak seçilmiştir. Aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmıştır. BESA1'in son katmanlarında sırasıyla, 64 nöronlu tamamen bağlı bir ağ yapısı ve bir Öklid kaybı katmanı almaktadır.					
BESA2	Mimari 8 katmandan oluşmaktadır. İlk katman giriş katmanıdır. İkinci katman 6 adet evrişim filtresinin bulunduğu evrişim katmanı olarak adlandırılır. Daha sonraki katman havuzlama katmanı olup, bu katmanda yarı örnekleme stratejisi ve maksimum değerin alınması benimsenmiştir. Dördüncü katman yine bir evrişim katmanı olup, 12 adet evrişim filtresini barındırmaktadır. Daha sonraki katman havuzlama katmanı olup, bu katmanda yarı örnekleme stratejisi ve maksimum değerin alınması benimsenmiştir. Altıncı katman yine bir evrişim katmanı olup, 12 adet evrişim filtresini barındırmaktadır. Evrişim katmanlarında kullanılan filtrelerin pencere boyutu 5x5 olarak seçilmiştir. Aktivasyon fonksiyonu olarak Doğrultulmuş Doğru Birim fonksiyonu kullanılmıştır. BESA'nın son katmanlarında sırasıyla, 64 nöronlu tamamen bağlı bir katman ve bir Softmax kaybı katmanı yer almaktadır.					

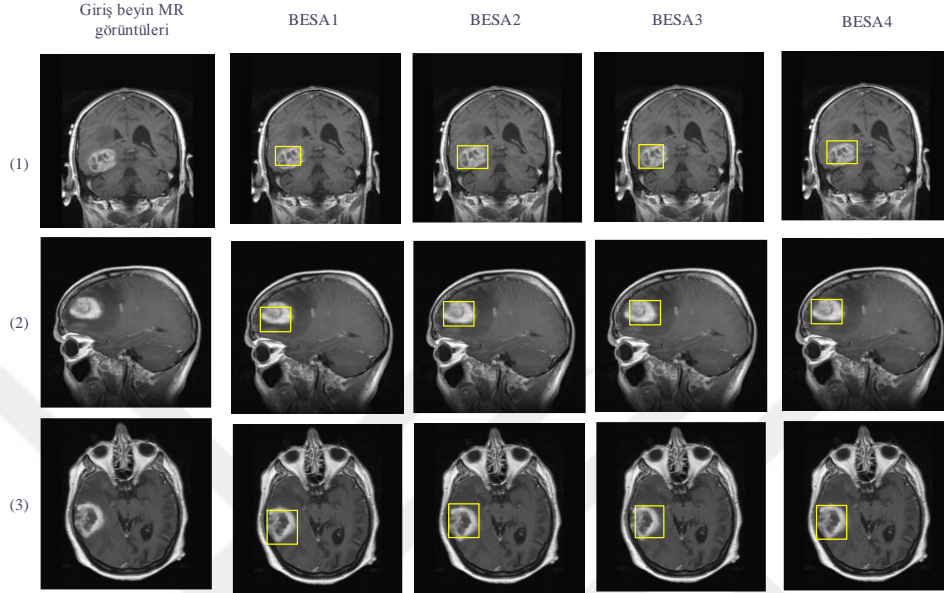
Çizelge 4.1. Tasarlanan BESA'ların parametreleri ve değerleri (devamı)

Tasarlanan BESA	Evrişim filtre boyutu	Havuzlama filtre boyutu	Havuzlama operatörü	Aktivasyon Fonksiyonu	Çıktı katmanı	Kayıp Fonksiyon
BESA3	Mimari 7 katmandan oluşmaktadır. İlk katman giriş katmanıdır. İkinci katman 6 adet evrişim filtresinin bulunduğu evrişim katmanı olarak adlandırılır. Daha sonraki katman havuzlama katmanı olup, bu katmanda havuzlama işlemi için 4x4'lük pencere boyutu seçilmiş ve ortalama değer alınması stratejisi benimsenmiştir. Dördüncü katman yine bir evrişim katmanı olup, 12 adet evrişim filtresini barındırmaktadır. Beşinci katman yine bir havuzlama katmanı olup, havuzlama işlemi için 5x5'lik pencere boyutu seçilmiş ve ortalama değer alınması benimsenmiştir. Evrişim katmanında kullanılan filtrelerin pencere boyutu 3x3 olarak seçilmiştir. Aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmıştır. ESA'nın son katmanlarında sırasıyla, 64 nöronlu tamamen bağlı bir katman ve bir Öklid kaybı katmanı yer almaktadır.					
BESA4	Mimari 9 katmandan oluşmaktadır. İlk katman giriş katmanıdır. İkinci katman 6 adet evrişim filtresinin bulunduğu evrişim katmanı olarak adlandırılır. Daha sonraki katman havuzlama katmanı olup, bu katmanda yarı örnekleme stratejisi ve ortalama değer alınması benimsenmiştir. Dördüncü katman yine bir evrişim katmanı olup, 12 adet evrişim filtresini barındırmaktadır. Beşinci katman havuzlama katmanı olup, bu katmanda yarı örnekleme stratejisi ve ortalama değer alınması benimsenmiştir. Altıncı katman yine bir evrişim katmanı olup, 12 adet evrişim filtresini barındırmaktadır. Yedinci katman havuzlama katmanı olup, havuzlama işlemi için 4x4'lük pencere boyutu seçilmiş ve ortalama değer alan operatör kullanılmıştır. Aktivasyon fonksiyonu olarak Düzeltilmiş Doğru Birim fonksiyonu kullanılmıştır. ESA'nın son katmanlarında, 64 nöronlu tamamen bağlı bir katman ve bir Softmax kayıp katmanı yer almaktadır.					

Eğitilmiş BESA'lar, daha sonra bir tümör detektörü olarak kullanılmaktadır. Test görüntülerinde eğer bir bölgenin tümör olma ihtimali 0.8' den büyük ise o bölge tümörlü bölge olarak işaretlenmekte, eğer değil ise de sağlıklı bölge olarak değerlendirilmektedir. Bu değer gerçekleştirilen deneysel çalışmalar sırasında deneme ve yanılma yoluyla elde edilmiştir.

Benchmark veri setinden 119 adet tümörlü görüntü eğitim için 51 adet tümörlü görüntü ise test için kullanılmıştır. Şekil 4.2'de ve Çizelge 4.2'de Benchmark veri setine ait elde edilen sonuçlar sırası ile verilmiştir. Şekil 4.2'de görüleceği üzere tespit edilen beyin tümörleri sarı bir çerçeve ile gösterilmiştir. Gerçek tümör bölgesi ile tespit edilen tümör bölgesinin değerlendirilmesi ile elde edilen oranlar Çizelge 4.2'de sunulmuştur. Üç farklı test MR görüntüsü ve bu görüntülere uygulanan 4 farklı BESA mimarisi sonuçları Şekil 4.2'nin 1, 2 ve 3 numaralı satırlarında gösterilmiştir. Şekil 4.2. görsel olarak incelendiğinde, BESA1 ve

BESA3 mimarilerinin ürettiği çerçevelerin ilgili tümörleri tespitinin kabul edilebilir olduğu fakat tam olarak da çerçeveleyemediği görülmektedir. Bununla beraber, BESA2 ve BESA4 mimarilerinin BESA1 ve BESA3 mimarilerine oranla ilgili tümörleri daha iyi tespit ettiği ürettiği çerçevelerden görülmektedir.




Şekil 4.2. Tasarlanan sistem tarafından doğru olarak etiketlenen Benchmark veri setine ait örnek görüntüler

Çizelge 4.2’de verilen sayısal değerler, yapılan görsel değerlendirmeyi doğrulamaktadır. Çizelge 4.2’de satırlar BESA mimarilerini gösterirken, sütunlar ise hesaplanan sayısal başarımlarını göstermektedir. Çizelge 4.2’den görüleceği gibi BESA1 için hesaplanan doğruluk, duyarlılık ve özgüllük değerleri sırası ile %97.81, %96.45, %95.66 iken bu değerler BESA2 için sırası ile %98.92, %94.13, %97.24, BESA3 için %97.27, %93.87, %96.11 ve BESA4 için ise %99.10, %98.36, %99.82 olarak hesaplanmıştır.

Çizelge 4.2. Tasarlanan sistemlerin Benchmark veri seti için başarımları

Tasarlanan ESA	Doğruluk	Duyarlılık	Özgüllük	Yanlış pozitif oran	Yanlış negatif oran
BESA1	%97.80	%96.45	%95.66	0.04	0.03
BESA2	%98.92	%94.13	%97.24	0.02	0.05
BESA3	%97.27	%93.87	%96.11	0.03	0.07
BESA4	%99.10	%98.36	%99.82	0.01	0.01

REMBREDANT veri setinden 87 adet tümörlü görüntü eğitim için 38 adet tümörlü görüntü ise test için kullanılmıştır. Şekil 4.3 ve Çizelge 4.3’de REMBREDANT veri setine ait elde edilen sonuçlar sırası ile verilmiştir. Şekil 4.3’de tasarlanan sistemler tarafından tespit edilen beyin tümörleri sarı bir çerçeve ile gösterilmiştir. Ayrıca gerçek tümör bölgesi ile tespit edilen tümör bölgesinin değerlendirilmesi ile elde edilen sayısal değerler de Çizelge 4.3’de sunulmuştur. Üç farklı test MR görüntüsü ve bu görüntülere uygulanan 4 farklı BESA mimarisi sonuçları Şekil 4.3’ün 1, 2 ve 3 numaralı satırlarında gösterilmiştir. Şekil 4.3 görsel olarak incelendiğinde, BESA1 ve BESA3 mimarilerinin tümörlerin tespiti kabul edilebilir olduğu, fakat ürettiği çerçevelerin tam olarak da tümörleri çerçeveleyemediği görülmektedir. Bununla beraber, BESA2 ve BESA4 mimarilerinin BESA1 ve BESA3 mimarilerine oranla ilgili tümörleri daha iyi tespit ettiği ürettiği çerçevelerden anlaşılmaktadır.



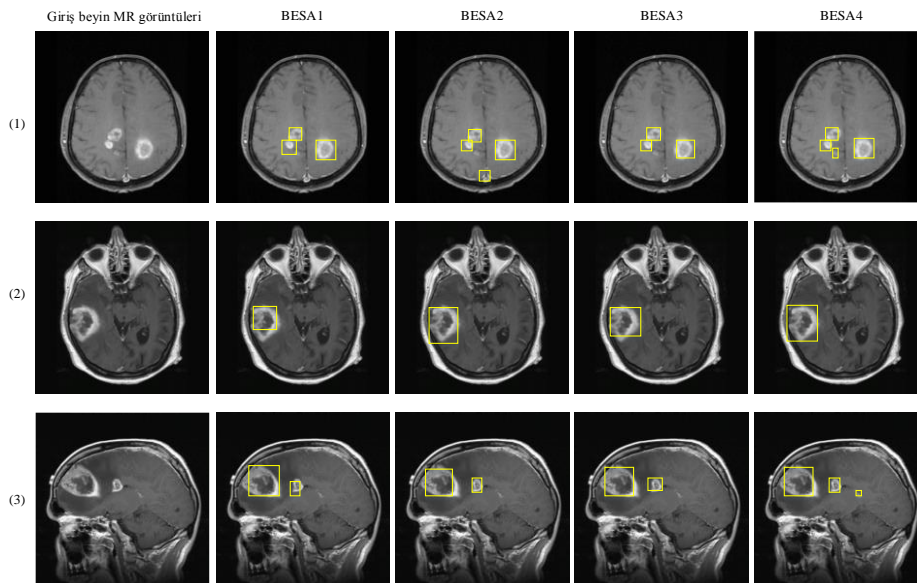
Şekil 4.3. Tasarlanan sistem tarafından doğru olarak etiketlenen REMBREDANT veri setine ait örnek görüntüler

Çizelge 4.3’de verilen sayısal değerler, görseller ile ilgili olarak yapılan yorumları desteklemektedir. Çizelge 4.3’de satırlar BESA mimarilerini gösterirken, sütunlar ise hesaplanan sayısal başarımlarını göstermektedir. Çizelge 4.3’den görüleceği gibi BESA1 için hesaplanan doğruluk, duyarlılık ve özgüllük değerleri sırası ile %96.91, %95.77, %96.80 iken, bu değerler BESA2 için sırası ile %97.41, %96.92, %98.54, BESA3 için %95.20, %94.53, %93.19 ve BESA4 için ise %98.31, %95.62, %98.43 olarak hesaplanmıştır.

