



**T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



DOKTORA TEZİ

**DİKKAT EKSİKLİĞİ HİPERAKTİVİTE BOZUKLUĞUNUN
MAKİNE VE DERİN ÖĞRENME TEKNİKLERİ İLE TESPİTİ**

Gülay ÇİÇEK

**DANIŞMAN
Prof.Dr. Aydın AKAN**

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

İSTANBUL-2021

Bu alıřma 28.07.2021 tarihinde ařağıdaki jüri tarafından Biyomedikal Mühendisliğı Anabilim Dalı Biyomedikal Mühendisliğı Programında Doktora Tezi olarak kabul edilmiştir.

Tez Jürisi

Prof.Dr. Aydın AKAN (Danışman)
İzmir Ekonomi Üniversitesi
Mühendislik Fakültesi

Prof.Dr. Fırat KAÇAR
İstanbul Üniversitesi-Cerrahpařa
Mühendislik Fakültesi

Prof.Dr. Osman Nuri UÇAN
Altınbaş Üniversitesi
Mühendislik Fakültesi

Do.Dr. Esra SAATÇI
İstanbul Kültür Üniversitesi
Mühendislik Fakültesi

Do.Dr. Yasin ÖZÇELEP
İstanbul Üniversitesi-Cerrahpařa
Mühendislik Fakültesi



20.04.2016 tarihli resmi gazetede yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın aboneli olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu çalışma İzmir Katip Çelebi Üniversitesi Bilimsel Araştırma Projeleri Yürütücü Sekreterliğinin 2017-ÖNAP-MÜMF-002 and 2019-GAP-MÜMF-003 numaralı projesi ile desteklenmiştir.

ÖNSÖZ

Öncelikle, hayatımın her alanında bana güç veren, ilham kaynağım Allah'ıma sonsuz şükürümü sunarım.

Bu tez çalışmamın yürütülmesinde desteğini hiçbir zaman esirgemeyen, emekleri ve fedakarlıkları için, hakkı ödenmez değerli danışman hocam Prof.Dr. Aydın AKAN'a teşekkür ederim.

Maddi ve manevi desteklerini esirgemeyen, varlıkları ile çalışma azmimi artıran, değerli babama, anneme ve kardeşlerime teşekkür ederim

Temmuz 2021

Gülây ÇİÇEK

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ	i
İÇİNDEKİLER	iv
ŞEKİL LİSTESİ	vi
TABLO LİSTESİ	vii
SİMGE VE KISALTMA LİSTESİ	ix
ÖZET	xi
SUMMARY	xiii
1. GİRİŞ	1
1.1. PROBLEM TESPİTİ	3
1.2. TEZİN AMACI	4
1.2.1. Genel	4
1.2.2. Özel	4
1.3. ARAŞTIRMA YÖNTEMİ	5
1.3.1. Uygulama Alanını Anlamak	5
1.3.1.1. Veri Kümesi Seçme ve Oluşturma	6
1.3.1.2. Veri Temizleme ve Ön İşleme	6
1.3.1.3. Öznitelik Çıkartma	6
1.3.1.4. Öznitelik Seçme	7
1.3.1.5. Uygun Sınıflandırma Algoritmanın Tespiti	7
1.3.1.6. Sınıflandırma Algoritmalarının Uygulanması	7
1.3.1.7. Değerlendirme	8
1.3.2. Araçlar	8
1.4. TEZİN KATKILARI	8
2. GENEL KISIMLAR	10
2.1. LİTERATÜR ÖZETİ	10
3. MALZEME VE YÖNTEM	17

3.1. VERİ KÜMESİ	18
3.2. VERİ ÖN İŞLEME	22
3.3. VERİ ARTIRIMI	22
3.4. ÖZNİTELİK ÇIKARTMA	25
3.4.1. Geleneksel Makine Öğrenimi ile Öznitelik Çıkartma	25
3.4.1.1. Doku Özellikleri	25
3.4.1.2. İstatistiksel doku özellikleri	26
3.4.1.3. Birinci Dereceden İstatistiksel Doku Analizi	26
3.4.1.4. İkinci Dereceden İstatistiksel Doku Analizi	27
3.4.1.5. Yerel İkili Örüntüler	27
3.4.1.6. Gri Seviye Eş Oluşum Matrisi (GLCM)	28
3.4.1.7. Haralick Doku Özellikleri	29
3.4.2. Derin Öğrenmeyi Kullanarak Otomatik Özellik Ayıklama	30
3.4.2.1. Transfer Öğrenimi	32
3.4.2.2. AlexNet	32
3.4.2.3. VGGNet	33
3.4.2.4. ResNet	33
3.4.2.5. SqueezeNet	34
3.4.2.6. Inception-ResNet	35
3.4.2.7. Önerilen CNN Mimarisi	35
3.5. ÖZNİTELİK SEÇME	35
3.5.1. Temel Bileşenler Analizi	36
3.6. SINIFLANDIRMA	37
3.6.1. K En Yakın Komşu Algoritması	37
3.6.2. Karar Ağaçları	39
3.6.3. Destek Vektör Makinesi	40
3.6.4. Topluluk Öğrenme Algoritmaları	40
3.6.4.1. Torbalama	41
3.6.4.2. Yükseltme	41
3.6.4.3. Rastgele Orman	42
3.7. DEĞERLENDİRME ÖLÇÜTLERİ	42
3.7.1. Karmaşıklık Matrisi	42

3.7.2. Çapraz Doğrulama Yöntemi	44
3.7.2.1. K-Katlamalı Çapraz Doğrulama	44
3.7.2.2. Dışarıda Bırakma Çapraz Geçerleme	45
3.7.2.3. Birini Dışarıda Bırakma Yöntemi	45
4. BULGULAR	47
4.1. MAKİNE ÖĞRENME ALGORİTMALARI İLE MODEL SONUÇLARI (YÖNTEM1)	47
4.2. DERİN ÖĞRENME ALGORİTMALARI İLE DENEY SONUÇLARI (YÖNTEM 2)	63
5. TARTIŞMA VE SONUÇLAR	73
5.1. TARTIŞMA	73
5.2. SONUÇLAR	75
KAYNAKLAR	78
EKLER	85
EK 1. Etik Kurul Onay Raporu	85
ÖZGEÇMİŞ	86

ŞEKİL LİSTESİ

	Sayfa No
Şekil 3.1: DEHB Tespit Methodoloji	18
Şekil 3.2: Bütün Kesitler ve Secili Kesitler	20
Şekil 3.3: Medyan Filtre.....	22
Şekil 3.4: LBP operatörüne bir örnek	28
Şekil 3.5: Basit Bir Derin Öğrenme Yapısı	30
Şekil 3.6: Evrişim ve Havuzlama Katmanı Örneği	31
Şekil 3.7: Nonlinear Aktivasyon Fonksiyonu (a) ReLU (b) TanH	31
Şekil 3.8: AlexNet Mimarisi	32
Şekil 3.9: VGGNet Mimarisi	33
Şekil 3.10: Artık Bloklar.....	34
Şekil 3.11: SqueezeNet Mimarisi	34
Şekil 3.12: Detaylı AlexNet Mimarisi	36
Şekil 3.13: Önerilen CNN Mimarisi [GulayNet Mimari :)]	36
Şekil 3.14: En Yakın Komşu Sınıflandırıcısı	38
Şekil 3.15: Mesafe Ölçüleri	38
Şekil 3.16: İkili Ağaç	39
Şekil 3.17: Destek Vektör Makinesi	40
Şekil 3.18: Topluluk Öğrenme Algoritmaları	41
Şekil 3.19: Torbalama Algoritması	41
Şekil 3.20: Yükseltme Algoritması	42
Şekil 3.21: Rastgele Orman Algoritması	42
Şekil 3.22: 10 Kat Çapraz Doğrulama Diyagramı.....	45
Şekil 3.23: Dışarıda Bırakma Çapraz Doğrulama Diyagramı.....	45
Şekil 3.24: Birini Dışarıda Bırakma Çapraz Doğrulama Diyagramı	46

Şekil 4.1: Doğruluk Oranları [Veri Kümesi1-PCAOFF]	58
Şekil 4.2: Duyarlılık Oranları [Veri Kümesi1-PCAOFF]	59
Şekil 4.3: Özgüllük Oranları [Veri Kümesi1-PCAOFF]	59
Şekil 4.4: Kesinlik oranları [Veri Kümesi1- PCAOFF].....	60
Şekil 4.5: F-Olcutu Oranları [Veri Kümesi1- PCAOFF]	60
Şekil 4.6: Doğruluk Oranları [Veri Kümesi2-PCAOFF]	61
Şekil 4.7: Duyarlılık Oranları [Veri Kümesi2-PCAOFF]	61
Şekil 4.8: Özgüllük Oranları [Veri Kümesi2-PCAOFF]	62
Şekil 4.9: Kesinlik Oranları [Veri Kümesi2-PCAOFF].....	62
Şekil 4.10: F-Olcutu Oranları [Veri Kümesi2-PCAOFF].....	63

TABLO LİSTESİ

	Sayfa No
Tablo 3.1: NPIstanbul ve ADHD200 Verikümesi.....	19
Tablo 3.2: Karmaşıklık Matrisi	43
Tablo 4.1: LBP Yönteminin Performans Sonuçları	49
Tablo 4.2: Birinci Mertebe Yönteminin Performans Sonuçları	50
Tablo 4.3: Haralick Yönteminin Performans Sonuçları	51
Tablo 4.4: GLCM Yönteminin Performans Sonuçları	52
Tablo 4.5: AlexNet Yönteminin Performans Sonuçları	53
Tablo 4.6: VGGNet Yönteminin Performans Sonuçları	54
Tablo 4.7: ResNet Yönteminin Performans Sonuçları	55
Tablo 4.8: SqueezeNet Yönteminin Performans Sonuçları	56
Tablo 4.9: Inception-ResNet Yönteminin Performans Sonuçları.....	57
Tablo 4.10: Artırılmış Verinin AlexNet Mimarisi ile Performans Sonuçları	65
Tablo 4.11: Artırılmış Verinin ResNet-18 Mimarisi ile Performans Sonuçları	66
Tablo 4.12: Artırılmış Verinin ResNet-50 Mimarisi ile Performans Sonuçları	67
Tablo 4.13: Artırılmış Verinin ResNet-101 Mimarisi ile Performans Sonuçları.....	68
Tablo 4.14: Artırılmış Verinin VGG-16 Mimarisi ile Performans Sonuçları	69
Tablo 4.15: Artırılmış Verinin VGG-19 Mimarisi ile Performans Sonuçları	70
Tablo 4.16: Artırılmış Verinin SqueezeNet Mimarisi ile Performans Sonuçları	71
Tablo 4.17: Artırılmış Verinin Önerilen CNN Ağı ile Performans Sonuçları	72
Tablo 5.1: Mevcut Benzer Çalışmalarla Karşılaştırma	74
Tablo 5.2: Algoritmaların Ortalama Performans Sonuçları [VeriKümesi1-PCAOFF]	74
Tablo 5.3: Algoritmaların Ortalama Performans Sonuçları [Verikümesi2-PCAOFF]	75

SİMGE VE KISALTMA LİSTESİ

Simgeler

Açıklama

$I_{euclid}(\mathbf{x}, \mathbf{y})$	: Öklid uzaklık fonksiyonu
$I_{manhattan}(\mathbf{x}, \mathbf{y})$	: Manhattan uzaklık fonksiyonu
$I_{Chebyshev}(\mathbf{x}, \mathbf{y})$	: Chebyshev mesafesi
μ	: Ortalama
σ	: Standart Sapma
σ^2	: Varyans

Kısaltmalar

Açıklama

ACC	: Doğruluk (<i>eng.</i> Accuracy)
ANN	: Yapay Sinir Ağları (<i>eng.</i> Artificial Neural Network)
CAD	: Bilgisayar Destekli Yardım (<i>eng.</i> Computer aided design)
CART	: Sınıflandırma ve Regresyon Ağacı (<i>eng.</i> Classification and Regression Tree)
CNN	: Evrimsel Sinir Ağları (<i>eng.</i> Convolutional Neural Network)
CPU	: Merkezi İşlem Birimi (<i>eng.</i> Central Processing Unit)
CT	: Bilgisayarlı Tomografi (<i>eng.</i> Computed Tomography)
DEHB	: Dikkat Eksikliği Hiperaktivite Bozukluğu
FM	: F-Olcutu (<i>eng.</i> F-Measure)
FMRI	: Fonksiyonel Magnetik Rezonans Görüntüsü (<i>eng.</i> Functional Magnetic Resonance Imaging)
DL	: Derin Öğrenme (<i>eng.</i> Deep Learning)
EEG	: Elektroensefalografi (<i>eng.</i> Elektroensefalogram)
ELM	: Aşırı Öğrenme Algoritması (<i>eng.</i> Extreme Learning Algorithm)
GM	: Gri Madde (<i>eng.</i> Gray Matter)
GLCM	: Gri Seviye Eş Oluşum Matrisi (<i>eng.</i> Gray Level Co-Occurrence Matris)
IQ	: Zeka Katsayısı (<i>eng.</i> Intelligence Quatient)
KNN	: K En Yakın Komşu (<i>eng.</i> K Nearest Neighbor)

LBP	: Yerel İkili Örüntü (<i>eng.</i> Local Binary Pattern)
LBP-TOP	: Üç Ortogonal Düzlemde Yerel İkili Modeller (<i>eng.</i> Local Binary Patterns on Three orthogonal Planes)
MEG	: Manyetoensefalografi (<i>eng.</i> Magnetoencephalography)
MKL	: Çoklu Çekirdek Algoritması (<i>eng.</i> Multiple Kernel Algorithm)
ML	: Makine Öğrenme (<i>eng.</i> Machine Learning)
PCA	: Temel Bileşenler Analizi (<i>eng.</i> Principal Component Analysis)
PREC	: Kesinlik (<i>eng.</i> Precision)
RBF	: Radyal Temel Fonksiyonu (<i>eng.</i> Radial Basis Function)
RS-FMRI	: Dinlenme Durumu Fonksiyonel Manyetik Resonance Görüntü (<i>eng.</i> Resting State Functional Magnetic Resonance Imaging)
SENS	: Duyarlılık (<i>eng.</i> Sensitivity)
SPEC	: Özgüllük (<i>eng.</i> Specificity)
SMRI	: Yapısal Magnetik Rezonans Görüntüsü (<i>eng.</i> Structural Magnetic Resonance)
SVM	: Destek Vektör Makineleri (<i>eng.</i> Support Vector Machine)
PET	: Pozitron emisyon tomografisi (<i>eng.</i> Positron emission tomography)
T ACC	: Eğitim Doğruluğu (<i>eng.</i> Training Accuracy)
T LOSS	: Eğitim Kaybı (<i>eng.</i> Training Loss)
V ACC	: Validasyon Doğruluğu (<i>eng.</i> Validation Accuracy)
V LOSS	: Validasyon Kaybı (<i>eng.</i> Validation Loss)

ÖZET

DOKTORA TEZİ

DİKKAT EKSİKLİĞİ HİPERAKTİVİTE BOZUKLUĞUNUN MAKİNE VE DERİN ÖĞRENME TEKNİKLERİ İLE TESPİTİ

Gülay ÇİÇEK

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof.Dr. Aydın AKAN

Dikkat Eksikliği Hiperaktivite Bozukluğu (DEHB), çocuklukta başlayan ve tedavi edilmediğinde ömür boyu sürebilen nöropsikiyatrik bir bozukluktur. Teknolojik gelişmeler, önceden tespit edilemeyen nöroanatomik ve nörofizyolojik temellerin anlaşılmasına katkıda bulunmuştur. Psikiyatrik ve fiziksel bozuklukların teşhisinde farklı modern nörogörüntüleme tekniklerinden yararlanılır. Yapısal MR, iyonlaştırıcı radyasyona dayanmayan ve beynin anatomisini ve patolojisini incelemeye kullanılan invazif olmayan bir yöntemdir. Yapısal MR, DEHB tanısında kritik bir araçtır ve beyin gelişimindeki minimal bozuklukların tespit edilmesini sağlar. DEHB'li bireylerin beyin dokusunda yapısal değişiklikler mevcuttur. Örneğin, prefrontal korteks, bazal gangliyonlar, beyaz ve gri maddeler, serebellum ve parieto-temporal bölgelerde hacimsel azalmalar mevcuttur.

Bu çalışmada, yapısal MR verileri kullanılarak Makine Öğrenme ve Derin Öğrenme yöntemleri ile objektif ve güvenilir bir DEHB tespit modeli geliştirilmiştir. Bu amaçla tezde, DEHB sınıflandırılması için iki farklı yaklaşım sunulmuştur. İlki, ML ve DL algoritmalarının birlikte kullanıldığı bir yöntem iken, diğeri sadece DL algoritmalarına dayanmaktadır. Birçok psikiyatrik hastalığın teşhisinde önemli bir parametre olarak kabul edilen gri ve beyaz madde, bu çalışmada da referans alınmıştır. Bu amaçla, gri ve beyaz maddenin tam ve net görüldüğü dilimlerin tespiti için bir algoritma geliştirildi. Bu algoritma vasıtasıyla seçilen dilimler ilk veri kümesine atanırken, yapısal MR'ı oluşturan bütün dilimlerde başka bir veri kümesine atandı. Bu veri kümesi, DEHB tespit metodolojilerinde kullanıldı. İlk metodolojide, Birinci Mertebe, İkinci Mertebe (LBP, GLCM, Haralick) istatistiksel ML

yöntemleri ile AlexNet, ResNet, VggNet, SqueezeNet ve Inception-ResNet DL mimarileri kullanarak farklı öznelik kümeleri oluşturuldu. Temel bileşenler analizi ile öznelik seçim yöntemi uygulandı. Tekil ve Çoklu sınıflandırma algoritmaları ile DEHB sınıflandırma modeli oluşturuldu. İkinci methodolojide ise, sadece DL mimarilerine dayanmaktadır. DL mimarilerinin sınıflandırma başarısı, veri miktarıyla doğru orantılı olduğundan dolayı, çevrim içi geometrik veri artırım teknikleri ile yapısal MR verileri artırıldı. AlexNet, VggNet (16,19), ResNet (18,50,101), SqueezeNet mimarileri ile sınıflandırma işlemleri gerçekleştirildi. Buna ek olarak, AlexNet mimarisinden esinlenerek tasarladığımız CNN ağımlar ile DEHB sınıflandırma modelleri oluşturuldu. İlk methodolojide, önerilen algoritma yardımıyla tespit edilen yapısal MR kesitlerini içeren birinci veri kümesi ile oluşturulan sınıflandırma modellerinde başarılı sonuçlar elde edildi. ML öznelik çıkarımında kullanılan LBP, Haralick, Birinci Mertebe ve GLCM yöntemleri ile, DL öznelik çıkarımında kullanılan AlexNet ve Inception-ResNet yöntemlerinde yüksek sınıflandırma performansları elde edildi. İkinci methodolojide ise, bütün dilimleri içeren ikinci veri kümesi ile yüksek sınıflandırma sonuçları elde edildi. AlexNet mimarisi ile tasarladığımız CNN ağımlarında yüksek sınıflandırma performansları gözlemlendi.

Temmuz 2021, 103 sayfa.

Anahtar kelimeler: Dikkat Eksikliği Hiperaktivite Bozukluğu, Yapısal Manyetik Rezonans, Görüntü İşleme, Makine Öğrenme Algoritmaları, Derin Öğrenme Algoritmaları

SUMMARY

Ph.D. THESIS

DETECTION OF ATTENTION DEFICIT HYPERACTIVITY DISORDER BY MACHINE AND DEEP LEARNING TECHNIQUES

Gülay ÇİÇEK

İstanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Biomedical Engineering

Supervisor: Prof.Dr. Aydın AKAN

Attention Deficit Hyperactivity Disorder (ADHD) is a neuropsychiatric disorder that begins in childhood and can last a lifetime if left untreated. Technological advances have contributed to the understanding of previously undetected neuroanatomical and neurophysiological foundations. Different modern neuroimaging techniques are used in the diagnosis of psychiatric and physical disorders. Structural MRI is a non-invasive method that does not rely on ionizing radiation and is used to study the anatomy and pathology of the brain. Structural MRI is a critical tool in the diagnosis of ADHD and enables the detection of minimal disturbances in brain development. There are structural changes in the brain tissue of individuals with ADHD. For example, there are volumetric reductions in the prefrontal cortex, basal ganglia, white and gray matter, cerebellum, and parieto-temporal regions.

In this study, an objective and reliable ADHD detection model was developed with Machine Learning and Deep Learning methods using structural MR data. For this purpose, two different approaches for the classification of ADHD are presented in the thesis. While the first is a method in which ML and DL algorithms are used together, the other is based only on DL algorithms. Gray and white matter, which are accepted as an important parameter in the diagnosis of many psychiatric diseases, were also taken as reference in this study. For this purpose, an algorithm was developed to detect slices in which gray and white matter appear complete and clear. While the slices selected by this algorithm were assigned to the first dataset, all the slices constituting the structural MR were assigned to another dataset. These datasets were used in ADHD detection methodologies. In the first methodology,

different feature sets were created using First Order, Second Order (LBP, GLCM, Haralick) statistical ML methods and AlexNet, ResNet, VggNet, SqueezeNet and Inception-ResNet DL architectures. Feature selection method was applied with principal component analysis. ADHD classification model was created with Single and Ensemble classification algorithms. In the second methodology, it is based only on DL architectures. Since the classification success of DL architectures is directly proportional to the amount of data, structural MR data has been increased with online geometric data augmentation techniques. Classification processes were performed with AlexNet, VggNet (16,19), ResNet (18,50,101), SqueezeNet architectures. In addition, ADHD classification models were created with our CNN network, which we designed inspired by the AlexNet architecture. In the first methodology, successful results were obtained in the classification models created with the first dataset containing the structural MR sections determined with the help of the proposed algorithm. High classification performances were obtained in LBP, Haralick, First Order and GLCM methods used in ML feature extraction, and AlexNet and Inception-ResNet methods used in DL feature extraction. In the second methodology, high classification results were obtained with the second dataset containing all slices. High classification performances were observed in the CNN network we designed with AlexNet architecture.