Çizelge 4.3. Tasarlanan sistemlerin REMBREDANT veri seti için performans sonuçları

Tasarlanan ESA	Doğruluk	Duyarlılık	Özgüllük	Yanlış pozitif oran	Yanlış negatif oran
BESA1	%96.91	%95.77	%96.80	0.03	0.04
BESA2	%97.41	%96.92	%98.54	0.01	0.03
BESA3	%95.20	%94.53	%93.19	0.06	0.05
BESA4	%98.31	%95.62	%98.43	0.01	0.04

Harvard veri setinden 65 adet tümörlü görüntü eğitim için 46 adet tümörlü görüntü ise test için kullanılmıştır. Şekil 4.4. ve Çizelge 4.4’de Harvard veri setine ait elde edilen sonuçlar sırası ile verilmiştir. Şekil 4.4’de görüleceği üzere tespit edilen beyin tümörleri sarı bir çerçeve ile gösterilmiştir. Çizelge 4.4’de gerçek tümör bölgesi ile tespit edilen tümör bölgesinin değerlendirilmesi ile elde edilen sayısal sonuçlar verilmiştir. Üç farklı test MR görüntüsü ve bu görüntülere uygulanan 4 farklı BESA mimarisi sonuçları Şekil 4.4’ün 1, 2 ve 3 numaralı satırlarında gösterilmiştir. Şekil 4.4 görsel olarak incelendiğinde, BESA1 ve BESA3 mimarilerinin ürettiği çerçevelerin ilgili tümörlerin tespiti kabul edilebilir olduğu fakat tam olarak da çerçeveleyemediği ve küçük yapıdaki tümörleri tespit edemediği görülmektedir. Bununla beraber, BESA2 ve BESA4 mimarilerinin BESA1 ve BESA3 mimarilerine göre ilgili tümörleri daha iyi tespit ettiği görülmektedir. Fakat BESA3’de, BESA4’ün tespit ettiği küçük tümörü tespit edememiştir.




Şekil 4.4. Tasarlanan sistem tarafından doğru olarak etiketlenen Harvard veri setine ait örnek görüntüler

Çizelge 4.4’de verilen sayısal değerler, görseller ile ilgili olarak yapılan yorumları desteklemektedir. Çizelge 4.4’de satırlar BESA mimarilerini gösterirken, sütunlar ise hesaplanan sayısal başarımların ölçütlerini göstermektedir. Çizelge 4.4’den görüleceği gibi BESA1 için hesaplanan doğruluk, duyarlılık ve özgüllük değerleri sırası ile %97.31, %94.43, %95.65 iken bu değerler BESA2 için sırası ile %98.12, %95.10, %96.24, BESA3 için %97.28, %92.56, %93.11 ve BESA4 için ise %98.62, %94.33, %94.74 olarak hesaplanmıştır.

Çizelge 4.4. Tasarlanan sistemlerin Harvard veri setinde başarımların ölçüt sonuçları

Tasarlanan ESA	Doğruluk	Duyarlılık	Özgüllük	Yanlış pozitif oran	Yanlış negatif oran
BESA1	%97.31	%94.43	%95.65	0.04	0.05
BESA2	%98.12	%95.10	%96.24	0.03	0.04
BESA3	%97.28	%92.56	%93.11	0.06	0.07
BESA4	%98.62	%94.33	%94.74	0.05	0.05

Şekil 4.5’de, önerilen yöntemin gerçek tümörlerle birlikte, tümör olmayıp ta tümör olarak belirlediği bazı örnek görüntüler verilmiştir. Ayrıca, daha öncede belirtildiği üzere, tümörü belirleyen çerçeve eğer tümörü %80 oranında kapsamıyorsa, bu tespitler de doğru pozitif olarak kabul edilmemiştir. Şekil 4.5-(a,b)’de verilen sonuçta, tümörün bir kısmı tespit edilebilmişse de bu tespit oranı (piksel sayısı) %80’in altında kaldığı için bu tespit doğru olarak değerlendirilmemiştir. Ayrıca Şekil 4.5-(c)’den de görüleceği üzere, önerilen sistem tümörleri tespit etmesine rağmen aynı zaman da göz çukurlarını da tümör olarak tespit ettiği için hatalı kabul edilmiştir.



Şekil 4.5. Tasarlanan sistemler tarafından yanlış olarak etiketlenen örnek MR görüntüleri
(Example MR images incorrectly labeled by the proposed systems)

Kullanılan veri tabanlarına ait tasarlanan BESA'ların eğitim ve test süreleri Çizelge 4.5'de sunulmuştur. Satırlar veri tabanlarını gösterirken sütunlar ise tasarlanan BESA mimarilerine ait eğitim ve test sürelerini ifade etmektedir. Eğitim süreleri dakika/saniye cinsinden ifade edilirken test süreleri ise saniye cinsinden ifade edilmiştir. Veri tabanlarına ait eğitim ve test sürelerindeki fark kullanılan görüntü sayısı ile ilgili iken BESA'larda eğitim ve test sürelerinin farklılaşması ise mimarilerin farklı yapılarda tasarlanmasından kaynaklanmaktadır.

Çizelge 4.5. Tasarlanan BESA'ların çalışma süreleri

Veri Setleri	BESA 1		BESA2		BESA3		BESA4	
	Eğitim Süresi (dk/sn)	Test Süresi (sn)	Eğitim Süresi (dk/sn)	Test Süresi (sn)	Eğitim Süresi (dk/sn)	Test Süresi (sn)	Eğitim Süresi (dk/sn)	Test Süresi (sn)
Benchmark	15/12	35,19	17/45	33,25	15/43	35,15	19/26	32,12
REMBREDANT	11/36	26,22	13/42	29,16	11/56	27,26	15/17	28,11
Harvard	7/25	13,11	8/16	12,13	7/56	12,58	9/26	13,05

Önerilen yöntemin performans değerlendirmesinin daha iyi yapılabilmesi amacıyla literatürdeki yöntemler ile karşılaştırılmıştır. Elde edilen ortalama doğruluk sonuçları Çizelge 4.6’da verilmiştir.

Çizelge 4.6. Önerilen yöntemin mevcut yöntemler ile doğruluk oranlarının karşılaştırılması

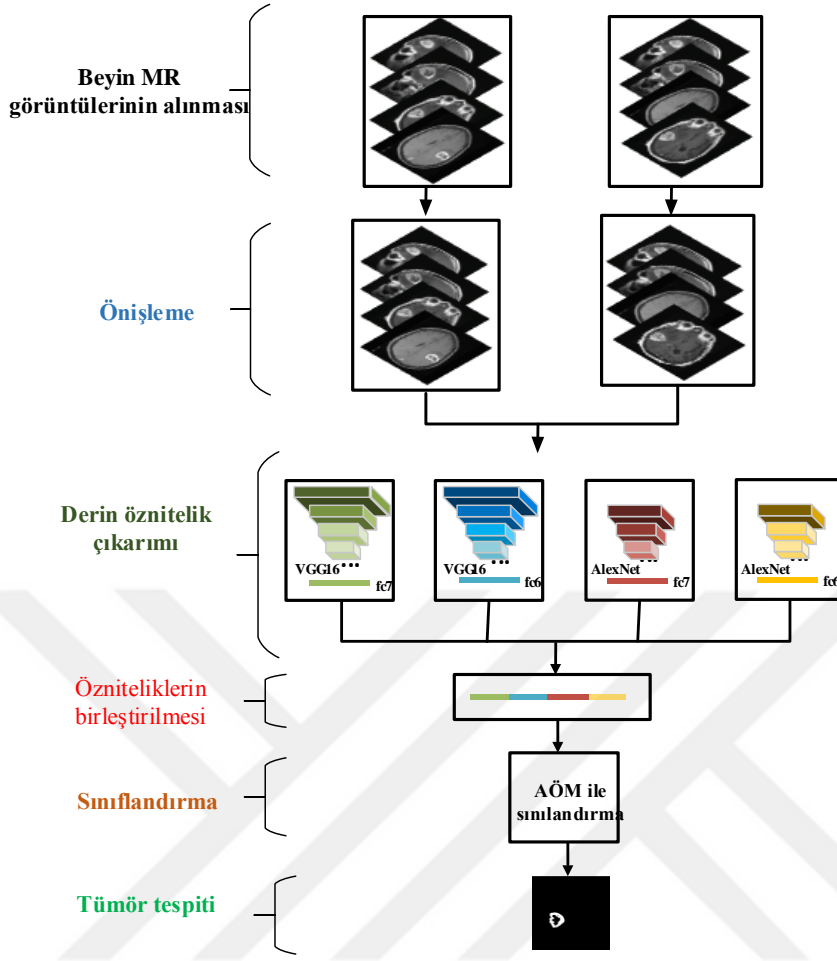
Veri setleri	Amin vd. [141]	Nabizadeh vd. [31]	Önerilen Mimariler			
			BESA1	BESA2	BESA3	BESA4
Benchmark	%98.12	%94.52	%97.80	%98.92	%97.27	%99.10
REMBREDANT	%95.11	%91.14	%96.91	%97.41	%95.20	%98.31
Harvard	%97.45	%93.28	%97.31	%98.12	%97.28	%98.62

Çizelge 4.6’da görüldüğü gibi üç veri seti için de BESA2 ve BESA 4 mimarilerinden elde edilen doğruluk oranları karşılaştırılan her iki yöntemden daha yüksektir. Diğer yandan Çizelge 4.6’dan görüleceği gibi Amin vd. [141] önerdikleri metotların ortalama doğruluğu Benchmark ve Harvard veri setinde BESA1 ve BESA3’e göre daha yüksek olmasına rağmen REMBREDANT veri setinde BESA1 ve BESA3 mimarilerinin ortalama doğruluğu daha yüksektir. Nabizadeh vd. [31] önerdikleri metot ise tasarladığımız dört mimarinin ortalama doğruluk değerlerinin gerisinde kalmıştır.

Bu veriler ışığında önerilen mimarilerin beyin MR görüntülerinden tümör tespitinde etkin bir şekilde kullanılabilmesi görülmektedir.

4.4. Uygulama 2: Derin Öznitelikler Kullanılarak Beyin MR Görüntülerinin Sınıflandırılması ve Tümör Tespiti

Tez çalışması kapsamında yapılan diğer bir çalışmanın amacı MR görüntülerini kullanarak beyin tümörlerinin çeşitlerine göre sınıflandırılması ve beyin tümörünün tespiti. Önerilen sistem, ön işlem, derin özelliklerin çıkartılması, derin özniteliklerin birleştirilmesi, sınıflandırma işlemi ve beyin tümörlerinin tespiti olmak üzere beş temel adımdan oluşmaktadır. Şekil 4.6’da, önerilen yöntemin çalışma prensibi gösterilmiştir.



Şekil 4.6. Önerilen yöntemin çalışma prensibi

Yapılan çalışmada ilk adım olarak beyin MR görüntüleri 5×5 Gauss filtresi uygulanarak önişlemeden geçirilmiştir.

İkinci adım da beyin MR görüntülerinin sınıflandırılması için ESA mimarileri kullanmak yerine, aktivasyon özelliklerini çıkarmak için önceden eğitilmiş ESA mimarileri kullanılmıştır. Bu amaçla, AlexNet ve VGG16 mimarileri ve bunların fc6 ve fc7 katmanlarındaki öznitelikler kullanılmıştır. Elde edilen fc6 ve fc7 vektörleri 4096 tane öznitelik içermektedir. Daha sonra bu mimarilerin aktivasyon katmanlarından gelen öznitelikler birleştirilmiştir. Oluşturulan öznitelik vektörleri AÖM'ye giriş parametresi olarak verilerek, beyin MR görüntüleri tümürlü-tümörsüz olarak ve tümörlerin çeşitleri ve seviyelerine göre sınıflandırılmıştır. Kullanılan AÖM'de gizli nöronların sayısı 10000'dir ve aktivasyon fonksiyonu sigmoid olarak belirlenmiştir. 10'lu çapraz geçerlilik testi ile doğruluk oranı hesaplanmıştır. Son aşamada tümürlü olarak sınıflandırılan görüntülerdeki tümörün yeri ve şekli belirlenmiştir. Önerilen yöntemin değerlendirilmesinde üç farklı veri seti

kullanılmıştır. Sınıflandırma performans değerlendirmesi için doğruluk parametresi kullanılmıştır.

Tümör tespit işleminin performans değerlendirmesinde ise doğruluk, duyarlılık, seçicilik ölçütleri ve Jaccard'ın benzerlik indeksi kullanılmıştır. Son adım olan beyin tümörlerinin tespiti ise global eşik değeri yardımı ile yapılmıştır. Bölütlenen görüntüde yanlış bölütlenen pikselleri yok etmek için morfolojik işlemler ve tümör maskeleye işlemleri uygulanmıştır. Ayrıca elde edilen sonuçlar literatürde yer alan diğer yöntemlerle karşılaştırılmıştır.