July 2021, 103 pages.

Keywords: Attention Deficit Hyperactivity Disorder, Structural Magnetic Resonance Imaging, Image Processing, Machine Learning Algorithm, Deep Learning Algorithm

1. GİRİŞ

Ömür boyu sürebilen nörolojik sistemin anormal işleyişinden kaynaklanan nörolojik bozukluklar, sinir sistemindeki bir grup belirti ile karakterizedir [1]. İletişim, davranış ve motor becerilerini olumsuz etkileyen bu bozukluklar, bireyin hayatının birçok alanında önemli problemlere sebep olmaktadır. Zihinsel engellilik, iletişim bozuklukları, öğrenme bozukluğu, motor bozuklukları, dikkat eksikliği hiperaktivite bozukluğu, otizm, nörolojik bozukluklar kategorisinde yer almaktadır. Zihinsel engellilik; akıl yürütme, problem çözme, planlama, akademik öğrenme gibi genel zihinsel becerilerdeki eksiklikler ile karakterize edilir. İletişim bozukluğu; dil bozukluğu ve çocukluk çağında başlayan kekemecilik gibi iletişimdeki eksikler ile karakterizedir. Öğrenme bozukluğu; bireyin öğrenme ve akademik becerilerinde etkili ve doğru bir şekilde algılamama ile karakterize edilir. Motor bozuklukları; omuz sallama, kafa sallama gibi tekrarlayan hareketler gibi motor becerilerindeki eksiklikler ile karakterizedir. Dikkat Eksikliği hiperaktivite bozukluğu (DEHB), dikkat eksikliği, dürtüsellik ve aşırı hareketlilik belirtileri ile karakterizedir [2].

DEHB çocukluk çağında başlayıp, tedavi edilmediği takdirde ömür boyu sürebilen nöropsikiyatrik hastalıktır [3]. DEHB; dikkatsizlik, dürtüsellik ve hiperaktivite ile karakterizedir [4]. Çocukların % 5'ini ve yetişkinlerin % 2,5'ini etkileyen zamanımızın en yaygın beyin hastalıkları arasındadır [5]. Dikkatsizlik semptomları, bireylerin uzun süre dikkatlerini sürdürmelerine engel olarak konsantre olamamalarına sebep olmaktadır. Hiperaktiflik, bireyin uzun süre rahat ve sakin oturamamasına ve sürekli hareket halinde olmasına sebep olur. Dürtüsellik ise, bireylerin isteklerini kontrol edememelerine ve olaylar hakkında hızlıca karar vermesine sebep olur. DEHB semptomları bireyden bireye farklılık arz etmektedir. Diğer bir değişle, belirtilerin kombinasyonları birey bazında değişmektedir. Bazı bireylerde, dikkatsizlik ve dürtüsellik birlikte görülürken, bazı bireylerde, dikkatsizlik, dürtüsellik ve hiperaktivite birlikte görülebilmektedir [6]. Erken

teşhis edilmediği durumlarda, öğrenme güçlüğü, tik bozuklukları, duygudurum bozuklukları, şiddete yatkınlık ve diğer psikiyatrik bozukluklar bu bozukluğa eşlik edilmesine sebep olur [7].

Teknolojik gelişmeler, önceden tespit edilemeyen nöroanatomik ve nörofizyolojik temellerin anlaşılmasına katkıda bulunmuştur. Psikiyatrik ve fiziksel bozuklukların teşhisinde, CT, sMRI, fMRI ve PET gibi modern nörogörüntüleme teknikleri kullanılır. Yapısal MR, iyonlaştırıcı radyasyona dayanmayan ve beyin anatomisini ve patolojisini incelemenin yanı sıra uzun vadeli evrimleri incelemek için sıklıkla kullanılan, invazif olmayan bir yöntemdir [8]. Yapısal MR, beyin gelişimindeki minimal bozuklukları tespit etmeyi sağlayan, DEHB'nin teşhisinde kritik bir araçtır [8]. Literatür çalışmalarında, DEHB'li bireylerin beyin sMRI'nda bazı değişiklikler tespit edilmiştir. DEHB'li bireylerde hareket, hafıza ve duygusal kontrolde önemli rol oynayan gri madde hacminin azaldığı gösterilmiştir [9]. Dikkatle ilgili işlevleri sağlayan kortikal kalınlığın küçüldüğü tespit edildi [10]. Ayrıca prefrontal korteks, bazal gangliyonlar, serebellum ve parieto-temporal bölgelerin hacimlerinin azaldığı da gözlemlendi [11–13]. DEHB'li bireylerin serebral hacimleri sağlıklı bireylerden % 3.2 daha küçüktür. Serebral hacimde, özellikle de frontal hacimde % 48 azalma gözlemlenmiştir [14]. Sağlıklı gruplarla karşılaştırıldığında DEHB'de hacim ve asimetri farklılıkları görülmektedir [11; 15; 16]. DEHB'li bireylerde hem sağ hem de sol prefrontal kortekste beyaz ve gri maddede azalma gözlemlendi [17–19]. Başka bir çalışmada, çocuklarda ve yetişkinlerde yapılan hacimsel yapısal MR çalışmalarında, daha küçük hacimlerde gri madde ve frontal bölgenin hacmi, bazal gangliyonların kaudat çekirdeğinin hacminde azalma olduğu gözlemlenmiştir [20].

Bilgisayar destekli teşhis sistemleri, beyin yapısının yorumlanmasındaki tutarlılığı artırarak tanısal değerlendirmelere katkıda bulunur [21]. CAD sistemleri hem fiziksel hem de psikiyatrik hastalıkların teşhis ve takibinde büyük önem taşır [22]. Bu çalışmada, yapısal MR kullanarak objektif ve güvenilir bir DEHB algılama modeli geliştirmek hedeflendi.

1.1. PROBLEM TESPİTİ

DEHB, akademik, psikiyatrik, sosyal, mesleki alan gibi bireyin birçok yönünü etkileyebilecek kronik bir bozukluktur [23]. Tedavi edilmediği takdirde DEHB'ye genellikle, majör depresif bozukluk, anksiyete bozukluğu, obsesif kompulsif bozukluk gibi diğer komorbiteler eşlik eder [24].

DEHB'li çocuklar büyüdükçe, bu bozukluktan etkileme şekilleri değişmektedir. 7 yaşında; kendine güven öz saygının azlığı, 11 yaşında; rahatsız edici davranış, öğrenme eksikliği, zayıf sosyal beceriler, 14 yaşında; meydan okuma, suçlara yönelme, okuldan dışlanma, madde bağımlılığı, motivasyon eksikliği ve karmaşık öğrenme güçlükleri görülebilmektedir [23].

Amerika Birleşik Devletlerinde yapılan bir çalışmaya göre milyonlarca kişi DEHB teşhisi kondu. 2016 Ulusal Çocuk Sağlığı araştırması 2-17 yaş arasında, 6.1 milyon çocuk arasında DEHB nin görüldüğünü bildirdi. DEHB tanı konma durumu, ABD'de 2-5 yaş arası 388.00 çocuk, 6-11 yaş arası 2.4 milyon çocuk, 12-17 yaş arası 3.3 milyon çocuk bulunmaktadır. Yıllara göre, DEHB tanısında da düzenli bir artış görülmüştür. ABD'de, 2003 yılında, çocukların % 7.8'ine, 2007'de %9.5, 2011 % 11 inde DEHB tanısı konmuştur. Erkeklerde, kızlara nazaran DEHB görülme olasılığı 2-6 kat daha fazladır [25].

DEHB tanısında, yaygın olarak kullanılan birçok yöntem mevcuttur. Klinik görüşmelerde ortaya çıkmayan DEHB semptomlarını belirlemeye yönelik DEHB derecelendirme ölçekleri yapılır. Bu ölçekte, amaç, bireylerin farklı zamanlarda ve mekânlardaki davranış şekilleri tespit edilir. Bireylerin öğrenme engelleri ve IQ seviyesi ise, Zekâ testleri ile tespit edilir [26]. Geniş spektrumlu ölçekler ile bireylerin sosyal, duygusal ve psikiyatrik sorunları ele alınır. Dil gelişimi, kelime kapasitesi, hafıza durumu gibi belirli yeteneklerin tespiti için özel testler yapılır. Dürtüsellik ve dikkatsizlik semptomlarının tespiti için bilgisayar testleri yapılır [27; 28]. Testlerin, bir anda yapılması mümkün olmadığından, farklı zamanlara yayılarak yapılır. Bu süreçte bireyler, hekimlerini rutin ziyaretlere başlar. Pratisyen hekimler, bu testleri yapacak ve değerlendirecek yeterli donanıma sahip değildir. Gelişim öyküsü, aile öyküsü

gibi ifadelerin alınması ve bahsedilen diğer testlerin yapılması ve değerlendirilmesi zaman alır. Ayrıca, farklı zamanlarda tekrarlandığında, farklı sonuçlar verebilen bu testlerin, doğru teşhiste önemli bir engeldir.

Sonuç olarak, DEHB yıllara göre düzenli bir şekilde artan bir bozukluk olup, tedavi edilmediği takdirde bireyleri çeşitli yönlerden olumsuz etkilemektedir. Beynin tedaviye yanıt yeteneği, erken çocukluk döneminde daha yüksektir. Erken teşhis ile daha etkili ve başarılı tedavi mümkündür. Amaç, hekimlere zaman kaybettirmeden, DEHB bozukluğunun teşhisinde yardımcı olabilecek hızlı, nesnel ve güvenilir bir araç geliştirilmesini sağlamaktır. Bu çalışmada, yapısal MR verilerini yorumlayacak, ML ve DL algoritmaları ile özgün DEHB tespit modeli geliştirildi.

1.2. TEZİN AMACI

1.2.1. Genel

Bu çalışmada, NPIstanbul NeuroPsikiyatri Hastanesi ve erişimi herkese açık olan ADHD-200 veri tabanından alınan sMRI verileri ile, insan çabasını en aza indirgeyerek hekimlere, DEHB tanısında, yardımcı olabilecek objektif ve güvenilir bir DEHB algılama modeli geliştirmek hedeflendi.

1.2.2. Özel

- Sağlıklı kontrol ve DEHB vakalarını doğru bir şekilde sınıflandırmak için otomatik bir DEHB algılama yöntemi sunulmuştur.
- Önerilen algılama yaklaşımını eğitmek ve test etmek için NPIstanbul veri kümesi ve erişimi halka açık ADHD-200 veri kümesi kullanılarak dengeli bir sMRI veri kümesi oluşturuldu.
- Yapısal MR kesitlerinin DEHB tespit modelinde katkı seviyesini ölçmek amacıyla, iki farklı veri kümesi oluşturuldu.