4.4.1. Sınıflandırma Sonuçları

Beyin MR görüntüleri, AlexNet ve VGG16 mimarileri için sırasıyla 227×227 ve 224×224 boyutlarına göre yeniden boyutlandırılmıştır. Beyin MR görüntülerine ait özellikler fc6 ve fc7 katmanlarından çıkartılmıştır. Her bir ESA modeli, 4096 boyutlu özellik vektörü üretmektedir. Daha sonra elde edilen özellikler birleştirilmiştir. Çizelge 4.7, 4.8 ve 4.9'da, AlexNet ve VGG16 mimarilerine ait fc6 ve fc7 katmanlarından çıkarılan özelliklerin çeşitli kombinasyonlar ile birleştirilerek oluşturulan özellik vektörlerine ait AÖM ile elde edilen sınıflandırma doğrulukları verilmiştir. Çizelge, 4.7- 4.9'un birinci, ikinci ve üçüncü sütunları sırasıyla birleştirilen öznitelik vektörlerini, doğruluk değerleri, ve öznitelik sayılarını göstermektedir. Çizelge 4.7. RIDER veri seti için elde edilen sonuçları göstermektedir. Çizelge 4.7'de tüm derin özellik kombinasyonlarının kabul edilebilir doğruluklar ürettiği ve AlexNet fc6 ve VGG16 fc6 özellik kümelerinin birleştirilmesinin en yüksek doğruluğu sağladığı görülmektedir. Hesaplanan en yüksek doğruluk %99 ve özellik sayısı 8192'dir. İkinci en yüksek doğruluk %98.90, AlexNet fc6, AlexNet fc7, VGG16 fc6 ve VGG16 fc7 öznitelik birleştirmeleri için elde edilmiştir ve özellik sayısı 16384'dür. En düşük doğruluk ise AlexNet fc6, AlexNet fc7 öznitelik birleştirmelerinden %97.90 olarak hesaplanmıştır ve özellik sayısı 8192'dir.

Çizelge 4.7. RIDER veriseti için elde edilen öznitelik vektörleri ve doğruluk oranları

Birleştirilen öznitelik setleri	Doğruluk (%)	Özniteliklerin sayısı
AlexNet fc6, VGG16 fc6	99	8192
AlexNet fc6, AlexNet fc7	97.90	8192
VGG16 fc6, VGG16 fc7	98.50	8192
AlexNet fc7, VGG16 fc7	98.85	8192
AlexNet fc6, AlexNet fc7, VGG16 fc6	98.80	12288
AlexNet fc6, AlexNet fc7, VGG16 fc6, VGG16 fc7	98.90	16384

Çizelge 4.8 Figshare veri seti için elde edilen sonuçları göstermektedir. Tüm özellik kümelerinin birleşiminin, Figshare veri seti için %97.64 en yüksek doğruluğu ürettiği görülmektedir. Ayrıca, AlexNet fc6 ve VGG16 fc6 özellik kümesi birleştirmesi de ikinci en yüksek doğruluktur. En kötü doğruluk %95.10, AlexNet fc6 ve AlexNet fc7 özellik kümesi birleştirmesinden elde edilmiştir.

Çizelge 4.8. Figshare veriseti için elde edilen öznitelik vektörleri ve doğruluk oranları

Birleştirilen öznitelik setleri	Doğruluk (%)	Özniteliklerin sayısı
AlexNet fc6, VGG16 fc6	97.45	8192
AlexNet fc6, AlexNet fc7	95.10	8192
VGG16 fc6, VGG16 fc7	96.14	8192
AlexNet fc7, VGG16 fc7	96.76	8192
AlexNet fc6, AlexNet fc7, VGG16 fc6	95.84	12288
AlexNet fc6, AlexNet fc7, VGG16 fc6, VGG16 fc7	97.64	16384

Çizelge 4.9 REMBREDANT veri seti için elde edilen sonuçları göstermektedir. Çizelge 4.9'dan tüm derin özellik kombinasyonlarının kabul edilebilir doğruluklar ürettiği ve tüm özellik kümelerinin birleşiminin en yüksek doğruluğu sağladığı görülmektedir. Hesaplanan en yüksek doğruluk %98.46 ve özellik sayısı 16384'dür. İkinci en yüksek doğruluk %98.30, AlexNet fc6, VGG16 fc6 öznitelik birleştirmeleri için elde edilmiştir ve özellik sayısı 8192'dir. En düşük doğruluk ise AlexNet fc6, AlexNet fc7 öznitelik birleştirmelerinden %97.10 olarak hesaplanmıştır ve özellik sayısı 8192'dir.

Çizelge 4.9. REMBREDANT veriseti için elde edilen öznelik vektörleri ve doğruluk oranları

Birleştirilen öznelik setleri	Doğruluk (%)	Özneliklerin sayısı
AlexNet fc6, VGG16 fc6	98.30	8192
AlexNet fc6, AlexNet fc7	97.10	8192
VGG16 fc6, VGG16 fc7	98.23	8192
AlexNet fc7, VGG16 fc7	97.76	8192
AlexNet fc6, AlexNet fc7, VGG16 fc6	98.15	12288
AlexNet fc6, AlexNet fc7, VGG16 fc6, VGG16 fc7	98.46	16384

Her veri seti için elde edilen en yüksek doğruluk oranlarını literatürdeki diğer yayınlanmış sonuçlarla karşılaştırılmıştır. Çizelge 4.10'da RIDER veri setini kullanan Amin ve ark. [141] ile bizim yöntemimiz karşılaştırılmıştır. Çizelge 4.10'da görüleceği gibi Amin ve arkadaşlarının elde ettiği başarılar bir yöntemleri hariç bizim tüm derin özellik kombinasyonlarından elde ettiğimiz başarılarından düşüktür. Sadece 25 çapraz geçerlikte ve Kübik Çekirdek DVM ile elde ettikleri başarı oranı bizim yöntemimizin başarısından yüksektir.

Çizelge 4.10. Rider veri setini kullanan literatürdeki çalışma ile önerdiğimiz metodun başarılarının kıyaslanması

Veriseti	Metot	Çapraz geçerlilik	Doğrusal DVM	Kübik DVM	Gaussian DVM
RIDER	Amin ve ark. [136]	5 fold	%81.3	%95.0	%93.3
		10 fold	%75.0	%96.7	%88.3
		15 fold	%85.9	%86.2	%84.0
		20 fold	%79.1	%80.0	%82.8
		25 fold	%90.0	%100	%89.3
		30 fold	%78.1	%85.0	%96.8
	Önerilen Metot (AlexNet fc6, VGG16 fc6 AÖM ile)		%99.0		

Çizelge 4.11'de Figshare veri setini kullanan Jun Cheng ve ark. [139] önerdikleri ile bizim yöntemimiz karşılaştırılmıştır. Çizelge 4.11'de görüleceği gibi Jun Cheng ve ark. elde ettiği başarı %94.68'dir. Bu başarı oranı bizim derin özellik kombinasyonlarından elde ettiğimiz başarılarından düşüktür.

Çizelge 4.11. Figshare veri setini kullanan literatürdeki çalışma ile önerdiğimiz metodun başarılarının kıyaslanması

Metot	Doğruluk
<i>Jun Cheng ve ark.</i> [144]	%94.68
Önerilen metod	%97.64

Çizelge 4.12’de REMBREDANT veri setini kullanan ve Kazdal ve ark. [140] ile bizim yöntemimiz karşılaştırılmıştır. Tablo 6’da görüleceği gibi Kazdal ve ark. elde ettiği sınıflandırma başarımları %84.26’dir. Bu başarımları oranı bizim derin özellik kombinasyonlarından elde ettiğimiz başarımlardan düşüktür.

Çizelge 4.12. REMBREDANT veri setini kullanan literatürdeki çalışma ile önerdiğimiz metodun başarılarının kıyaslanması

Metot	Doğruluk
<i>Kazdal ve ark.</i> [145]	%84.26
Önerilen metod	%98.08

4.4.2. Bölütleme Sonuçları


Görüntünün bölütlenmesi aşamasında ise global eşikleme kullanılmıştır ve bunun için bir eşik değeri seçilmiştir. Eğer ilgilenilen piksel değeri eşik değerinden küçükse göz ardı edilerek görüntü ikiliye çevrilmiştir. Eşikleme işlemi genelde görüntünün birden fazla özelliğini kullanarak bölütlemeyi gerçekleştiren yöntemlere göre daha hızlı sonuç vermektedir. Özellikle biyomedikal görüntülerin pek çoğunda parlaklık, bölütleme açısından ayırt edici bir özellik olması nedeniyle eşikleme işleminin kullanılabilmesi bir uygulama alanı olmaktadır. Eşikleme işleminden sonra morfolojik işlemler ve pencereleme tekniği kullanılmıştır. Doğruluk, duyarlılık ve özgüllük kriterlerine dayalı performans değerlendirmesi yapıldığında en iyi eşik değerin $T = 155$ olduğu gözlemlenmiştir. Eşik değeri belirlenmesindeki performans değerleri Tablo 1’de gösterilmiştir. Çizelge 4.13’de verilen sayısal değerler, yapılan görsel değerlendirmeyi doğrulamaktadır. Çizelge 4.13’de satırlar veri setlerinin adlarını gösterirken, sütunlar ise hesaplanan sayısal başarımları ölçütlerini göstermektedir. Çizelge 4.13’den görüleceği gibi RIDER veri seti için hesaplanan doğruluk,

duyarlılık, özgüllük ve Jaccard indeks değerleri sırası ile %98.91, %98.15, %98.20, %98.52 iken bu değerler Figshare veri seti için sırası ile %97.44, %97.12, %97.54, %96.88, REMBREDANT veri seti için ise %97.90, %96.53, %97.19, %97.23 olarak hesaplanmıştır.

Çizelge 4.13. Önerilen yöntemin tümör tespitinde başarımları

Veri setleri	Doğruluk	Duyarlılık	Özgüllük	Jaccard indeksi
RIDER	%98.91	%98.15	%98.20	%98.52
Figshare	%97.44	%97.12	%97.54	%96.88
REMBREDANT	%97.90	%96.53	%97.19	%97.23

Şekil 4.8’de görüleceği üzere beyin tümörlerinin tespiti sırasında yapılan her işlemin sonuçları yer almaktadır. 1. sütunda beyin MR görüntüleri, 2.sütunda önışlem sonucu oluşan görüntüler, 3.sütunda eşikleme işlemi sonucunda elde edilen görüntüler, 4.sütunda morfolojik işlemler ve maskeleme işlemi sonunda oluşan görüntüler, 5.sütun da ise Jaccard benzerlik sonucuna göre oluşan görüntüler yer almaktadır ve görüntülerde yer alan pembe renkli kısımlar gerçek ikili tümör görüntülerine göre eksik alan bulunduğunu, yeşil renkli kısımlar ise fazla alan bulunduğunu göstermektedir. Satırlar ise sırasıyla RIDER, Figshare ve REMBREDANT veri setine ait beyin MR görüntülerini temsil etmektedir. Şekil 4.8 görsel olarak incelendiğinde tümör bölgeleri başarıyla gerçeğe yakın şekilde bölümlendiği görülmektedir. Veri setlerine ait tümör tespit sonuçları incelendiğinde her üç veri seti içinde tümör başarımları kabul edilebilecek seviyededir. Tümör tespitinde en iyi başarımın RIDER veri setinden elde edildiği görülmüştür.



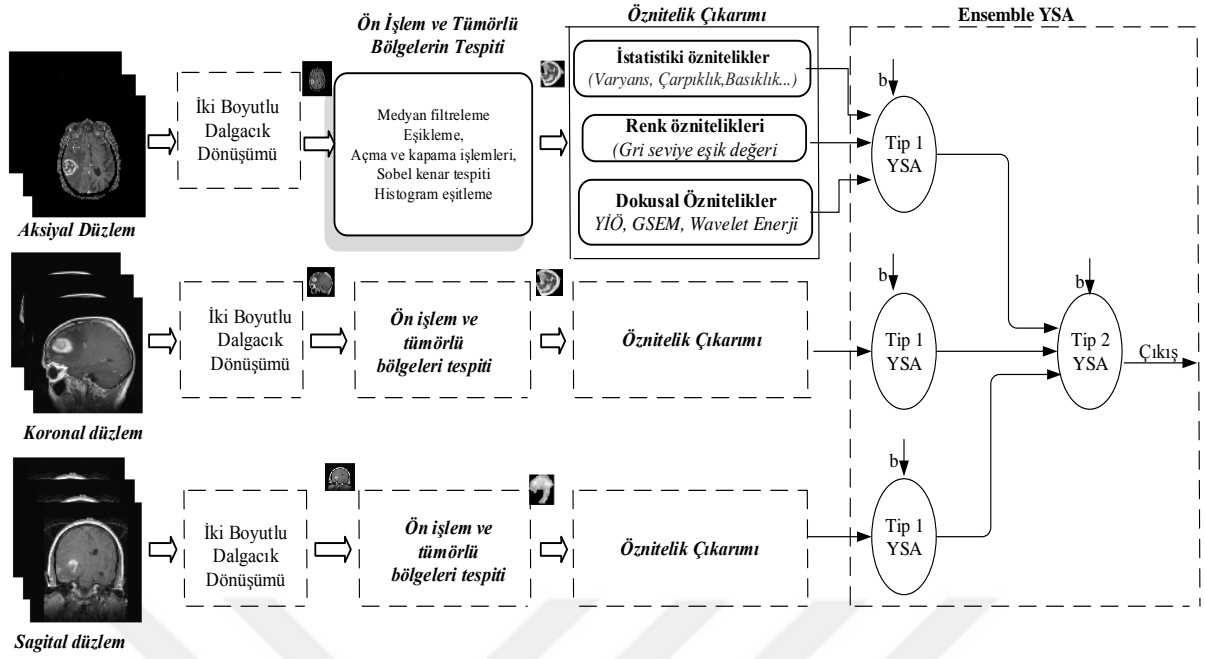
Şekil 4.8. Tümör tespit aşamaları.