- Makine öğrenimi özellikleri, Birinci Mertebe ve İkinci Mertebe (LBP, GLCM, Haralick) İstatiksel Öznitelik Çıkartma yöntemleri kullanılarak manuel öznitelikler çıkarıldı.
- Derin Öğrenme öznitelikleri, çeşitli Evrişimli Sinir Ağı (CNN) mimarileri kullanılarak otomatik olarak çıkarıldı.
- Hem tekli hem de toplu makine öğrenme algoritmaları, son teknoloji ile karşılaştırıldığında üstün sınıflandırma performansı elde etmek için kullanıldı.
- Çevirim içi veri artırım teknikleri uygulanarak, AlexNet, VGGNet, ResNet, SqueezeNet gibi derin öğrenme mimarilerinin oluşturulan farklı veri küme setlerini karakterize etmedeki performansları tespit edildi.

1.3. ARAŞTIRMA YÖNTEMİ

Bu çalışmada amaç, yapısal MR veri setlerine dayalı olarak DEHB tespit modeli geliştirmektir. Bu amaçla, problemin tespitine yönelik Makine Öğrenimi ve Derin Öğrenme yaklaşımlarını içeren bir methodoloji önerildi.

1.3.1. Uygulama Alanını Anlamak

Problemin tespitine yönelik verilerin temini için NPIstanbul NeuroPsikiyatri Hastanesi nöroloji uzmanı Prof. Dr. Barış Metin'den DEHB ve sağlıklı bireylere ilişkin yapısal MR verileri alındı. Ancak, kısıtlı sayıda veri içeren bu veri kümeleri ile sağlam bir model oluşumundan bahsedilemezdi. Bu nedenle, halka açık ADHD-200 veri tabanından da yapısal MR verileri alınarak veri sayısı artırıldı. Öncelikli amaç, sağlam ve güvenilir bir DEHB tespit modeli için yeterli sayıda veri edinimi sağlamaktır. Amaç, doğru ve erken DEHB tespit modeli geliştirerek sağlıkta bu alanda yaşanan yanlış teşhis sıkıntısının bir nebze de olsa önüne geçmektir.

1.3.1.1. Veri Kümesi Seçme ve Oluşturma

Çalışmamızda NPIstanbul NöroPsikiyatri Hastanesi ve ADHD-200 veri setinden elde edilen sMRI verilerini kullanıyoruz. $11 + 157 = 168$ toplam sağlıklı birey ve $178 + 9 = 187$ toplam DEHB'li birey sayısı ile dengeli bir veri seti oluşturulmuştur. Halka açık ve kolay erişilebilir ADHD-200 veri seti, 7 farklı merkezden sMRI ve fMRI görüntülerini içerir. ADHD-200 ve NPIstanbul Hastanesi'nden alınan sMRI görüntüleri birleştirilerek DEHB tespit modeli için bir veri seti oluşturuldu.

1.3.1.2. Veri Temizleme ve Ön İşleme

Veri kümesinde, yinelenen ve alakasız gözlemler, yapısal hatalar, istenmeyen aykırı değerler ve eksik veriler bulunabilir. Veri temizleme ile buna benzer yanlış biçimlendirilen verilerin düzeltilmesi sağlanır. İlgisiz, gereksiz veriler veya gürültüler var ise eğitim aşamasında, böyle verilerin kullanılması, performansın düşmesine sebep olur. Veri ön işleme sonuçların yorumlama şeklinde önemli değişikliklere sebep olacağından, veri kümesinde belirtilen eksiklikler olması halinde, gerekli temizleme yapılır. Sayısal görüntülerin edinimi sırasında gürültüler oluşur [29]. Bu gürültülerin giderilmesi için, medyan, ortalama, minimum, maksimum ve wiener gibi filtreler kullanılabilir. Bu çalışmada, medyan filtre ile görüntü iyileştirimi sağlanmıştır.

1.3.1.3. Öznitelik Çıkartma

Öznitelik Çıkartma, ham veri kümesi işleyerek, verinin daha yönetilebilir olmasını sağlayan bir boyut azaltma sürecidir. Yapısal MR imgelerini karakterize edecek uygun özniteliklerin bulunması amacıyla temelde iki farklı öznitelik yöntemi seçilmiştir: i) el ile öznitelikler ve ii) otomatik öznitelikler. El ile öznitelikler yönteminde, kullanıcı tarafından belirlenen yöntemlere göre veriden özniteliklerin çıkarılması sağlanırken, otomatik öznitelikler yönteminde ise, seçilen yönteme göre verileri karakterize edecek özniteliklerin tespiti, yöntem tarafından otomatik yapılır.

1.3.1.4. Öznitelik Seçme

Problem çözme için çıkartılan öznitelikler arasından daha uygun öznitelikler seçimi yapılır. Gereksiz öznitelikler çıkarılarak, mümkün olduğunca ilgili verileri koruyarak, minimum sayıda öznitelikler kümesi seçilir. Böylece, hesaplama maliyeti azalır, modelin yorumlanması kolaylaşır ve performans artar. Bu çalışmada, temel bileşenler analizi öznitelik seçme algoritması uygulanmıştır [30].

1.3.1.5. Uygun Sınıflandırma Algoritmanın Tespiti

Bu bölümde amacımız ne tür bir sınıflandırma algoritması ile DEHB tanı modeli oluşturacağını belirlemektir. Çalışmamızın amacına yönelik modeller oluşturmak, ve modellerin birbirileri ile karşılaştırmak amacıyla temelde iki farklı sınıflandırma algoritması oluşturulmuştur: *i)* tekil sınıflandırma algoritması ve *ii)* toplu sınıflandırma algoritması. Bu türden sınıflandırma ML algoritmalarıyla DEHB teşhisine yönelik oluşturulan methodolojide kullanıldı. DL algoritmaları ile oluşturulan methodolojide ise, AlexNet, VGGNet, SqueezeNet ve ResNet gibi mimariler kullanılarak, otomatik sınıflandırma yapıldı.

1.3.1.6. Sınıflandırma Algoritmalarının Uygulanması

DEHB-sağlıklı sınıflandırma deneyleri, 355 örnek içeren bir veri kümesi üzerinde gerçekleştirildi. Yapısal MR kesitlerinin DEHB tanı modelindeki etkisini tespit etmek amacıyla iki farklı veri kümesi oluşturuldu: *i)* Yapısal MR imgelerinin bütün kesitleri bir veri kümesine atandı ve *ii)* önerdiğimiz algoritma ile belirlenen gri ve beyaz maddeler diğer bir veri kümesine atandı. Tüm deneyler, biri bütün dilimleri içeren ve diğeri belirli dilimleri içeren iki veri kümesi üzerinde gerçekleştirilerek farklı senaryolar tasarlandı. ML ve DL sınıflandırma algoritmaları kullanıldı. Eğitim ve test verilerinin rastgele örneklenmesi K Kat Çapraz Doğrulama ile gerçekleştirildi.

1.3.1.7. Değerlendirme

Bu adımda, çeşitli metriklerden yararlanılarak, DEHB tespit modellerinin performansları değerlendirildi: doğruluk, duyarlılık, özgüllük, kesinlik, f-ölçütü gibi değerler her modelin karmaşıklık matrisi üzerinde hesaplandı.

1.3.2. Araçlar

Temel olarak, DEHB tespitinde, modeller oluşturmak için iki farklı teknik kullanıldı: i) Manuel özellik çıkarma ve klasik Makine Öğrenimi (ML), algoritmalar kullanma ii) Derin Öğrenme (DL) yaklaşımını kullanarak otomatik özellik çıkarma. ML ve DL algoritmalarını içeren Matlab, DEHB tespit modeli için kullanıldı.

1.4. TEZİN KATKILARI

Çalışma, DEHB tespit yöntemi için sunulan özgün yöntem ve elde edilen yüksek sınıflandırma performansı yönüyle diğer çalışmalardan ayrılmaktadır. Yöntemi diğer çalışmalardan farklı kılan yönleri ise şöyledir;

- Yapısal MR kesitlerinin DEHB modelinde etkilerinin incelenmesi
- Gri ve beyaz maddenin tam ve net görüldüğü kesitlerin seçilmesinde, kendi geliştirdiğimiz algoritmanın uygulanması
- ML ve DL algoritmalarına girdi olarak verilen iki farklı veri kümesinin DEHB tespit modeline etkilerinin incelenmesi
- Veri kümelerinin karakterize edilmesi için kullanılan İstatiksel Doku öznitelikleri yöntemleri ile elde edilen farklı öznitelik kümelerinin DEHB sınıflandırma modeline etkilerinin incelenmesi
- Tekil ve Topluluk sınıflandırma algoritmalarının DEHB sınıflandırma modeline etkilerinin incelenmesi

- Çevirim içi veri artırım teknikleri ile veri artırımı sağlanarak, DL mimarilerinin ile sınıflandırma performanslarının incelenmesi
- Kendi geliştirdiğimiz CNN ağının yapısal MR verilerini karakterize etmedeki rolü

Sonuç olarak, DEHB tespit modeli için takip edilen adımlar ve gri ve beyaz maddenin tam ve net görüldüğü dilimlerin, geliştirdiğimiz algoritma ile tespiti, tasarladığımız CNN ağının veri kümelerini karakterize etmedeki başarıları bu çalışmanın özgün yanlarını açıkça göstererek, literatüre önemli katkılar sağlamaktadır.



2. GENEL KISIMLAR

2.1. LİTERATÜR ÖZETİ

Bu çalışmada, DEHB'li bireylerinin beyin bölgeleri ile bu bölgeler arasındaki ilişkileri analiz etmek için bir model oluşturuldu. Grafik tabanlı temel bileşenler yöntemi 118 ADHD ve 98 normal fMRI görüntüsüne uygulanarak öznitelikler çıkarılmıştır. DEHB tespit modeli için destek vektör makinesi kullanıldı. Modelin performans oranı % 94.91 dır.

Ani Eloyan ve arkadaşları (2012), DEHB tespitine yönelik bir model geliştirmek amacıyla, erişimi herkese açık olan ADHD-200 veri kümesinden 776 deneğe (491 DEHB, 285 Sağlıklı) ait sMRI ve fMRI görüntülerini kullandılar. Özniteliklerin tespiti için tekil değer ayrıştırıcılar, rastgele orman, gradyan artırma, torbalama, voksel tabanlı morfometri yöntemleri kullanılmıştır. DEHB sınıflandırma modeli için Destek Vektör Makinelerinden yararlanılmıştır. Modelin hassasiyeti % 21.0, ve özgüllüğü % 94.0 dır. DEHB'li ve sağlıklı bireylerden alınan örnek sayıları arasındaki fazla fark, dengesiz veri kümesinin oluşumuna neden olmuştur. Bu durum, modelin hassasiyetinin düşmesine neden olmuştur [31].