4.5. Uygulama 3: MR Görüntülerinden Aşırı Öğrenme Makinesi Tabanlı Tümör Tespiti

Tez kapsamında yapılan diğer bir çalışmada [146] beyin MR görüntülerinden tümör tespitini otomatik yapan bir BDOTS tasarlanmıştır. Bu çalışmada, BDOTS'un geliştirilmesi ve değerlendirilmesi için Harvard Üniversitesi tarafından erişime açılan beyin MR görüntülerinin yer aldığı AANLIB veri seti kullanılmıştır [22]. Bu çalışma dört aşamadan oluşmaktadır. İlk olarak beyin MR görüntüleri gürültü temizleme ve histogram germe ön işlemlerine tabi tutulmuştur. İkinci aşamada Watershed algoritması ile bölütleme işlemi yapılmıştır. Daha sonra bölütlenen görüntü üzerine aşınma ve genleşme gibi morfolojik işlemler uygulanarak ilgili alanların çıkarımı yapılmıştır. Daha sonra tümörün kenarların tespiti Sobel kenar çıkarımı ile yapılmıştır. Üçüncü aşamada ise ilgili alanlara ait öznitelikler çıkarılmıştır. Öznitelik çıkarımında dokusal özniteliklerin belirlenmesi amacıyla Shearlet dönüşümü uygulanmıştır. Dönüşümde $\alpha=1,2,3,4$ değerleri kullanılarak 61 adet frekans dilimi ve katsayıları elde edilmiştir. Her bir katsayı matrisinin ortalama ve varyans değerleri hesaplanarak 122 adet öznitelik çıkartılmıştır. İlgili alanların şekilsel ve renksel özelliklerini belirlemek amacıyla basıklık, pürüzsüzlük, çarpıklık, varyans ve beyazlık değerleri hesaplanmıştır. Sonuç olarak her bir ilgi alanına ait öznitelik vektör boyutu 1×127 olarak elde edilmiştir. Dördüncü aşamada ise elde edilen öznitelikleri iyi huylu ve kötü huylu tümör olarak ayırmak amacı ile ilgi alanlarının sınıflandırılması için Aşırı Öğrenme Makinesi kullanılmıştır. Tasarlanan sistem, 30 kez çalıştırılmış ve en yüksek doğruluk oranı %97.26 olarak en düşük doğruluk oranı ise %94.13 olarak bulunmuştur. Ortalama doğruluk oranı $\%95.15 \pm 0,77$ olarak hesaplanmıştır.

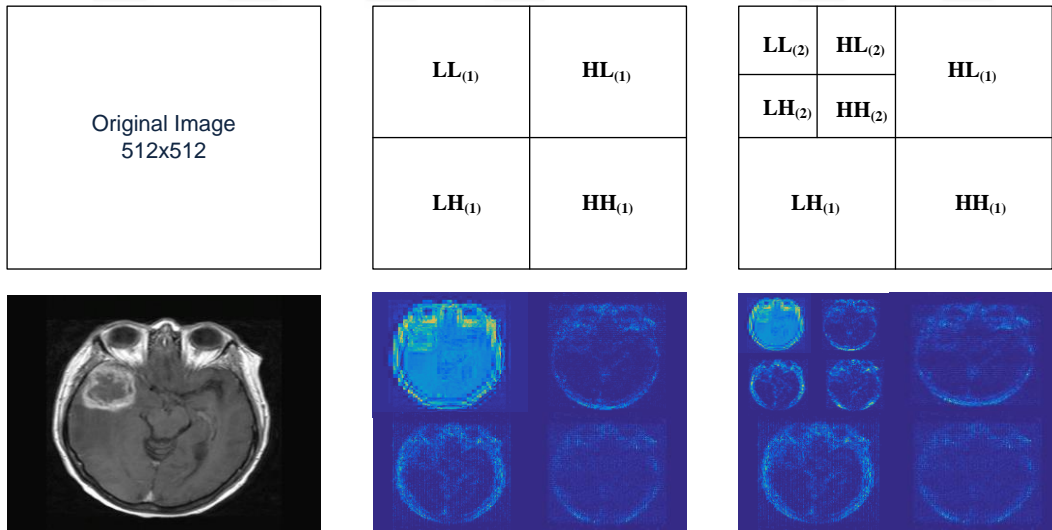
4.6. Uygulama 4: Ensemble YSA Kullanılarak Beyin MR Görüntülerinin Sınıflandırılması

Yapılan çalışmada [147] veri tabanından aksiyel, koronal ve sagittal düzleme ait 140 adet malignant tümörlü beyin MR görüntüsü ve 140 adet benign beyin MR görüntüsü kullanılmıştır. Önerilen BDOTS beş temel adımdan oluşmaktadır. Bu adımlar iki boyutlu dalgacık dönüşümü, ön işleme, segmentasyon, özellik çıkarma ve sınıflandırmadır. Önerilen BDOTS'un blok şeması Şekil 4.9'da gösterilmektedir.




Şekil 4.9. Önerilen BDOTS'un çalışma prensibi

İlk olarak beyin MR görüntülerine iki boyutlu dalgacık dönüşümü uygulanarak görüntüler 4 alt gruba ayrılmıştır. Böylelikle Orijinal görüntü yerine, orijinal görüntüden 4 kat daha küçük olan alt bantlar kullanılmıştır.




Şekil 4.10. İki boyutlu dalgacık dönüşümü uygulanmış görüntüler

Daha sonra beyin MR görüntülerinde olabilecek gürültüleri gidermek için beyin MR görüntüleri 3x3 boyutunda ortanca filtre kullanılarak ön işleme tabi tutulmuştur.



Şekil 4.11. (a) Orjinal MR görüntüsü, (b) Ön işlem uygulanmış MR görüntüsü

Daha sonra Beyin MR görüntüleri Otsu bölütleme yöntemi ile bölütlenmiş ve uygun eşik değer yardımı ile tümör olabilecek yapılar belirlenmiştir.



Şekil 4.12. (a) Eşiklenmiş MR görüntüsü, (b) Açma işlemi, (c) Kapama işlemi, (d) Tümör tespiti

Daha sonra tümör olabilecek yapılara ait istatistiksel öznitelik olarak ortalama, varyans, çarpıklık ve basıklık değerleri olarak dört öznitelik, bir adet gri seviye renk özelliği, tek düze YİÖ operatörü kullanılarak ve merkez pikselden sekiz komşu ve uzaklık değeri bir kabul edilerek elli dokuz öznitelik ve GSEM karesine ait Kontrast, Korelasyon, Enerji, Homojenlik, Entropi ve normalize edilmiş momentum farkının tersi olmak üzere görüntülerden $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 'lik uzaklı değerlerine ait yirmi dört öznitelik ile yedi adet

dalgacık enerjisi öznitelikleri çıkarılarak birleştirilmiş ve 1x95 boyutunda öznitelik vektörü elde edilmiştir. Beyin MR görüntülerinin sınıflandırılması için iki adet YSA modeli kullanılmıştır. İlk olarak her bir düzleme ait beyin MR görüntüleri ayrı ayrı sınıflandırılmıştır. Düzlemlerde kullanılan YSA modellerine ait özellikler Çizelge 4.14’de verilmiştir.

Çizelge 4.14. Tip 1 YSA mimarisinin özellikleri ve eğitim parametreleri

Mimari	
Katmanların sayısı	3
Katmanlardaki nöron sayısı	Input : 77 Hidden : 10 Output : 3
Başlangıç ağırlıklar ve bias değeri	Random
Aktivasyon fonksiyonları	Tangent-sigmoid Tangent-sigmoid Linear
Eğitim Parametreleri	
Öğrenme kuralı	Scaled Conjugate Gradient
Toplam kare hatası	0.0000001

Her bir düzlemden elde edilen öznitelik vektörleri için Tip 1 YSA mimarisi kullanılmıştır. YSA’ların performans sonuçları Çizelge 4.15’de sunulmuştur.

Çizelge 4.15. Düzlemlerden elde edilen performans sonuçları

<i>Uzaysal Düzlem</i>	<i>Doğruluk</i>	<i>Duyarlılık</i>	<i>Pozitif Tahmin Değeri</i>
Axial	%97.50	%97.84	%97.14
Coronal	%98.21	%98.56	%97.85
Sagittal	%97.14	%97.82	%97.13
Ortalama	%97.61	%98.07	%97.37

Literatürde yer alan çalışmaların performansı önerdiğimiz yöntemin performansı ile karşılaştırılmıştır. İlk olarak karşılaştırılan [16] nolu çalışmada beyin MR görüntülerinin tümörlü ve tümörsüz olarak sınıflandırılması amacıyla görüntülerden GSEM karesine ait Kontrast, Korelasyon, Enerji, Homojenlik öznitelikleri $0^\circ, 45^\circ, 90^\circ, 135^\circ$ ’lik döndürmeler ile 16 öznitelik çıkarılmıştır. Daha sonra çıkarılan öznitelikler DVM, k-NN ve YSA gibi farklı

sınıflandırıcılar ile sınıflandırma işlemi yapılmıştır. Literatürde yer alan [31] nolu çalışmada tümörlü beyin MR görüntülerinin sınıflandırılması amacıyla tümör olabilecek yapılardan Gabor dalgacık dönüşümü 33x33, 45x45 ve 65x65 üç farklı pencere boyutunda sekiz yönlendirme ölçeği ile Gabor-dalgacık öznelikleri elde edilmiştir. Bu çalışmada kullandığımız veri setine [16] ve [32] numaralı çalışmalarda yer alan yöntemler uygulanarak önerdiğimiz yöntem ile performansları karşılaştırılmış ve sonuçları Çizelge 4.16’da sunulmuştur.

Çizelge 4.16. Önerilen yöntemin literatürde yer alan diğer çalışmaların performansları ile karşılaştırılması

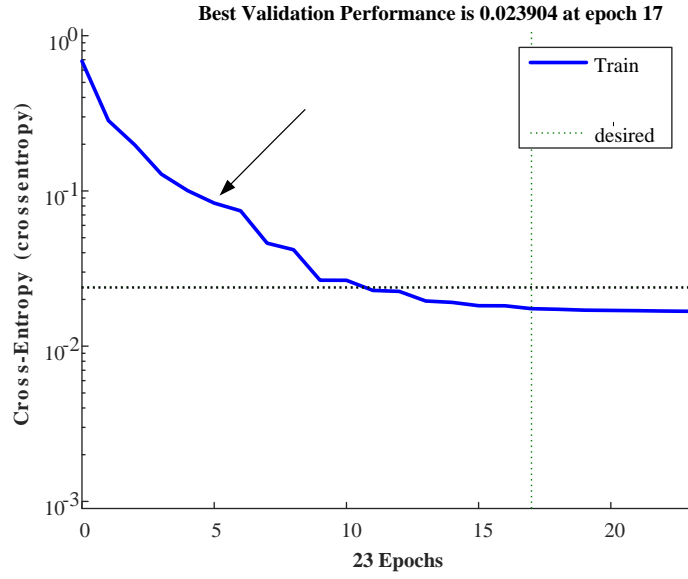
Method	DVM			K- EYK (k=7)			YSA		
	Aksiyel	Koronal	Sagital	Aksiyel	Koronal	Sagital	Aksiyel	Koronal	Sagital
[16]	%96.13	%95.20	%91.42	%97.25	%97.43	%96.53	%96.30	%95.20	%94.31
[32]	%92.43	%94.50	%92.12	%96.50	%94.13	%95.42	%96.83	%97.15	%96.26
Önerilen metot	%96.85	%96.11	%91.12	%97.85	%98.26	%96.83	%97.50	%98.21	%97.14

Daha sonra düzlemlerde kullanılan Tip 1 YSA’ların çıkışları birleştirilerek farklı bir Tip 2 YSA’nın girişine verilmiştir. Kullanılan Tip 2 YSA modeline ait özellikler Çizelge 4.17’de verilmiştir. Bu sayede daha güçlü ve güvenilir bir sonuç alınması amaçlanmıştır.

Çizelge 4.17. Tip 2 YSA modelinin mimarisi ve eğitim parametreleri

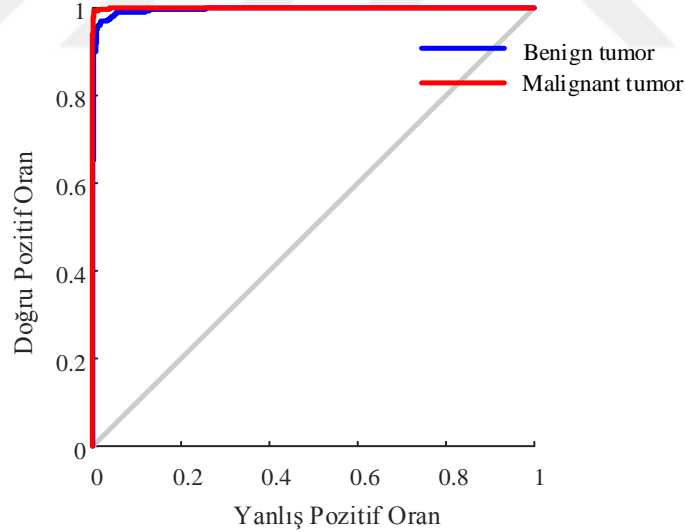
Mimari	
Katmanların sayısı	3
Katmanlardaki nöron sayısı	Input : 6 Hidden : 5 Output : 3
Başlangıç ağırlıklar ve bias değeri	Random
Aktivasyon fonksiyonları	Tangent-sigmoid Tangent-sigmoid Linear
Eğitim Parametreleri	
Öğrenme kuralı	Scaled Conjugate Gradient
Toplam kare hatası	0.0000001

Önerilen Ensemble modelin eğitim performansı Şekil 4.13’de gösterilmiştir.