Dai ve arkadaşları (2012), DEHB-200 veritabanından alınan rs-fMRI ve sMRI verilerini kullanarak DEHB tahmin modeli geliştirdiler. Veri kümesinden 776 (DEHB 485, 281 Sağlıklı) beyin görüntüsü alınmıştır. DEHB sınıflandırma modeli, SVM ve MKL yöntemleri ile oluşturuldu. Çalışmada, multimodal özelliği entegre eden MKL'nin yüksek performans verdiği gözlemlenmiştir. Ancak, dengesiz bir veri kümesi ile oluşturulan modelden elde edilen yüksek performans, modelin güvenilirliği gölgelemiştir [32].

Xiaolong ve arkadaşları (2013) yapısal MR kullanarak, DEHB tespitine yönelik makine öğrenme algoritma temelli bir sınıflandırma modeli geliştirdiler. Bu çalışmada, 110 denekten (55 Sağlıklı, 55 DEHB) alınan sMRI verileri kullanılmıştır. Beyin ölçümleri, Freesurfer yazılım paketi kullanılarak gerçekleştirildi. Optimum özniteliklerin belirlenmesi, Ardışık

ileri yönde seçim (Sequential Forward Selection- SFS) ve F-puanı (F-score) yöntemleri ile sağlanmıştır. Destek Vektör Makineleri (Support Vector Machine - SVM) ve Aşırı Öğrenme Makineleri (Extreme Machine Learning - ELM) ile elde edilen modeller, çapraz geçerleme yöntemi ile değerlendirildi. ELM, SVM, SVM-RBF için doğrulama değerleri sırasıyla, % 90.18, % 84.73 ve % 86.55 dir. Çalışma, DEHB ve sağlıklı bireyler arasındaki farklılığın frontal lob, temporal lob, oksitipal lob ve insülerde olduğunu göstermesi açısından önemlidir [33].

Matthew Brown ve arkadaşları (2012), DEHB-200 veri kümesinden alınan bireylere ait demografik bilgilerinin yanında rs-fMRI verilerini kullanarak DEHB sınıflandırma modeli geliştirdiler. Sağlıklı ve DEHB'li bireylerden 973 örnek alınmıştır. Bu çalışmada DEHB altipleri de bir sınıf olarak kaydedilmiştir. Bu sınıflar; DEHB kombine (DEHB-C), DEHB dikkatsiz (DEHB-I) tipi ve sağlıklıdır. Sınıflandırma doğruluk oranı % 62.5 dir [34].

Rubi Hammera ve arkadaşları (2012), DEHB sınıflandırma modelinde, 40 erkek bireyden (20 DEHB, 20 sağlıklı) alınan fMRI verileri kullanılmıştır. Gereksiz nörobiyolojik belirteçlerinin tespiti için PCA uygulanmıştır. Lojistik Regresyon yöntemi ile DEHB sınıflandırma modeli oluşturuldu. Modelin doğruluk oranı % 92.5 dir. Denek sayısının oldukça düşük olması, elde edilen yüksek performansı gölgede bırakarak, modelin güvenilirliği üzerinde negatif bir etki yaratmıştır [35].

Chang ve arkadaşları (2012), 436 (216 sağlıklı, 210 DEHB) denegin yapısal MRI verileri ile DEHB tespit modeli geliştirdiler. Yapısal MRI görüntülerinin karakteristik özneliklerinin belirlenmesi için, LBP-TOP izotropik yerel ikili desenler yöntemi kullanıldı. SVM ile DEHB tahmin modeli oluşturuldu. Modelin doğruluk oranı % 69 dır. Tek sınıflandırma ve tek öznelik çıkartma tekniği ve elde edilen düşük performans, modelin güvenilirliği üzerinde olumsuz bir etki yaratmıştır[36].

Bhaskar ve arkadaşları (2018), ADHD-200 ve ABIDE veri tabanından alınan sMRI ve fMRI görüntülerinden doku bazlı öznelikler çıkarılarak, DEHB ve otizmin tespitine yönelik bir model oluşturdular. LEFMSF öğrencisi ile, sMRI ve FMRI verilerinden alınan doku

bazlı öznitelikler çıkarıldı. SVM algoritması ile model oluşturuldu. Modelin ADHD-200 veri setindeki başarımları oranı 0.673 iken, ABIDE veri setindeki başarımları oranı ise 0.643 dır. Başarımları oranları, her iki veri kümesinde oldukça düşüktür [37].

Bu çalışmada (2012), 446 deneye ait sMRI ve fMRI görüntüleri, ADHD-200 veri tabanından alındı. Lokal ve Global Morfolojik öznitelikler, LBP-TOP yöntemi ile çıkarıldı. SVM ile DEHB tespit modeli oluşturuldu. Modelin başarımları oranı 0.69 dır. [36].

DEHB ile sağlıklı bireyler arasındaki fizyolojik beyin farklılıklarını araştırmak için çeşitli çalışmalar yapılmıştır [38], [39]. Bu çalışmalardan bazıları giriş verisi olarak EEG ve MEG kaydını kullanır. Ancak, bu kayıtlar oldukça dış gürültüye maruz kaldıklarından güvenilir değildir [40], [41].

Moghaddari ve arkadaşları (2020), 31 DEHB, ve 30 sağlıklı çocuktan aldıkları EEG sinyalleri üzerine bir DEHB tespit modeli geliştirdiler. Derin öğrenme modeli ile geliştirilen bu sınıflandırma için, öncelikle, veriler gürültülerden temizlendi. Verilerden teta, beta, alfa ve gama frekans bantlarını çıkarılarak üç kanallı bir RBG görüntüsü oluşturuldu. Oluşturulan yeni veri 13 katmanlı bir evrişimli sinir ağına verilerek eğitildi. Önerilen modelin eğitim ve test verileri 5 kat çapraz doğrulama ile değerlendirildi ve ortalama doğruluk oranı % 98.48 dir [42].

Hüseyin ve arkadaşları (2017), DEHB'nin nöroelektrik anlayışına ve klinik tanısına katkıda bulunmak amacıyla, yeni bir sınıflandırma yaklaşımı sundu. Özyinelemeli öznitelik seçimi, ayırt edici özelliklerin tespitinde kullanılarak, gerekli öznitelikleri içeren küme belirlendi. Bu küme, SVM'ye girdi verilerek, modeller oluşturuldu. Delta bandının, DEHB sınıflandırmasında, olumlu katkısından dolayı, önemli bir çalışmadır [43].

Zhu ve arkadaşları (2017), DEHB tespiti için yapısal MRI verileri ile bir model oluşturdu. Gauss yöntemi ile önileme adımında istenmeyen bölgeler çıkarılarak gürültü giderildi. Sağ kaudat çekirdek, sol prekuneus ve sol üst frontal girus, segmentasyon yöntemi ile çıkarıldı. DEHB sınıflandırılma modeli, 3-D evrişimli sinir ağı ile oluşturulmuştur. Modelin

performansı % 62.52 dir [44].

Yuyang ve arkadaşları (2017), yapısal MR biyobelirteçlerini ve makine öğrenimi sınıflandırıcılarını kullanarak objektif bir DEHB algılama aracı geliştirdi. Bu multimodal nörogörüntülemeler, birkaç tek sınıflandırıcıyı tek bir modelde birleştiren toplu sınıflandırma algoritması ile kullanıldı. Sınıflandırmada kullanılan özellikler arasında bölgesel kortikal gri cevher kalınlığı ve yüzey alanı, subkortikal yapıların GM hacmi, beyaz cevher lif yollarının hacmi ve fraksiyonel anizotropisi, iki taraflı bölgesel bağlanabilirlik bulunmaktadır. Objektif biyobelirteçler kullanılarak oluşturulan modelin doğruluk oranı % 90.0 dır. Sağ inferior frontal girus, sağ orta frontal inferior parietal fonksiyonel bileşke ve sağdaki düğümde yer alan düğümün aktivitelerinin DEHB ile sağlıklı bireyleri ayırt etmede önemli bir parametredir [45].

Ghamzadeh ve arkadaşları (2019), DEHB sınıflandırma modeli için, fMRI verileri ile çok yönlü bir yöntem sunmaktadır. Bulanık entropi ve alt matris yöntemi ile zaman-frekans alanları belirlenmiştir. Kolmogorav-Smimov testi ile ayırt edici öznelilikler tespit edilmiştir. Çapraz doğrulama yöntemi ile modelin performansı değerlendirilmiştir. Bu çalışmada, fMRI verilerinin yanı sıra yaş ve cinsiyet gibi fenotip bilgilerinde kullanılmıştır. Modelin doğruluk oranı % 100.0 dır [46].

Yanli ve arkadaşları (2019), Makine öğrenimi sınıflandırıcıları ile ENİGMA-DEHB veri setinden alınan yapısal MRI görüntüleri ile DEHB sınıflandırma modeli geliştirdiler. Modelin doğruluk oranı % 66.00 dır. Araştırmada, DEHB ile sağlıklı bireyler arasında kafa içi hacim, beynin yüzey alanı ve alt kortikal hacimlerinin farklılık gösterdiğini tespit edilmiştir [47].

Huang ve arkadaşları (2019), uzaysal-zamansal derin öğrenme modellerinde dinlenme durumlu fMRI verilerini kullanarak DEHB tespit modeli geliştirdiler. Bu çalışmada, entropideki türev değişikliklerine dayalı olarak geliştirilen 4-D CNN adlı derin öğrenme yöntemi oluşturuldu. Çalışmada, zamansal ve mekansal tanecikli hesaplama ve füzyon modelleri önerilmiştir. Yöntemi eğitmek ve doğrulamak için ADHD-200 veri kümesi

kullanıldı. Modelin doğruluk oranı % 71.3 dır [48].

Wang ve arkadaşları (2019), 3B fraktal boyut karmaşıklık haritasını kullanarak DEHB sınıflandırma modeli önerdiler. ADHD-200 veri kümesinden alınan yapısal MR verilerinin gri madde yoğunluklarının Hausdorff fraktal boyutları hesaplandı. Üç boyutlu evrişimli sinir ağı modeli ile özniteliklerin çıkarımı ve sınıflandırılması sağlandı. Modelin başarı oranı % 69.0 dır [49].

Sahar ve arkadaşları (2019), non-invaziv görüntülemeye dayalı objektif bir DEHB tanı aracı geliştirdi. ADHD-200 veri setinden alınan sMRI ve fMRI verileri ile çok modlu bir 3D CNN modeli geliştirildi. Tıbbi görüntülerin karakterize edilmesinde, erken ve geç füzyon şemaları kullanıldı ve modeller K En Yakın Komşu, Doğrusal Diskriminant Algoritmaları ile oluşturuldu. Modelin doğruluk oranı % 74.93 dır [50].

Wanga ve arkadaşları (2019), bölgeler arası morfolojik bağlantı modeli DEHB sınıflandırma modeli geliştirdiler. Model, bölgeler arası morfolojik özelliklere sahip bir hibrit makine yöntemi kullanılarak oluşturuldu. Çapraz doğrulama yöntemi ile modelin değerlendirilmesi sağlanmıştır. Modelin doğruluk, duyarlılık ve özgüllük oranları sırasıyla % 74.65, % 75.0 ve % 74.29 dır [51].