Şekil 4.13. Ensemble modelin eğitim performansı

Önerilen Ensemble modelin performansın değerlendirilmesi amacıyla AUC değeri 0,985 olarak hesaplanmıştır. Önerilen sistemin ROC eğrisi Şekil 4.14' de verilmiştir.

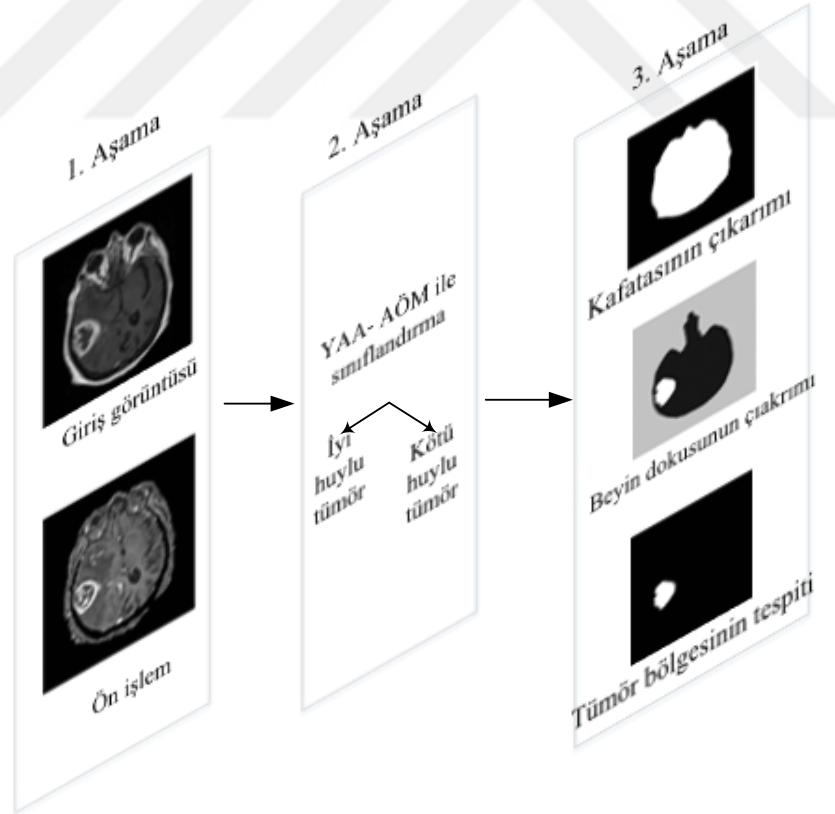


Şekil 4.14. Ensemble modelin ROC eğrisi


Tip 1 YSA modelinin çıktıları, Tip 2 YSA modelinin girişine uygulanmıştır. Bu sayede genel sistemin doğruluk oranı %98.70'e yükseltilmiştir ve sistemin performansını arttırılmıştır.

4.7. Uygulama 5: Derin Öğrenme Tabanlı Beyin Tümörlerini Sınıflandırma ve Tespit Sistemi

Derin öğrenme tabanlı beyin MR görüntülerinden tümörlerin sınıflandırılması ve tespiti için tasarlanan BDOTS Şekil 4.15’de gösterildiği gibi, üç ana aşamadan oluşmaktadır. Bu aşamalar, ön işleme, YAA-AÖM ile beyin tümörlerinin sınıflandırılması ve görüntü işleme tekniklerine dayalı tümör tespitidir. Kullanılan bütün imgeler ilk önce 32x32 boyutuna yeniden boyutlandırılmıştır. Ön işleme aşamasında, olabilecek gürültüler yerel olmayan araçlar ve yerel yumuşatma yöntemi kaldırılarak giriş görüntüleri ön işlemden geçirilmiştir. Sınıflandırma aşamasında, YAA – AÖM kullanılarak beyin tümörleri iyi huylu ve kötü huylu olarak sınıflandırılmıştır. Giriş katmanındaki görüntülere evrişim ve havuzlama işlemleri uygulanmış olup giriş katmanı ağırlıkları rastgele seçilmiştir. Gizli katman ve çıkış katmanı arasındaki ağırlıklar, en küçük kare yöntemi kullanılarak analitik olarak hesaplanmıştır. Tümörleri tespit etmek için havza bölütleme kullanılarak beyin MR görüntüleri bileşenlerine ayrılarak daha sonra morfolojik operatörler ile tümör tespiti yapılmıştır ve yapılan işlemlere ait görüntüler Şekil 4.16’da verilmiştir.




Şekil 4.15. Tasarlanan BDOTS'un çalışma prensibi




Şekil 4.16. (a) Orijinal görüntü, (b) Ön işlem uygulanmış görüntü, (c) Beyin kafatasının çıkarımı, (d) Beyin dokusunun çıkarımı, (e) Beyin tümörünün tespiti


YAA-AÖM'nin ayarlanabilir 4 parametresi mevcuttur. Bunlar sırası ile evrişim filtresi boyutu r , evrişim filtresi sayısı K , havuzlama boyutu ve C regülasyon katsayısıdır. K değeri 16, evrişim filtresi boyutu 5, havuzlama filtresi boyutu 2×2 olarak belirlenmiştir. En uygun C değerinin belirlenmesi için $2^{-10}, 2^{-8}, \dots, 2^8, 2^{10}$ aralığında ızgara araması yapılmış ve minimum hatanın elde edildiği C değeri seçilmiştir. Şekil 4.17'de YAA-AÖM'nin çalışma prensibi sunulmuştur. Şekil 4.18 ve Şekil 4.19'de sırası ile evrişim katmanı ve havuzlama katmanı sonrasında elde edilen görüntüler gösterilmiştir.



Şekil 4.17. YAA-AÖM'nin çalışma prensibi



Şekil 4.18. Evrişim işleminin sonucu oluşan görüntüler



Şekil 4.19. Havuzlama işleminin sonucu oluşan görüntüler

YAA-AÖM mimarisinin beyin tümörlerini iyi veya kötü huylu olarak sınıflandırma doğruluğu %97.18 olarak hesaplanmıştır. YAA-AÖM makinesinin başarımlarını aynı veri seti üzerinde literatürde yer alan metotlar kullanılarak elde edilen sonuçlarla karşılaştırılmıştır.

İlk olarak [31] numaralı çalışmada kullanılan Gabor dalgacık özellikleri, 1.dereceden istatistiksel tanımlayıcılar, GSEM, GSDUM ve YİÖ yöntemleri kullanılarak elde edilen özneliklere dayalı olarak beyin tümörleri DVM, k-EYK ve YSA gibi sınıflandırıcılar ile sınıflandırılmıştır. Sınıflandırıcıların sınıflandırma doğruluk değerleri Çizelge 4.18’de verilmiştir.

Çizelge 4.18. Gabor dalgacık ve istatistiksel-dokusal özneliklere dayalı farklı sınıflandırıcıların sınıflandırma performans değerleri

	DVM	k- EYK (k=7)	YSA
Gabor-dalgacık öznelikleri	92.40	90.60	93.60
İstatistiksel ve dokusal öznelikler	95.06	93.70	96.24

Ayrıca YAA-AÖM’nin performansı derin öğrenme mimarilerinden olan ESA ve AlexNet mimarileri ile karşılaştırılmıştır. Karşılaştırmada kullanılan ESA modeli 6 katmandan oluşmaktadır. İlk katman giriş katmanıdır. İkinci katman 6 adet evrişim filtresi bulunduğu evrişim katmanı olarak adlandırılır. Daha sonraki katman alt örnekleme katmanı olup, bu katmanda yarı örnekleme stratejisi benimsenmiştir. Dördüncü katman yine bir evrişim katmanı olup, 12 adet evrişim filtresini barındırmaktadır. Beşinci katman yine bir alt örnekleme katmanı olup, yarı örnekleme kullanılmıştır. Son katman ise yine bir evrişim katmanı olup, 12 adet evrişim filtresini barındırır. İlk iki evrişim katmanında kullanılan filtrelerin boyutu 5x5 pencere boyutu seçilmiştir. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır.

Çizelge 4.19’da YAA-AÖM ile performans karşılaştırması yapılan diğer yöntemlerin doğruluk değerleri sunulmuştur. Çizelge 4.19 sayısal olarak incelendiğinde YAA-AÖM en yüksek performansı göstermektedir. İkinci en yüksek performans ise AlexNet mimarisinden elde edilmiştir.

Çizelge 4.19. Farklı metotların sınıflandırma başarısı

Metot	Doğruluk
YAA- AÖM	%97.18
ESA	%96.45
Gabor-dalgacık öznitelikleri	%96.24
İstatistiksel ve dokusal öznitelikler	%93.65
AlexNet	%96.91



5. SONUÇ

Bu tez çalışmasında beyin MR görüntülerinden beyin tümörlerini tespit ve teşhis etmek için beş farklı BDOTS tasarlanmıştır. Bu sayede uzmanların tümörler hakkında bilgilere BDOTS'lar sayesinde daha hızlı ulaşarak cerrahi planlamayı daha doğru ve kısa sürede yapabilmeleri sağlanacaktır. Beyin tümörlerinden etkilenen hastaların sayısının günümüzde artması göz önüne alındığında beyin tümörü tespit ve teşhisi için gerekli olan zaman ve insan gücünün azaltılabileceği düşünüldüğünde BDOTS'lar araştırmacılar için önemli bir araştırma haline gelmiştir.

Yapılan bu tez çalışmasında beyin MR görüntülerinden tümör tespiti ve tümörlerin türlerine ve seviyelerine göre sınıflandırılması yapılmıştır. Yapılan çalışmaları iki ana başlıkta gruplayabiliriz. İlk grup beş aşamadan oluşmaktadır. Bunlar ön işlem, bölütleme, özellik çıkarımı, kenar tespiti ve sınıflandırma aşamalarıdır. İkinci grup ise iki aşamadan oluşmaktadır. Bunlar derin öğrenme tabanlı tümör tespiti ve tümörlerin sınıflandırılmasıdır.

Bu tez çalışmasında ilk olarak beyin MR görüntülerinden tümörlü bölgelerin otomatik olarak tespit edilmesi için derin öğrenme tabanlı yöntem önerilmiştir. Harvard, Benchmark ve REMBREDANT veri setleri kullanılarak önerilen BESA mimarileri test edilmiştir. Yapılan çalışmada dört farklı BESA mimarisi kullanılmış ve elde edilen sonuçlar hem görsel hem de sayısal olarak değerlendirilmiştir. Üç veri seti kullanıldığında mimarilerin ortalama doğruluk başarımları BESA1 için %97.34, BESA2 için %98.15, BESA3 için %96.58 ve BESA4 için %98.66 olarak hesaplanmıştır. Elde edilen en yüksek doğruluk değeri ise %99.10 ile BESA4 mimarisi ve Benchmark veri setinden elde edilmiştir. Ayrıca, önerilen yöntemin başarımları, literatürdeki bazı yöntemler ile kıyaslanmıştır. Kıyaslamalarda önerilen yöntemin daha başarılı olduğu görülmüştür. BESA4 mimarisi tasarlanan diğer mimarilere oranla daha başarılı sonuçlar ürettiğini göstermiştir. BESA4'ün performansının, diğer mimarilerden daha iyi olmasının sebebi, evrişim ve havuzlama katmanlarının sayısı ve bu katmanlarda kullanılan filtre boyutu ile kayıp ve aktivasyon katmanlarındaki kullanılan fonksiyonlardan kaynaklanmaktadır. Önerilen yöntemin performansı daha önceden yapılan benzer çalışmalar ile kıyaslanmış önerilen yöntemin başarımlarının yüksek olduğu görülmüştür.