Asad ve arkadaşları (2020), DEHB sınıflandırma modeli için, fMRI görüntülerini uçtan uca derin öğrenme mimarilerinde kullandılar. Derin fMRI (Deep fMRI) yöntemi, ADHD-200 veri setinden alınan zaman serisi sinyallerini girdi olarak alır, bir sınıflandırma yapar ve geri yayılımı kullanarak uçtan uca eğitir. Modelin özgüllük ve duyarlılık oranları sırasıyla % 91.6 ve % 65.5 dir. Araştırma sonuçları, DEHB ve sağlıklı birey arasında en belirgin farklılığın frontal lobda olduğu tespit etmiştir [52].

Faraone ve arkadaşları (2019), klinik ve biyolojik verileri, ML algoritmaları ile kullanılarak bir DEHB sınıflandırma modeli geliştirdiler. Model oluşumunda, isveç tıbbi kayıtlarından alınan 34.009 veri kullanılmıştır. Rastgele orman ile oluşturulan modelin doğruluk oranı % 74 tür. Çalışma, klinik bulguların yanı sıra çevresel maruziyetler ve aile öyküsü gibi

bileşenlerinde DEHB modelinde olumlu bir katkı sağlayacağını göstermektedir [53].

Luo ve arkadaşları (2019), DEHB tespit modelinde, yapısal MR verileri ile en iyi biyobelirteçlerin tespiti için ML algoritmaları kullandılar. Varyansı azaltarak, sınıflandırma sonuçlarını iyileştirmek amacıyla, toplu öğrenme algoritmaları uygulandı. Yapısal MR karakterize edecek özellikler gri cevher kalınlığı, yüzey alan, subkortikal yapıların gri hacmi, beyaz madde lif yollarının fraksiyonel anizotropisi, çift bölgesel bağlanabilirlik ve küresel topolojik özelliklerdir. Modelin doğruluk oranı % 89 dır [54].

Zhang ve arkadaşları (2019), DEHB tanımlama problemi için derin öğrenme teknikleri kullanıldı. Cifar10 veri seti kullanılarak bir VGG-16 modeli önceden eğitildi. Eğitilen ağın bazı katmanları, DEHB bireyleri tanımlamak için CNN modeline aktarıldı. VGG-16 mimarisi ile oluşturulan DEHB sınıflandırma modeli % 94.39 dur [55].

Meedinyatya ve arkadaşları (2021), fMRI verilerinden çıkartılan tohum bazlı korelasyon (SBC), düşük frekanslı dalgalanmanın fraksiyonel genliği (fALFF) ve bölgesel homojenlik (ReHO) gibi çıkartılan özellikler CNN mimarisiyle birleştirilerek, DEHB tespitine yönelik bir metodoloji geliştirdiler. FaLFF ve ReHo kullanan metodoloji, % 67 doğrulukla, SBC ile % 84 ve % 96 doğrulukla sonuçlanmıştır [56].

Sampath ve arkadaşları (2021), DEHB tanımlama süreci için bir karar destek sistemi geliştirmişlerdir. Önerilen sistem, hem fMRI hem de göz hareketi verilerini kullanır. Sistem, ön işleme, özellik çıkartma ve özellik seçme ve sınıflandırma aşamalarından oluşmaktadır. Göz hareketleri kullanılarak yapılan sınıflandırma için, % 81 doğrulukla, fMRI verileri için yapılan sınıflandırma da ise % 82 doğrulukla sonuçlanmıştır [57].

Khullar ve arkadaşları (2021), rs-fMRI verilerine derin öğrenme yöntemleri uygulayarak DEHB tespit modeli geliştirdiler. Bu amaçla, iki boyutlu evrişimli sinir ağı algoritması ile hibrit evrişimli sinir ağı uzun-kısa süreli bellek yöntemi kullanılmıştır. Modelin değerlendirilmesi için doğruluk, özgüllük, duyarlılık, f-ölçütü ve ROC eğrisi değerleri hesaplanmıştır. Hibrit evrişimli sinir ağı ile oluşturan modelin doğruluk oranı 98.50 % dir


[58].

Mehdi ve arkadaşları (2021), EEG sinyallerinin dalgacık temelli özniteliklerini kullanarak DEHB sınıflandırılması üzerinde çalışma gerçekleştirdiler. 7-12 yaş aralığında, 61 DEHB'li ve 60 sağlıklı gruptan EEG sinyalleri alındı. Dalgacık yöntemi ile EEG sinyalleri alt bantlara ayrıştırıldı. Her bir alt banttın, zamansal ve istatistiksel öznitelikler hesaplandı. Gereksiz özniteliklerin tespiti için PCA yöntemi kullanıldı. SVM ve KNN yöntemi elde edilen sınıflandırma doğrulukları sırasıyla, % 98.33 ve % 99.17 dir [59].



3. MALZEME VE YÖNTEM

Bu çalışmada, yapısal MR verileri kullanılarak Makine Öğrenme ve Derin Öğrenme yöntemleri ile objektif ve güvenilir bir DEHB tespit modeli geliştirmek amaçlandı. Bu amaçla, çalışmada, DEHB sınıflandırılması için iki farklı methodoloji (**Şekil 3.1:**) sunuldu. İlki, ML ve DL algoritmalarının birlikte kullanıldığı bir yöntemeye dayanırken, diğeri sadece DL algoritmalarına dayanan bir yöntemeye dayanmaktadır. **İlk yöntemde**, önerilen model, dört temel aşamadan oluşmaktadır: veri setlerinin oluşturulması, öznitelik çıkartma, öznitelik seçimi ve sınıflandırmadır. Bu yöntemde, yapısal MR kesitlerinin DEHB sınıflandırma modeline etkisini tespit amacıyla, iki farklı veri kümesi oluşturuldu. Veri kümelerinin oluşumunda iki durum dikkate alındı: i) tüm denekler için, yapısal MR verilerinin tüm kesitleri bir veri kümesine atanır. ii) yapısal MR verilerinin gri ve beyaz maddelerin tamamen net görüldüğü dilimler önerilen bir algoritma ile tespit edilerek diğeri veri kümesine atanır. Her iki veri kümesinin karakterize edecek özniteliklerin tespiti için manuel ve otomatik özniteliklerden yararlanıldı. Birinci ve İkinci Mertebe istatistiksel öznitelikler (LBP, Haralick, GLCM) kullanılarak el ile öznitelikler kümeleri oluşturuldu. AlexNet, VGGNet, ResNet, SqueezeNet ve Inception-ResNet mimarileri de kullanılarak otomatik öznitelikler kümeleri oluşturuldu. Hem ML hem de DL yöntemleri ile elde edilen öznitelikler kümelerinde gereksiz özniteliklerin tespiti için PCA yöntemi uygulandı. DL algoritmasının başarısı, veri miktarı ile doğru orantılıdır. DL mimarilerinde performansı artırmak için transfer öğrenimi (transfer learning) yöntemi kullanılmıştır. DEHB sınıflandırma modelleri, tekil ve çoğul sınıflandırma algoritmaları kullanılarak oluşturulmuştur. **İkinci yöntemde**, önerilen model, üç aşamadan oluşmaktadır: veri kümesinin oluşumu, öznitelik çıkartma, sınıflandırmadır. Bu methodolojide de, veri kümelerinin oluşumunda iki durum dikkate alındı: i) tüm denekler için, yapısal MR verilerinin tüm kesitleri bir veri kümesine atanır. ii) yapısal MR verilerinin gri ve beyaz maddelerin tamamen net görüldüğü dilimler önerilen bir algoritma ile tespit edilerek diğeri veri kümesine atanır. Öznitelik çıkartma ve sınıflandırma



Şekil 3.1: DEHB Tespit Metodoloji

ise, kullanılan CNN mimarisine göre otomatik olarak yapılmıştır. DL mimarilerinde, başarı, veri miktarıyla doğru orantılıdır. Doğru ve sağlam bir DEHB modeli için veri artırım teknikleri uygulanmıştır. AlexNet, VGGNet (16, 19), ResNet (18, 50, 101), SqueezeNet mimarileri ile bir DEHB sınıflandırma modeli oluşturulmuştur. Buna ek olarak, DL mimarilerinin performans sonuçlarını dikkate alarak, kendi CNN ağımızın tasarlanması sağlandı.

3.1. VERİ KÜMESİ

Bu çalışmada, NPIstanbul NöroPsikiyatrik Hastanesi ve herkes tarafından erişime açık olan ADHD-200 veri kümesinden alınan yapısal MR verileri kullanılmıştır. NPIstanbul NöroPsikiyatri hastanesinden 9 ADHD'li, 11 sağlıklı bireyin yapısal MR verileri ile, ADHD-200 veri kümesinden 157 sağlıklı ve 178 DEHB'li bireyin MR verileri kullanılmıştır. Çalışmada kullanılan toplam sağlıklı birey sayısı 168, DEHB 'li birey sayısı ise 187 dir. Veri kümeleri hakkında ayrıntılı bilgi **Tablo 3.1:**'de gösterilmektedir. NPIstanbul Nöropsikiyatri Hastanesi'nden elde edilen sMRI verileri, Üsküdar Üniversitesi Nöropsikiyatri Sağlık Uygulama ve Araştırma Merkezi'ndeki gönüllü hastalar ve yaş eşleştirilmiş sağlıklı kontrollerden toplandı. Nöropsikiyatrist hekim tarafından tüm gönüllüler muayene süreçleri

Tablo 3.1: NPIstanbul ve ADHD200 Verikümesi


	NPIstanbul Verikümesi	ADHD-200 Kümesi
Sağlıklı	11	157
DEHB	9	178
Toplam	20	335

hakkında bilgilendirildi. Bilgilendirici yazılı onay formu tüm katılımcılar tarafından imzalanmıştır. İnsan denekleri içeren tıbbi araştırmalar için etik ilkelerin Helsinki Bildirgesi mutlak surette takip edildi ve araştırma protokolü Üsküdar Üniversitesi Klinik Araştırmalar Etik Kurulu tarafından onaylandı. ADHD-200 veri kümesi, sekiz bağımsız beyin görüntüleme tarama sitesinden dinlenme durumunda fMRI, yapısal MRI ve fenotip bilgilerini içermektedir. Her yapısal MR görüntüleri kesitlerden oluşmaktadır. Yapısal MR verilerini oluşturan bütün dilimler bir veri kümesine, MR verilerindeki gri ve beyaz maddenin tam ve net görüldüğü dilimler ise başka bir veri kümesine atanarak, iki farklı veri kümesi oluşturulmuştur. Bunun temel sebebi, farklı dilimleri içeren verilerin DEHB tespit modeline etkilerini tespit etmektir. **Şekil 3.2:** yapısal MR verisinin tüm dilimleri ile önerilen algoritma yardımıyla secilen dilimlerini göstermektedir. DEHB sınıflandırma modeli için önerdiğimiz, iki farklı veri kümesi, DEHB tespiti için sunulan iki metodoloji de kullanıldı. Yapısal MR kesitlerinin seçimi için aşağıdaki adımlar sırasıyla gerçekleştirildi. Belirli dilimleri içeren 1. veri kümesinin oluşturulmasında aşağıdaki adımlar takip edilmiştir.

- Üç boyutlu yapısal MR görüntüleri, iki boyutlu MR görüntülere dönüştürülerek imgenin kesitleri elde edilir.
- Kesitlerdeki gürültünün giderilmesi amacıyla medyan filtre uygulanır.
- Her kesit ikili görüntüye (binary image) çevrilir.
- Her kesitteki en büyük bileşeni bulmak amacıyla, bağlantılı bileşenler analizi (connected component analysis) uygulanır.

- Her kesitteki tüm bileşenlerin alanı hesaplanır ve en büyük alana sahip bileşeni içeren $I_m(i, j)$ kesiti seçilir.
- En büyük bileşeni takip eden $I_m(i, j)$ takiben belirli sayıda kesit seçilir.

Birinci veri kümesi, önerdiğimiz algoritma ile her deneğe ait sınırlı sayıda kesiti içerirken, ikinci veri kümesi, yapısal MR verisine ait bütün kesitleri içermektedir. Her iki veri kümesinin DEHB tanı modelindeki etkisini tespit etmek amacıyla, **ilk yontemde** aşağıdaki işlemler sırasıyla yapılır.



Şekil 3.2: Bütün Kesitler ve Secili Kesitler

- İki farklı veri kümesinin karakterize edilmesi için, manuel öznitelikler olarak birinci

ve ikinci dereceden istatistiksel öznitelik çıkartma yöntemi ve otomatik öznitelikler olarak AlexNet, VGGNet, ResNet, SqueezeNet, Inception-ResNet DL mimarileri kullanılarak veri kümelerini karakterize edecek farklı öznitelikler kümeleri oluşturulur.

- Temel bileşenler analizi uygulanarak, veri kümelerinin ilgisiz öznitelikler kaldırılır ve boyut indirgeme yapılır.
- Eğitim ve test verilerinin rastgele örneklenmesi, 10 Kat Çapraz Doğrulama ile gerçekleştirilir.
- Karar Ağacı, K En Yakın Komşu, Destek Vektör Makineleri gibi tekil sınıflandırma algoritmaları ile Torbalama, Yükseltme gibi algoritmaları ile topluluk sınıflandırma yöntemleri uygulanarak DEHB sınıflandırma modelleri oluşturulur.
- Her modelin performans değerlendirilmesi için doğruluk, duyarlılık, özgüllük, kesinlik ve f-ölçütü gibi değerler hesaplanır.


İkinci yöntemde, DL mimarilerinin, DEHB tanı modelindeki etkilerini tespit etmek amacıyla, önerdiğimiz veri kümelerini karakterize etmedeki başarısı tespit etmek amaçlanmıştır. Bu amaçla, bu yöntemde, aşağıdaki adımlar sırasıyla gerçekleştirildi.

- Geometrik veri artırım teknikleri uygulanarak sentetik verilerin üretimi sağlandı.
- AlexNet, VGGNet (16,19), ResNet (18,50,101), SqueezeNet mimarileri kullanılarak otomatik öznitelikler çıkarıldı ve sınıflandırıldı.
- Eğitim ve test verilerinin rastgele örneklenmesi için, 5 Kat Çapraz Doğrulama gerçekleştirildi.
- Modellerin performans ölçümü için, mini-parti doğruluğu (mini-batch accuracy), validasyon doğruluğu (validation accuracy), mini-parti kaybı (mini-batch loss), validasyon kaybı (validation loss) değerleri hesaplandı.

- DEHB tespitinde daha hızlı, etkin, güvenilir bir CNN modeli için özgün bir CNN ağı tasarlandı. Daha az katmanlı, eğitim süreci çok daha kısa, yüksek sınıflandırma performansına sahip bir CNN ağı geliştirildi.

3.2. VERİ ÖN İŞLEME

Veri ön işleme, verilerin algoritma ile kolayca yorumlanabilmesi için gürültünün ortadan kaldırıldığı adımdır. Gürültüyü gidermek için minimum, medyan, maksimum, gauss gibi filtreler kullanılarak sonuçlar iyileştirilir. Bu çalışmada, medyan filtre kullanılarak görüntüde iyileştirme sağlanmıştır. Medyan filtre, doğrusal olmayan bir filtre türüdür ve gürültüyü azaltmak için kullanılır. Bu filtre, kenarları koruyarak gürültüyü ortadan kaldırır. Medyan filtre, belirli bir alandaki tüm piksel değerlerini sıralar ve sıralamada ortada bulunan değeri, çıktıya aktarır. **Şekil 3.3:**, medyan filtre gösterimine bir örnektir.



Şekil 3.3: Medyan Filtre

3.3. VERİ ARTIRIMI

Evrişimli sinir ağlarında, sağlam modellerin oluşması, mümkün olduğunca fazla sayıda örnek içeren, veri kümeleri ile mümkündür. Az sayıda örnekleri içeren veri kümeleri ile oluşturulacak modellerde aşırı uyum problemi ile karşı karşıya kalınmaktadır. Veri artırımı, aşırı uyum probleminin azaltılmasına yardımcı olarak, sınıflandırma sağlamlılığını ve performansını artırmak için kilit bir faktör olarak kabul edilir. Ancak, her veri ile ilgili yeterli sayıda gerçek örnekler bulunmayabilir. Bu durumda, sentetik veriler oluşturularak veriler artırılır. Bu durumda, her verinin sınıf bilgisi korunarak, mevcut veri seti değiştirilerek

veriler artırılır. İki tür veri artırımı söz konusudur: i) çevirim içi veri artırımı ii) çevirim dışı veri artırımı. Yeterli depolama imkanı olmama durumunda çevirim içi veri artırımı, aksi durumda çevirim dışı veri artırımı tercih edilir. Çevirim dışı veri artırımında ise, eğitim öncesinde veri artırılmakta ve eğitim sonrasında mevcut artırılan veri korunmaktadır. Çevirim içi veri artırımında, eğitim esnasında veri artırılmakta ve daha sonra artırılan verinin mevcut olmadığı durum söz konusudur. Yeterli depolama alanı olması durumunda, çevirim dışı artırım yapılabilir. Bu çalışmada, çevirim içi veri artırım tekniği kullanılmıştır. Çalışmamızda, CNN ağları kullanılarak geometrik veri artırımının DEHB sınıflandırma modeline etkisi de araştırılmıştır. Bu amaçla, veriler, döndürme, ölçekleme, öteleme gibi geometrik veri artırım teknikleri ile kullanılarak çevirim içi yöntemle veri artırılmıştır.

Öteleme (Translation), bir noktanın belirli bir yonde hareketini sağlayan bir dönüşümdür. Bir noktanın (x,y) x ekseninde a kadar, y ekseninde b kadar kaydırılmak istenirse, Denklem 3.1 uygulanır.

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} 1 & 0 & a \\ 0 & 1 & b \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (3.1)$$

Ölçekleme (Scaling), bir noktayı, tüm yönlerde aynı olan ölçek faktörü ile büyüten geometrik dönüşümdür. Ölçekleme için, Denklem 3.2 uygulanır.

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} a & 0 & 0 \\ 0 & b & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (3.2)$$

Döndürme (Rotation), noktanın veya cismin, merkeze bağlı olarak dairesel hareketini

sağlar. Dönme için, Denklem 3.3 uygulanır.

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} \cos a & -\sin a & 0 \\ \sin a & \cos a & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (3.3)$$

Yansıma (Reflection), bir nesnenin ayna görüntüsünü sağlayan geometrik dönüşümdür

Yansıma için, Denklem 3.4. uygulanır.

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} 1 & a & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (3.4)$$

Kesme (Shearing), bir nesnenin x koordinat veya y koordinat değerini eğimli bir dönüşüme dönüştürür. Kesme için, Denklem 3.5 uygulanır.

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (3.5)$$

Eğer bir nokta x ekseninde kaydırılmak (3.1), ölçeklemek (3.2), döndürülmek (3.3) istenirse, değer a yerine, y ekseninde bu işlemler yapılmak istenirse de, değer b yerine yazılır.

3.4. ÖZİNİTELİK ÇIKARTMA

Özellik çıkarma, tüm görüntüyü en iyi karakterize eden bir dizi parametre seçme işlemidir. Öte yandan, tüm görüntü yoğunluğu değerleri de bir öznelik olarak kullanılabilir. Bu durumda, algoritmanın hesaplama karmaşıklığı artar. Boyutsal indirgeme ile ilgili özellik çıkarma, verilerini mümkün olduğunca az bilgi ile karakterize etmeyi amaçlamaktadır [60]. Öznelik çıkarma teknikleriyle orjinal değişkenlerin dönüşümü sağlanır. Daha az değişken ile veri analizi daha kolay hale gelir [61]. Bu çalışmada, ML ve DL öznelik çıkartma algoritmaları kullanılmıştır.

3.4.1. Geleneksel Makine Öğrenimi ile Öznelik Çıkartma

Verileri karakterize edecek özneliklerin kullanıcı tarafından belirlenmesine, geleneksel makine öğrenimi ile öznelik çıkartma veya el ile öznelik çıkartma denir. Bu çalışmada, verilerin karakterizasyonunda doku bazlı öznelik çıkartma teknikleri uygulanır.

3.4.1.1. Doku Özellikleri

Bir nesnenin ilgili bölgelerini tanımlamak için kullanılan temel özelliklerden biri olan doku, görüntü yoğunluğundaki yerel varyasyonların tekrarlayan modellerini açıklar. Literatürde doku için birçok tanım verilmiştir. Bu tanımlardan bazıları aşağıdaki gibidir:

- Doku, görüntünün gri seviyesinde uzamsal bir dağılım olarak nitelendirilir, tek bir noktada tanımlanamaz. Bilgisayarla görme, görüntü işleme ve görüntü tanıma gibi alanlarda kullanılan doku, bir görüntüde yüzey özelliklerinin çıkarılmasında önemli bir rol oynar [62].
- Bir görüntüye benzeyen öğeler koleksiyonu olarak tanımlanır.
- Bir görüntüdeki normal piksel değerleri modeli olarak tanımlanır. Her görüntüde renk, şekil ve boyut gibi alt desenlere sahip desenler vardır. Bu desenlerin her biri görüntünün dokusunu oluşturur.

Doku, görüntü hakkında zengin bilgiler sağladığı için tıbbi görüntü analizi, medya modelleme, içerik tabanlı görüntü elde etme ve diğer birçok uygulamada önemli bir rol oynar [63; 64]. Görüntünün doku bilgilerinin temsili, doku tanımlayıcısı ile sağlanır [65]. Doku analizi yöntemleri dört gruba ayrılır: istatistiksel, yapısal, model ve dönüşüm tabanlı yöntemler. Çalışmamızda, yapısal MR verilerini karakterize etmede, **istatistiksel yöntem doku analiz yöntemi** kullanılmıştır.