Bu tez çalışmasında ikinci olarak, derin özelliklerin birleştirilmiş olmasının görüntü sınıflandırma başarısına etkileri incelenmiştir. Başka bir deyişle, beyin MR görüntülerinin sınıflandırması görevinde en iyi derin özellik kümelerinin kombinasyonunu belirlemek amaçlanmıştır. Araştırmada RIDER, Figshare, Rembredant olmak üzere üç veri seti ve

önceden eğitilmiş Alexnet ve VGG16 mimarileri kullanılmıştır. Birleştirilen özneteliklere dayalı sınıflandırma işlemi ise AÖM ile yapılmıştır. RIDER veri seti kullanıldığında AlexNet fc6, VGG16 fc6 katmanlarından elde edilen ve birleştirilen öznetelik vektörleri kullanıldığında tümörlerin sınıflandırma doğruluğu %99 olarak hesaplanmıştır. Figshare veri seti kullanıldığında AlexNet fc6, AlexNet fc7, VGG16 fc6, VGG16 fc7 katmanlarından elde edilen ve birleştirilen öznetelik vektörleri kullanıldığında tümörlerin sınıflandırma doğruluğu %97.64 olarak hesaplanmıştır. Rembredant veri seti kullanıldığında ise AlexNet fc6, AlexNet fc7, VGG16 fc6, VGG16 fc7 katmanlarından elde edilen ve birleştirilen öznetelik vektörleri kullanıldığında tümörlerin sınıflandırma doğruluğu %98.46 olarak hesaplanmıştır. Karşılaştırmalardan, beyin tümörlerini sınıflandırmada önerilen yöntemin performansının diğer yöntemlerden daha iyi olduğu görülmektedir. Beyin MR görüntülerinden tümör tespiti ise eşik değer yardımıyla bölütleme ile yapılmıştır. Daha sonra morfolojik işlemler yardımıyla tümör olabilecek yapılar belirgin hale getirilmiştir. Önerilen yöntemin tümör tespitinde başarımları doğruluk, duyarlılık, özgüllük ve Jaccard'ın benzerlik indeks değerine göre yapılmıştır. Performans değerleri sırasıyla RIDER veri seti için %98.91, %98.15, %98.20, %98.52, Figshare veri seti için %97.44, %97.12, %97.54, %96.88 ve Rembredant veri seti için ise %97.90, %96.53, %97.19, %97.23 olarak hesaplanmıştır.

Bu tez çalışmasında üçüncü olarak istatistiksel, renksel ve dokusal özneteliklere dayalı AÖM tabanlı tümörlerin tespiti ve sınıflandırılması yapılmıştır. Shearlet dönüşümünden elde edilen her bir katsayı matrisinin ortalama ve varyans değerleri hesaplanarak 122 adet öznetelik çıkartılmıştır. İlgili alanların şekilsel ve renksel özelliklerini belirlemek amacıyla basıklık, pürüzsüzlük, çarpıklık, varyans ve beyazlık değerleri hesaplanmıştır. Sonuç olarak her bir ilgi alanına ait öznetelik vektör boyutu 1x127 olarak elde edilmiştir. Elde edilen özneteliklere dayalı beyin tümörlerinin iyi huylu ve kötü huylu tümör olarak sınıflandırılması amacı ile Aşırı Öğrenme Makinesi kullanılmıştır. Tasarlanan sistem, 30 kez çalıştırılmış ve en yüksek doğruluk oranı %97.26 olarak en düşük doğruluk oranı ise %94.13 olarak bulunmuştur. Ortalama doğruluk oranı 95.15 ± 0.77 olarak hesaplanmıştır.

Bu tez çalışmasında dördüncü olarak YAA-AÖM yapısı ile beyin MR görüntülerinden tümörlerin sınıflandırılması yapılmıştır. YAA-AÖM'de dört ayarlanabilir parametreye sahiptir: evrişim filtre boyutu r , evrişim filtre boyutu K , havuzlama operatörünün boyutu ve düzenleme (regülasyon) katsayısı C 'dir. Yapılan kapsamlı deneylere dayanarak, evrişim filtre boyutu 5, K değeri 16, havuzlama boyutu 2x2 olarak belirlendi. Ayrıca en uygun C değerinin belirlenmesi için 2^{-10} , 2^{-8} , ..., 2^8 , 2^{10} değerleri arasında ayrı bir arama yapıldı ve en az hata

payı olan C değeri seçildi. YAA-AÖM performansı test edildi ve ayrıca literatürde bulunan iki yöntem ile karşılaştırıldı. YAA-AÖM yöntemi ile sınıflandırma doğruluğu %97.18 olarak elde edildi. Bu çalışmanın sonucu olarak YAA-AÖM yapısının biyomedikal görüntü işleme uygulamalarında kullanılabilecek önemli bir araç olduğu tespit edilmiştir.

Bu tez çalışmasında son olarak istatistiksel, renksel ve dokusal özniteliklere dayalı YSA tabanlı tümörlerin sınıflandırılması ve otsu bölütleme ve morfolojik operatörler ile beyin tümörlerinin tespiti yapılmıştır. Aksiyal, koronal ve sagittal düzlemlere ait beyin MR görüntüleri kullanılmıştır. Her bir düzlem ayrı bir veri tabanı olarak düşünülmüş ve her bir görüntüden istatistiksel, renksel ve dokusal öznitelikler çıkarılmıştır. Daha sonra her bir düzlem için YSA kullanılarak tümörler iyi huylu ve kötü huylu olarak sınıflandırılmıştır. Aksiyel, koronal ve sagittal düzlemlere ait YSA'ların sınıflandırma doğruluk değerleri sırasıyla %97.50, %98.21, %97.14 olarak hesaplanmıştır. Daha sonra üç düzlem için kullanılan her bir YSA'nın çıkışı farklı bir YSA'ya giriş olarak verilmiş ve önerilen sistemin performansı artırılarak doğruluk değeri %98.70 olarak hesaplanmıştır.

Gerçekleştirilen BDOTS'ların performansının değerlendirilmesi için literatürde aynı veri setlerini kullanarak diğer araştırmacıların önerdikleri yöntemlerin performansları karşılaştırıldığında tasarlanan her bir BDOTS diğer çalışmalara üstünlük sağlamıştır. Tümör tespitinde elde edilen en yüksek doğruluk değeri %99.10 ile BESA4 mimarisi ve Benchmark veri setinden elde edilmiştir. Beyin tümörlerinin sınıflandırılmasında elde edilen en yüksek doğruluk değeri ise RIDER veri setinden AlexNet fc6, VGG16 fc6 katmanlarından elde edilen ve birleştirilen öznitelik vektörlerinin AÖM ile sınıflandırılması sonucu %99 olarak hesaplanmıştır.

Gelecekte beyin MR görüntülerinin yanı sıra BT görüntülerinin kullanılması planlanmaktadır. Ayrıca literatürde yer alan diğer derin öğrenme mimarileri tümör tespiti ve tümörlerin sınıflandırılması işleminde kullanılacaktır.

6. KAYNAKLAR

- [1] R. Anitha ve D.S.S. Raja, *Segmentation of glioma tumors using convolutional neural networks*, **Int. J. Imaging Syst. Technol.**, 27 :4 (2017) 354–360.
- [2] A. Selvapandian ve K. Manivannan, *Fusion based Glioma brain tumor detection and segmentation using ANFIS classification*, **Comput. Methods Programs Biomed.**, 166 (2018) 33–38.
- [3] S. Chen, C. Ding, ve M. Liu, *Dual-force convolutional neural networks for accurate brain tumor segmentation*, **Pattern Recognit.**, 88 (2019) 90–100.
- [4] Z.U. Rehman, S.S. Naqvi, T.M. Khan, M.A. Khan, ve T. Bashir, *Fully automated multi-parametric brain tumour segmentation using superpixel based classification*, **Expert Syst. Appl.**, 118 (2019) 598–613.
- [5] L. Šajin ve M. Kukar, *Image processing and machine learning for fully automated probabilistic evaluation of medical images*, **Comput. Methods Programs Biomed.**, 104 :3 (2011) 75–86.
- [6] M. Talo, U.B. Baloglu, Ö. Yıldırım, ve U. Rajendra Acharya, *Application of deep transfer learning for automated brain abnormality classification using MR images*, **Cogn. Syst. Res.**, 54 (2019) 176–188.
- [7] S. Kumar, C. Dabas, ve S. Godara, *Classification of Brain MRI Tumor Images: A Hybrid Approach*, **Procedia Comput. Sci.**, 122 (2017) 510–517.
- [8] K. Dimililer ve A. Ilhan, *Effect of Image Enhancement on MRI Brain Images with Neural Networks*, **Procedia Comput. Sci.**, 102 :August (2016) 39–44.
- [9] T.S. Illés, F. Lavaste, ve J.F. Dubousset, *The third dimension of scoliosis: The forgotten axial plane*, **Orthop. Traumatol. Surg. Res.**, 105 :2 (2019) 351–359.
- [10] A. ARI ve D. Hanbay, *Bölgesel Evrişimsel Sinir Ağları Tabanlı MR Görüntülerinde Tümör Tespiti*, **Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Derg.**, 2018 :18–2 (2018) 1395–1408.
- [11] R.S. Kabade ve M.S. Gaikwad, *Segmentation of Brain Tumour and Its Area Calculation in Brain MR Images using K-Mean Clustering and Fuzzy C- Mean Algorithm*, **Int. J. Comput. Sci. Eng. Technol.**, 4 :05 (2013) 524–531.

- [12] H.A. Aslam, T. Ramashri, M. Imtiaz, ve A. Ahsan, *A New Approach to Image Segmentation for Brain Tumor detection using Pillar K-means Algorithm*, 2 :3 (2013) 1429–1436.
- [13] J. Kleesiek, G. Urban, A. Hubert, D. Schwarz, K. Maier-Hein, M. Bendszus, ve A. Biller, *Deep MRI brain extraction: A 3D convolutional neural network for skull stripping*, **Neuroimage**, 129 (2016) 460–469.
- [14] D. Herek, N. Karabulut, P. Üniversitesi, T. Fakültesi, R.A. Dalı, K. Kampüsü, ve T. Denizli, *MANYETİK REZONANS GÖRÜNTÜLEME*, (y.y.).
- [15] World Health Organization: WHO. <https://www.who.int/> (on line access on 15 Nov, 2018).
- [16] P. Shanthakumar ve P. Ganeshkumar, *Performance analysis of classifier for brain tumor detection and diagnosis*, **Comput. Electr. Eng.**, 45 (2015) 302–311.
- [17] R. Wang, W. Li, R. Li, ve L. Zhang, *Automatic blur type classification via ensemble SVM*, **Signal Process. Image Commun.**, 71 :37 (2019) 24–35.
- [18] G. Mohan ve M.M. Subashini, *MRI based medical image analysis: Survey on brain tumor grade classification*, **Biomed. Signal Process. Control**, 39 (2018) 139–161.
- [19] G. Song ve Q. Dai, *A novel double deep ELMs ensemble system for time series forecasting*, **Knowledge-Based Syst.**, 134 (2017) 31–49.
- [20] The Multimodal Brain Tumor Segmentation Challenge: MICCAI BRATS. <https://www.smir.ch/BRATS/Start2015> (on line access on 25 May, 2017).
- [21] The Multimodal Brain Tumor Segmentation Challenge: MICCAI BRATS. <https://www.smir.ch/BRATS/Start2013> (on line access on 15 April, 2018).
- [22] The Whole Brain Atlas - Harvard Medical School. <http://www.med.harvard.edu/AANLIB/home.html> (on line access on 28 June, 2017).
- [23] The Cancer Imaging Archive (TCIA) <https://wiki.cancerimagingarchive.net/display/Public/REMBREDANT>(on line access on 19 July, 2016).
- [24] K. Sudharani, T.C. Sarma, ve K.S. Prasad, *Advanced Morphological Technique for Automatic Brain Tumor Detection and Evaluation of Statistical Parameters*, **Procedia**

- Technol.**, 24 (2016) 1374–1387.
- [25] V. Vijay, A.R. Kavitha, ve S.R. Rebecca, *Automated Brain Tumor Segmentation and Detection in MRI Using Enhanced Darwinian Particle Swarm Optimization(EDPSO)*, **Procedia Comput. Sci.**, 92 (2016) 475–480.
- [26] S. Chaplot, L.M. Patnaik, ve N.R. Jagannathan, *Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network*, **Biomed. Signal Process. Control**, 1 :1 (2006) 86–92.
- [27] M.S.H. Al-tamimi, A.S.H. Al-tamimi, ve G. Sulong, *A New Abnormality Detection Approach for T1-Weighted Magnetic Resonance Imaging Brain Slices Using Three Planes*, **Adv. Comput.**, 6 :1 (2016) 6–27.
- [28] P. Thirumurugan ve P. Shanthakumar, *Brain tumor detection and diagnosis using ANFIS classifier*, **Int. J. Imaging Syst. Technol.**, 26 :2 (2016) 157–162.
- [29] A. Roy, S.P. Maity, ve S.K. Yadav, *On segmentation of MR images using curvelet and Fuzzy C-means under compressed sensing*, **2014 20th Natl. Conf. Commun. NCC 2014**, (2014) 1–6.
- [30] P. Sriramakrishnan, T. Kalaiselvi, ve R. Rajeswaran, *Modified local ternary patterns technique for brain tumour segmentation and volume estimation from MRI multi-sequence scans with GPU CUDA machine*, **Biocybern. Biomed. Eng.**, 39 :2 (2019) 470–487.
- [31] N. Nabizadeh ve M. Kubat, *Brain tumors detection and segmentation in MR images: Gabor wavelet vs statistical features*, **Comput. Electr. Eng.**, 45 (2015) 286–301.
- [32] Q. Ain, M.A. Jaffar, ve T.-S. Choi, *Fuzzy anisotropic diffusion based segmentation and texture based ensemble classification of brain tumor*, **Appl. Soft Comput.**, 21 (2014) 330–340.
- [33] BrainWeb: Simulated Brain Database. <https://brainweb.bic.mni.mcgill.ca/brainweb/>(on line access on 10 May, 2017).
- [34] S. Abbasi ve F.T. Pour, *A hybrid approach for detection of brain tumor in MRI images*, **2014 21st Iran. Conf. Biomed. Eng. ICBME 2014**, :Icbme (2014) 269–274.
- [35] I. Maiti ve M. Chakraborty, *A new method for brain tumor segmentation based on*

- watershed and edge detection algorithms in HSV colour model*, **2012 Natl. Conf. Comput. Commun. Syst. NCCCS 2012 - Proceeding**, (2012) 192–196.
- [36] N. Singh, S. Das, ve A. Veeramuthu, *An efficient combined approach for medical brain tumour segmentation*, **Proc. 2017 IEEE Int. Conf. Commun. Signal Process. ICCSP 2017**, 2018-Janua (2018) 1325–1329.
- [37] K.B. Vaishnavee ve K. Amshakala, *An automated MRI brain image segmentation and tumor detection using SOM-clustering and Proximal Support Vector Machine classifier*, **ICETECH 2015 - 2015 IEEE Int. Conf. Eng. Technol.**, :March (2015) 1–6.
- [38] K. Kamnitsas, E. Ferrante, S. Parisot, C. Ledig, A. V. Nori, A. Criminisi, D. Rueckert, ve B. Glocker, *DeepMedic for brain tumor segmentation*, **Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)**, 10154 LNCS (2016) 138–149.
- [39] The Multimodal Brain Tumor Segmentation Challenge: MICCAI BRATS. <https://www.smir.ch/BRATS/Start2017> (on line access on 15 May, 2018).
- [40] H. Mohsen, E.-S.A. El-Dahshan, E.-S.M. El-Horbaty, ve A.-B.M. Salem, *Classification using deep learning neural networks for brain tumors*, **Futur. Comput. Informatics J.**, 3 :1 (2017) 68–71.
- [41] H. Chen, Z. Qin, Y. Ding, L. Tian, ve Z. Qin, *Brain tumor segmentation with Deep Convolutional Symmetric Neural Network*, **Neurocomputing**, :xxxx (2019) 1–9.
- [42] M. Sajjad, S. Khan, K. Muhammad, W. Wu, A. Ullah, ve S.W. Baik, *Multi-grade brain tumor classification using deep CNN with extensive data augmentation*, **J. Comput. Sci.**, 30 (2019) 174–182.
- [43] Radiopedia. <https://radiopaedia.org/>(on line access on 08 May, 2017).
- [44] J. Cheng, W. Huang, S. Cao, R. Yang, W. Yang, Z. Yun, Z. Wang, ve Q. Feng, *Enhanced performance of brain tumor classification via tumor region augmentation and partition*, **PLoS One**, 10 :10 (2015) 1–13.
- [45] M. Ben naceur, R. Saouli, M. Akil, ve R. Kachouri, *Fully Automatic Brain Tumor Segmentation using End-To-End Incremental Deep Neural Networks in MRI images*, **Comput. Methods Programs Biomed.**, 166 (2018) 39–49.

- [46] A. Selvikvåg Lundervold ve A. Lundervold, *An overview of deep learning in medical imaging focusing on MRI*, **Z. Med. Phys.**, 29 :2 (2018) 102–127.
- [47] S. Hussain, S.M. Anwar, ve M. Majid, *Segmentation of glioma tumors in brain using deep convolutional neural network*, **Neurocomputing**, 282 (2018) 248–261.
- [48] R. Ezhilarasi ve P. Varalakshmi, *Tumor detection in the brain using faster R-CNN*, **Proc. Int. Conf. I-SMAC (IoT Soc. Mobile, Anal. Cloud), I-SMAC 2018**, (2019) 388–392.
- [49] C.V. R.Vinoth, *MRI images Using CNN and SVM Classification*, **2018 Conf. Emerg. Devices Smart Syst.**, :March (2018) 21–25.
- [50] S.G. Umut Arıöz, *Beyin MR Görüntülerinden Tümör Tespiti İncelemesi Review : Tumor Detection Using Brain MR Image*, **Tıp Teknol. Kongresi**, (2016) 252–255.
- [51] GÖRÜNTÜ İŞLEME (5.Hafta)
http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu_Isleme_Ders_Notlari-5.Hafta.pdf (on line access on 25 September, 2018).
- [52] Görüntü Restorasyonu. BMÜ-357 Sayısal Görüntü İşleme Yrd. Doç. Dr. İlhan AYDIN.
<http://docplayer.biz.tr/3693692-Goruntu-restorasyonu-bmu-357-sayisal-goruntu-iseme-yrd-doc-dr-ilhan-aydin.html>(on line access on 17 October, 2018).
- [53] A. Rajendran ve R. Dhanasekaran, *Fuzzy clustering and deformable model for tumor segmentation on MRI brain image: A combined approach*, **Procedia Eng.**, 30 (2012) 327–333.
- [54] J. Sachdeva, V. Kumar, I. Gupta, N. Khandelwal, ve C.K. Ahuja, *A novel content-based active contour model for brain tumor segmentation*, **Magn. Reson. Imaging**, 30 :5 (2012) 694–715.
- [55] X. Zhang, X. Li, H. Li, ve Y. Feng, *A semi-automatic brain tumor segmentation algorithm*, **Proc. - IEEE Int. Conf. Multimed. Expo**, 2016-Augus (2016) 1–6.
- [56] S. Yousefi, R. Azmi, ve M. Zahedi, *Brain tissue segmentation in MR images based on a hybrid of MRF and social algorithms*, **Med. Image Anal.**, 16 :4 (2012) 840–848.
- [57] H. Tang, E.X. Wu, Q.Y. Ma, D. Gallagher, G.M. Perera, ve T. Zhuang, *MRI brain image segmentation by multi-resolution edge detection and region selection*, **Comput.**

- Med. Imaging Graph.**, 24 :6 (2000) 349–357.
- [58] M. Maitra ve A. Chatterjee, *A Slantlet transform based intelligent system for magnetic resonance brain image classification*, **Biomed. Signal Process. Control**, 1 :4 (2006) 299–306.
- [59] M. Jafari, S. Kasaei, ve K. Branch, *Automatic Brain Tissue Detection in Mri Images Using Seeded Region Growing Segmentation and Neural Network Classification*, **Brain**, 5 :8 (2011) 1066–1079.
- [60] R. Donoso, A. Veloz, ve H. Allende, *Modified expectation maximization algorithm for MRI segmentation*, **Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)**, 6419 LNCS (2010) 63–70.
- [61] E.J. Canales-Rodríguez, J. Radua, E. Pomarol-Clotet, S. Sarró, Y. Alemán-Gómez, Y. Iturria-Medina, ve R. Salvador, *Statistical analysis of brain tissue images in the wavelet domain: Wavelet-based morphometry*, **Neuroimage**, 72 (2013) 214–226.
- [62] H. Merisaari, R. Parkkola, E. Alhoniemi, M. Teräs, L. Lehtonen, L. Haataja, H. Lapinleimu, ve O.S. Nevalainen, *Gaussian mixture model-based segmentation of MR images taken from premature infant brains*, **J. Neurosci. Methods**, 182 :1 (2009) 110–122.
- [63] A. Ortiz, J.M. Górriz, J. Ramírez, D. Salas-González, ve J.M. Llamas-Elvira, *Two fully-unsupervised methods for MR brain image segmentation using SOM-based strategies*, **Appl. Soft Comput. J.**, 13 :5 (2013) 2668–2682.
- [64] N. Zhang, S. Ruan, S. Lebonvallet, Q. Liao, ve Y. Zhu, *Kernel feature selection to fuse multi-spectral MRI images for brain tumor segmentation*, **Comput. Vis. Image Underst.**, 115 :2 (2011) 256–269.
- [65] H.A. Vrooman, C.A. Cocosco, F. van der Lijn, R. Stokking, M.A. Ikram, M.W. Vernooij, M.M.B. Breteler, ve W.J. Niessen, *Multi-spectral brain tissue segmentation using automatically trained k-Nearest-Neighbor classification*, **Neuroimage**, 37 :1 (2007) 71–81.
- [66] M.Y. Siyal ve L. Yu, *An intelligent modified fuzzy c-means based algorithm for bias estimation and segmentation of brain MRI*, **Pattern Recognit. Lett.**, 26 :13 (2005) 2052–2062.

- [67] L.H. Juang ve M.N. Wu, *MRI brain lesion image detection based on color-converted K-means clustering segmentation*, **Meas. J. Int. Meas. Confed.**, 43 :7 (2010) 941–949.
- [68] D. Yamamoto, H. Arimura, S. Kakeda, T. Magome, Y. Yamashita, F. Toyofuku, M. Ohki, Y. Higashida, ve Y. Korogi, *Computer-aided detection of multiple sclerosis lesions in brain magnetic resonance images: False positive reduction scheme consisted of rule-based, level set method, and support vector machine*, **Comput. Med. Imaging Graph.**, 34 :5 (2010) 404–413.
- [69] H. Bulu ve D.E. Üniversitesi, *Tıbbi Görüntüler için 3 Boyutlu Bölütleme Algoritmalarının Karşılaştırılması Comparison of 3D Segmentation Algorithms for Medical Imaging Bilgisayar Mühendisliği Bölümü*, (y.y.) 2–5.
- [70] T. Kulları, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 5 (2017) 345–355.
- [71] M. Eichmann, *Efficient Multilevel Image Thresholding*, :December (2005).
- [72] A. Demirhan ve I. Güler, *Image segmentation using self-organizing maps and gray level co-occurrence matrices*, **J. Fac. Eng. Archit. Gazi Univ.**, 25 :2 (2010) 285–291.
- [73] Y. hui Liu, M. Muftah, T. Das, L. Bai, K. Robson, ve D. Auer, *Classification of MR tumor images based on Gabor wavelet analysis*, **J. Med. Biol. Eng.**, 32 :1 (2012) 22–28.
- [74] E.A.S. El-Dahshan, H.M. Mohsen, K. Revett, ve A.B.M. Salem, *Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm*, **Expert Syst. Appl.**, 41 :11 (2014) 5526–5545.
- [75] E.J. Candès ve D.L. Donoho, *Curvelets: A Surprisingly Effective Nonadaptive Representation of Objects with Edges*, **Curves Surf. Fitting**, C :2 (2000) 1–10.
- [76] P.J. Burt ve E.H. ADELSON, *The Laplacian Pyramid as a Compact Image Code* - *Fundamental Papers in Wavelet Theory*, **Fundam. Pap. Wavelet Theory**, C :4 (1983) 532–540.
- [77] S. Biswas ve J. Sil, *An efficient face recognition method using contourlet transform*, **Proc. 2015 IEEE Int. Conf. Res. Comput. Intell. Commun. Networks, ICRCICN 2015**, (2016) 27–31.
- [78] Kazım Hanbay." Yuvarlak örgü makineleri için görüntü işleme tabanlı kumaş hatası

- tespit sistemi" PhD Thesis, İnönü University, Turkey, 2016.
- [79] Wang-Q Lim, *The Discrete Shearlet Transform: A New Directional Transform and Compactly Supported Shearlet Frames*, **IEEE Trans. Image Process.**, 19 :5 (2010) 1166–1180.
- [80] K. Guo ve D. Labate, *Optimally Sparse Multidimensional Representation Using Shearlets*, **SIAM J. Math. Anal.**, 39 :1 (2007) 298–318.
- [81] H. Kodal Sevindir, C. Yazıcı, ve S. Çetinkaya, *Asymptotic Analysis of Shearlet Transform for Inpainting*, **Sak. Univ. J. Sci.**, 22 :6 (2018) 1–1.
- [82] R. Vyas, T. Kanumuri, G. Sheoran, ve P. Dubey, *Efficient iris recognition through curvelet transform and polynomial fitting*, **Optik (Stuttg.)**, 185 :July 2018 (2019) 859–867.
- [83] A.D. Rahulkar, D. V. Jadhav, ve R.S. Holambe, *Fast discrete curvelet transform based anisotropic iris coding and recognition using k-out-of-n: A fused post-classifier*, **Mach. Vis. Appl.**, 23 :6 (2012) 1115–1127.
- [84] M. Zand, S. Doraisamy, A.A. Halin, ve M.R. Mustaffa, *Texture classification and discrimination for region-based image retrieval*, **J. Vis. Commun. Image Represent.**, 26 (2015) 305–316.
- [85] A. Şengür, Y. Guo, ve Y. Akbulut, *Time–frequency texture descriptors of EEG signals for efficient detection of epileptic seizure*, **Brain Informatics**, 3 :2 (2016) 101–108.
- [86] Ş. Öztürk ve B. Akdemir, *Application of Feature Extraction and Classification Methods for Histopathological Image using GLCM, LBP, LBGLCM, GLRLM and SFTA*, **Procedia Comput. Sci.**, 132 :Iccids (2018) 40–46.
- [87] Y. Wei, Q. Tian, J. Guo, W. Huang, ve J. Cao, *Multi-vehicle detection algorithm through combining Harr and HOG features*, **Math. Comput. Simul.**, 155 (2019) 130–145.
- [88] B. Yuan, B. Xia, ve D. Zhang, *Polarization image texture feature extraction algorithm based on CS-LBP operator*, **Procedia Comput. Sci.**, 131 (2018) 295–301.
- [89] Michael, E. Tipping ve Christopher M. Bishop, *Probabilistic Principal Component Analysis*, **J. R. Stat. Soc. Ser. B (Statistical Methodol.**, 61 (1999) 611–622.

- [90] D.L. Swets ve J.J. Weng, *Using discriminant eigenfeatures for image retrieval*, **IEEE Trans. Pattern Anal. Mach. Intell.**, 18 :8 (2002) 831–836.
- [91] P. Belhumeur, J. Hespanha, ve D. Kriegman, *Face recognition: Eigenfaces vs Fisherfaces: Recognition using class specific projection*, **IEEE Trans. Pattern Anal. Mach. Intell.**, 19 :7 (1997) 711–720.
- [92] M.J. McKeown, L.K. Hansen, ve T.J. Sejnowsk, *Independent component analysis of functional MRI: What is signal and what is noise?*, **Curr. Opin. Neurobiol.**, 13 :5 (2003) 620–629.
- [93] R. Aziz, C.K. Verma, ve N. Srivastava, *A novel approach for dimension reduction of microarray*, **Comput. Biol. Chem.**, 71 (2017) 161–169.
- [94] D. Karaboga, *An idea based on honey bee swarm for numerical optimization*, **Tech. Rep. TR06**, (2005).
- [95] R. Aziz, C.K. Verma, ve N. Srivastava, *A fuzzy based feature selection from independent component subspace for machine learning classification of microarray data*, **Genomics Data**, 8 (2016) 4–15.
- [96] D. Hanbay, I. Turkoglu, ve Y. Demir, *Modeling switched circuits based on wavelet decomposition and neural networks*, **J. Franklin Inst.**, 347 :3 (2010) 607–617.
- [97] Z. Li, B. Niu, F. Peng, G. Li, Z. Yang, ve J. Wu, *Classification of Peanut Images Based on Multi-features and SVM*, **IFAC-PapersOnLine**, 51 :17 (2018) 726–731.
- [98] B. Richhariya ve M. Tanveer, *EEG signal classification using universum support vector machine*, **Expert Syst. Appl.**, 106 (2018) 169–182.
- [99] S. Kang, D. Kim, ve S. Cho, *Approximate training of one-class support vector machines using expected margin*, **Comput. Ind. Eng.**, 130 :October 2018 (2019) 772–778.
- [100] A. Ari ve D. Hanbay, *Deep learning based brain tumor classification and detection system*, **Turkish J. Electr. Eng. Comput. Sci.**, 26 :5 (2018) 2275–2286.
- [101] C. Chen, B. Jiang, Z. Cheng, ve X. Jin, *Joint Domain Matching and Classification for cross-domain adaptation via ELM*, **Neurocomputing**, 349 (2019) 314–325.
- [102] O.F. Alcin, F. Ucar, ve D. Korkmaz, *Extreme learning machine based robotic arm*

- modeling*, **2016 21st Int. Conf. Methods Model. Autom. Robot. MMAR 2016**, :1 (2016) 1160–1163.
- [103] J.S.R. Jang, *ANFIS: Adaptive-Neural Network-Based Fuzzy Inference System* *IEEE Transactions on Systems, Man Cybern.*, 23 :3 (1993) 665–685.
- [104] R. Sofia ve D. Sivakumar, *Certain Investigations for Human Emotion Classification with Sugeno Model of ANFIS*, **Int. J. Innov. Technol. Explor. Eng.**, :4 (2019) 427–432.
- [105] D. Hanbay, A. Baylar, ve E. Ozpolat, *Predicting flow conditions over stepped chutes based on ANFIS*, **Soft Comput.**, 13 :7 (2009) 701–707.
- [106] A. Bhattacharya ve P. Vasant, *Soft-sensing of level of satisfaction in TOC product-mix decision heuristic using robust fuzzy-LP*, **Eur. J. Oper. Res.**, 177 :1 (2007) 55–70.
- [107] X. Huang, A. Maier, J. Hornegger, ve J.A.K. Suykens, *Indefinite kernels in least squares support vector machines and principal component analysis*, **Appl. Comput. Harmon. Anal.**, 43 :1 (2017) 162–172.
- [108] D. Hanbay, A. Baylar, ve M. Batan, *Prediction of aeration efficiency on stepped cascades by using least square support vector machines*, **Expert Syst. Appl.**, 36 :3 PART 1 (2009) 4248–4252.
- [109] H. Marouani ve Y. Fouad, *Particle swarm optimization performance for fitting of Lévy noise data*, **Phys. A Stat. Mech. its Appl.**, 514 (2019) 708–714.
- [110] Y. Chen, L. Li, J. Xiao, Y. Yang, J. Liang, ve T. Li, *Particle swarm optimizer with crossover operation*, **Eng. Appl. Artif. Intell.**, 70 :January (2018) 159–169.
- [111] A. Ali Hameed, B. Karlik, M.S. Salman, ve G. Eleyan, *Robust adaptive learning approach to self-organizing maps*, **Knowledge-Based Syst.**, 171 (2019) 25–36.
- [112] K. Taşdemir, P. Milenov, ve B. Tapsall, *Topology-based hierarchical clustering of self-organizing maps*, **IEEE Trans. Neural Networks**, 22 :3 (2011) 474–485.
- [113] Mesut Pişkin. <http://mesutpiskin.com/blog/opencv-morfolojik-operatorler-ve-filtreler.html> (on line access on 18 March, 2019).
- [114] R.C. Gonzalez, *Digital_Image_Processing_2ndEd.pdf*, (2002).
- [115] Halime Boztoprak." Görüntü işleme teknikleri ve yapay zeka yöntemleri kullanarak

- atıksu arıtmada performans analizlerinin incelenmesi". PhD Thesis, Selcuk University, Turkey, 2014.
- [116] G. ATALI, S.S. Özkan, ve D. Karayel, *Morfolojik Görüntü İşleme Tekniği ile Yapay Sinir Ağlarında Görüntü Tahribat Analizi*, **Acad. Platf. J. Eng. Sci.**, 4 :1 (2016) 1–7.
- [117] Halime Boztoprak." **Gerçek Zamanlı Tasit Plaka Tanıma Sistemi**". M.Sc. Thesis, Ispart University, Turkey, 2007.
- [118] Acharya, *Image Processing: Principles and Applications [book review]*, (2007).
- [119] A. Madani, R. Arnaout, M. Mofrad, ve R. Arnaout, *Fast and accurate view classification of echocardiograms using deep learning*, **npj Digit. Med.**, 1 :1 (2018) 6.
- [120] X.W. Gao, R. Hui, ve Z. Tian, *Classification of CT brain images based on deep learning networks*, **Comput. Methods Programs Biomed.**, 138 (2017) 49–56.
- [121] D.D.N. De Silva, S. Fernando, I.T.S. Piyatilake, ve A.V.S. Karunaratne, *Wavelet based edge feature enhancement for convolutional neural networks*, (2018).
- [122] S. Park ve J. Woo, *Gender Classification Using Sentiment Analysis and Deep Learning in a Health Web Forum*, **Appl. Sci.**, 9 :6 (2019) 1249.
- [123] GitHub. <https://github.com/Kulbear/deep-learning-nanofoundation/wiki/ReLU-and-Softmax-ActivationFunctions> (On line acces on 22 May, 2018).
- [124] CS231n: Convolutional Neural Networks for Visual Recognition. <http://cs231n.github.io/convolutionalnetworks/#fc>. (On line acces on 20 October, 2017).
- [125] M. Havaei, A. Davy, D. Warde-Farley, A. Biard, A. Courville, Y. Bengio, C. Pal, P.M. Jodoin, ve H. Larochelle, *Brain tumor segmentation with Deep Neural Networks*, **Med. Image Anal.**, 35 (2017) 18–31.
- [126] A. Cicuttin, M.L. Crespo, K.S. Mannatunga, V.V. Garcia, G. Baldazzi, L.P. Rignanese, M. Ahangarianabhari, G. Bertuccio, S. Fabiani, A. Rachevski, I. Rashevskaya, A. Vacchi, G. Zampa, N. Zampa, P. Bellutti, A. Picciotto, C. Piemonte, ve N. Zorzi, *A programmable System-on-Chip based digital pulse processing for high resolution X-ray spectroscopy*, **2016 Int. Conf. Adv. Electr. Electron. Syst. Eng. ICAEES 2016**, 15 (2017) 520–525.

- [127] S. Ioffe ve C. Szegedy, *Batch Normalization : Accelerating Deep Network Training by Reducing Internal Covariate Shift*, (y.y.).
- [128] S. Lu, Z. Lu, ve Y. Zhang, *Pathological brain detection based on AlexNet and transfer learning*, **J. Comput. Sci.**, 30 (2019) 41–47.
- [129] A. Krizhevsky ve G.E. Hinton, *ImageNet Classification with Deep Convolutional Neural Networks*, (y.y.) 1–9.
- [130] M.D. Zeiler ve R. Fergus, *Visualizing and Understanding Convolutional Networks*, (2014) 818–833.
- [131] Z. Kolar, H. Chen, ve X. Luo, *Automation in Construction Transfer learning and deep convolutional neural networks for safety guardrail detection in 2D images*, **Autom. Constr.**, 89 :May 2017 (2018) 58–70.
- [132] M. Lin, Q. Chen, ve S. Yan, *Network In Network*, (y.y.) 1–10.
- [133] S. Liu, G. Tian, ve Y. Xu, *A novel scene classification model combining ResNet based transfer learning and data augmentation with a filter*, **Neurocomputing**, 338 (2019) 191–206.
- [134] K. Greff, *Training Very Deep Networks*, (y.y.) 1–9.
- [135] G. Huang, Z. Liu, L. Van Der Maaten, ve K.Q. Weinberger, *Densely connected convolutional networks*, **Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017**, 2017-Janua (2017) 2261–2269.
- [136] J. Hu, L. Shen, S. Albanie, G. Sun, ve E. Wu, *Squeeze-and-Excitation Networks*, (y.y.) 1–13.
- [137] B. Zoph ve J. Shlens, *Learning Transferable Architectures for Scalable Image Recognition*, (y.y.).
- [138] T. Saikia ve F. Hutter, *AutoDispNet: Improving Disparity Estimation with AutoML*, (y.y.).
- [139] Hendry ve R.-C. Chen, *Automatic License Plate Recognition Via Sliding-Window Darknet-Yolo Deep Learning*, **Image Vis. Comput.**, (2019).
- [140] O. Ronneberger, P. Fischer, ve T. Brox, *U-Net: Convolutional Networks for Biomedical Image Segmentation*, (y.y.) 1–8.

- [141] J. Amin, M. Sharif, M. Yasmin, ve S.L. Fernandes, *A distinctive approach in brain tumor detection and classification using MRI*, **Pattern Recognit. Lett.**, 0 (2017) 1–10.
- [142] M.G. Armato, Sam, Reinhard Beichel, Luc Bidaut, Larry Clarke, Barbara Croft, Chuck Fenimore, *No Title*, (y.y.).
- [143] figshare. https://figshare.com/articles/brain_tumor_dataset/1512427 (On line acces on 15 April 2018).
- [144] J. Cheng, W. Yang, M. Huang, W. Huang, J. Jiang, Y. Zhou, R. Yang, J. Zhao, Y. Feng, Q. Feng, ve W. Chen, *Retrieval of Brain Tumors by Adaptive Spatial Pooling and Fisher Vector Representation*, **PLoS One**, 11 :6 (2016) e0157112.
- [145] S. Kazdal, B. Dogan, ve A.Y. Camurcu, *Computer-aided detection of brain tumors using image processing techniques*, (2015) 863–866.
- [146] Ari A, Hanbay D, “MR Görüntülerinden Aşırı Öğrenme Makinesi Tabanlı Tümör Tespiti”, IMESET international Conference, 226, 2017, Bitlis, Türkiye.
- [147] A. Ari ve D. Hanbay, *An Expert Systems for Brain MR Images Classification by Using Ensemble Neural Network*, :2 (2018) 44–56.

ÖZGEÇMİŞ

18.03.1988 tarihinde Tarsus'da doğdum. İlköğretim ve ortaöğretim eğitimimi Tarsus'da tamamladım. 2010 yılında Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik Bilgisayar Eğitimi Bölümü Bilgisayar Öğretmenliğinden mezun oldum. 2011 yılında Diyarbakır Eğil METEM'e Bilişim Teknolojileri öğretmeni olarak atandım. 2013 Yılında Fırat Üniversitesi Fen Bilimleri Enstitüsü Elektronik Bilgisayar Bölümü Telekomünikasyon Ana Bilim Dalı'nda Yüksek Lisans eğitimi tamamladım. 2015 yılında Fırat Üniversitesi Bilgisayar Mühendisliği Bölümünden Mühendislik Tamamlama Programı ile mezun oldum ve aynı yıl İnönü Üniversitesi Bilgisayar Mühendisliği bölümünde Doktora öğrenimine başladım. Evli ve bir çocuk babasıyım.