3.4.1.2. İstatistiksel doku özellikleri

İstatistiksel yöntem, her bir ögenin uzamsal dağılımını hesaba katarak, her noktada yerel özelliklerin dağılımından bir dizi istatistiksel bilgi çıkarır. Bu yöntem birinci dereceden, ikinci dereceden ve daha yüksek dereceden istatistiksel yöntem olarak kategorize edilir. Bu çalışmada, MR görüntülerinden öznitelikleri çıkarmak için birinci ve ikinci dereceden istatistiksel doku analiz yöntemleri kullanılmıştır.

3.4.1.3. Birinci Dereceden İstatistiksel Doku Analizi

Bu yöntemde, piksellerin komşu piksel ile olan ilişkisi dikkate alınmaksızın, her piksel tek başına ele alınarak öznitelikler çıkarılır. Denklem (3.6), çalışmamızda kullanılan birinci dereceden istatistiksel özellikleri göstermektedir. İstatistiksel dağılımın ilk örnek momenti olarak bilinen ortalama (mean) μ , görüntüdeki değerlerin ortalamasını verir. Varyans (variance), σ^2 , veri örneklerinin ortalama değer etrafındaki dağılımını ölçer. Çarpıklık (skewness), değerlerin ortalama değerden dağılımındaki asimetriyi ölçer. Son olarak, basıklık (kurtosis) görüntüdeki gri değerlerin dağılımının tepe noktasını ölçer.

$$\begin{aligned}
\text{Ortalama} &= \frac{1}{N} \sum_i \sum_j I(i, j) \\
\text{Varyans} &= \frac{1}{N-1} \sum_i \sum_j (I(i, j) - \mu)^2 \\
\text{Çarpıklık} &= \frac{1}{N} \sum_i \sum_j \left(\frac{I(i, j) - \mu}{\sigma} \right)^3 \\
\text{Kurtosis} &= \frac{1}{N} \sum_i \sum_j \left(\frac{I(i, j) - \mu}{\sigma} \right)^4
\end{aligned} \tag{3.6}$$


Burada i ve j satır ve sütun numaralarını belirtir, $I(i, j)$ gri tonlu görüntü matrisinin herhangi bir elemanıdır, N görüntüdeki toplam piksel sayısıdır, μ ortalamayı temsil eder ve σ , verinin piksel değerlerinin standart sapmasıdır.

3.4.1.4. İkinci Dereceden İstatistiksel Doku Analizi

İkinci dereceden istatistiksel yöntem, gri seviyelerin göreceli konumları hakkında bilgi sağlar. Bir pikselin diğeriyle olan ilişkisini göz önünde bulundurarak bir dizi istatistiksel hesaplama yapılır. Bu çalışmada, yerel ikili örüntü (Local Binary Pattern -LBP), haralick ve gri seviye eş oluşum matrisi (Gray Level Co-Occurence Matris-GLCM) yöntemleri kullanılmıştır.

3.4.1.5. Yerel İkili Örüntüler

Görüntü işlemede yaygın olarak kullanılan etkili yerel doku tanımlayıcılarından biri yerel ikili modeldir. LBP, merkez pikseli komşu piksellerle karşılaştırarak elde edilir. LBP özellik vektörü için görüntü hücrelere bölünür. Her 3×3 hücredeki her piksel için, örneğin, merkezi pikselin 8 komşusuyla ilişkisi göz önüne alınarak bir karşılaştırma yapılır. Merkez piksel komşu pikselden daha küçükse, bir "0" atanır, aksi takdirde bir "1" atanır ve 8 haneli bir sayı elde edilir. Her sayının frekansı, elde edilen sayı ondalık sayıya dönüştürülerek hesaplanır. Her sayının histogramı, frekans bilgisi ile hesaplanır. Özellik vektörünü oluşturmak için hücrelerin histogramları birleştirilir. **Şekil 3.4.:** LBP'nin nasıl inşa edildiğini açıklar.



Şekil 3.4: LBP operatörüne bir örnek

3.4.1.6. Gri Seviye Eş Oluşum Matrisi (GLCM)

GLCM, doku tanımlayıcılarından biridir ve birçok desen tanıma uygulamasında kullanılmıştır. $K \times L$ boyutlu gri seviyeli bir görüntünün GLCM matrisini elde etmek için, belirli bir açı " θ " ve mesafe " d " olan iki komşu değerinin piksel çiftinin ortak olasılık dağılımları hesaplanır [66; 67].

$$G(n, m) = \sum_{i=1}^K \sum_{j=1}^L \left\{ \begin{array}{ll} 1, & \text{if } I(i, j) = n \text{ \& } \\ & j(i + d \cos \theta, j + d \sin \theta) = m \\ 0, & \text{otherwise} \end{array} \right\} \quad (3.7)$$

Burada, $n, m \in \{0, 1, \dots, N_g - 1\}$ piksellerin yoğunluk değerleridir, $(i, j)^{th}$ görüntünün yoğunluk değeridir, $K \times L$, N_g gri seviyelerine sahip görüntünün boyutudur. Bu çalışmada, $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ ve $d = 1$ mesafesi için GLCM matrisleri hesaplanır. GLCM matrisleri tüm yönler için hesaplandıktan sonra, tek bir matris elde etmek için ortalaması alınır ve normalize edilir. Nihai GLCM matrisinden sırasıyla, kontrast, korelasyon, enerji ve homojenlik öznitelik değerleri hesaplanır.

$$\begin{aligned}
G_C &= \sum_{n=0}^{N_g-1} \sum_{m=0}^{N_g-1} (n-m)^2 G^2(n,m) \\
G_{Corr} &= \sum_{n=0}^{N_g-1} \sum_{m=0}^{N_g-1} (n-\mu)(m-\mu)G(n,m)/\sigma^2 \\
G_E &= \sqrt{\sum_{n=0}^{N_g-1} \sum_{m=0}^{N_g-1} G^2(n,m)} \\
G_H &= \sum_{n=0}^{N_g-1} \sum_{m=0}^{N_g-1} \frac{1}{1+(n-m)^2} G(n,m)
\end{aligned} \tag{3.8}$$

N_g gri düzeylerin sayısını, $G(n,m)$ GLCM matrisinin $(n,m)^{th}$ girdisi, μ ortalama değer ve σ^2 , GLCM matrisinin varyansdır. G_C , G_{Corr} , G_E , G_H , GLCM matrisinden hesaplanan Kontrast, Korelasyon, Enerji ve Homojenlik özellikleridir.

3.4.1.7. Haralick Doku Özellikleri


Haralick yöntemi; böbrek, prostat, akciğer ve demans gibi birçok hastalığın tespitinde medikal görüntüleri karakterize etmek için kullanılan başarılı matematiksel yöntemlerden biridir [68–72]. Yapısal MR dokusunu tanımlamak için çıkarılan Haralick öz nitelikleri şu şekildedir. Açısal ikinci moment (Angular second moment), korelasyon (correlation), kontrast (contrast), kareler toplamı (sum of squares), ters fark momenti (inverse difference moment), toplam ortalama (sum average), toplam varyans (sum variance), toplam entropi (sum entropy), entropi (entropy), fark varyansı (difference variance), fark entropisi (difference entropy), Korelasyon I'in bilgi ölçüsü (information Measure of Correlation I), Korelasyon II'nin bilgi ölçüsü (information Measure of Correlation II) ve maksimum korelasyon katsayısı (maximum correlation coefficient) dır. *Açısal ikinci moment*, bir görüntünün homojenliğini ölçer. *Korelasyon*, bir pikselin komşu piksel ile olan ilişkisini ölçer. *Kontrast*, referans pikselin komşu piksel ile arasındaki giriş seviyesi değişikliklerinin bir ölçüsüdür. *Toplam Ortalama*, gri düzey toplam dağılımın ortalamasını ölçer. *Fark varyansı*, gri seviye fark dağılımını ölçer. *Sum entropi*, görüntülerin gri düzey dağılımıyla

ilgili bozukluğu ölçer. *Fark entropi*, verilerin rasgeleliğini karakterize eder. *Ters fark momenti*, yerel homojenliğin bir ölçüsüdür. *Kareler toplamı*, ortalamadan hesaplanan sapmaların bir ölçüsüdür. *Toplam varyans*, görüntüdeki rastgele gri seviyelerin görüntünün ortalama değerlerinden kare sapmasının bir beklentisidir. *Maksimum korelasyon katsayısı* optimum değere karşılık gelir. *Korelasyon I'in bilgi ölçüsü*, öngörülen iki rastgele değişken ile gerçek değer arasındaki doğrusal ilişkilerini ölçer. *Korelasyon II'nin bilgi ölçüsü*, öngörülen değer ve gerçek değer arasındaki ilişki ve gücü ölçer.

3.4.2. Derin Öğrenmeyi Kullanarak Otomatik Özellik Ayıklama

Derin öğrenme, insan beyninin çalışma mekanizmasından esinlenen geliştirilmiş bir yapay sinir ağı modelidir. Temel Yapay Sinir Ağı üç katmandan oluşur: giriş, çıkış ve gizli katmanlar. Her katmanda birden fazla nöron bulunur. ANN'lerde gizli katmanların sayısı farklı olabilir. Mimariden mimariye değişir. Optimum gizli katman sayısı, numune sayısı, girdi değerleri ve çıktı parametreleri dikkate alınarak belirlenir. Bu parametrelerin sayısı artarsa, gizli katmanların sayısı da artar, dolayısıyla ağın derinliği de artar. Bu ağa Derin Öğrenme ağı denir. DL, kullanıcıya sunduğu mimari ile klasik sinir ağlarından daha iyi performans göstermektedir. Son yıllarda, DL, birçok uygulamada başarılı sonuçlar elde etmiş ve geleneksel makine öğrenimi yöntemlerinden daha iyi performans gösterdiği kanıtlanmıştır [73]. DL mimarisinde, bir nesnenin sınıflandırılması için temel adımlar, girdi değerleri, bu değerleri temsil eden özniteliklerin çıkarımı ve sınıflandırılması sırasıyla gerçekleştirilir.


Şekil 3.5:, basit bir DL yapısını gösterir.



Şekil 3.5: Basit Bir Derin Öğrenme Yapısı


Evrişim katmanı, girdi görüntüsü filtrelerden geçerek evrişim işlemi ile yeni görüntüler oluşur. **Şekil 3.6:**, imge boyutları 5X5 olan bir matris, 3x3 filtre uygulandığında, elde

edilen çıktıyı göstermektedir. Bu ilk adım görüntüyü karakterize edecek öznelikleri temsil eder. Havuzlama katmanı, görüntünün verilen parametreye göre küçültülmesini sağlar. Parametre çeşitleri üç tiptir : maksimum, minumum ve ortalama. Örneğin; maksimum değer parametre olarak verilmişse, belirtilen bölgeden maksimum değer çıktıya aktarılır.



Şekil 3.6: Evrişim ve Havuzlama Katmanı Örneği

Normalleştirme katmanı, görüntüdeki değerlerin belirli aralıklarla çekilmesini sağlar. Drop out katmanı, ağda bazı bağlantıları kaldırarak ağın ezberlemesini önler. Böylece ağdan daha başarılı sonuçlar alınması sağlanır. Tam bağlı katmanda, tüm düğümler birbirine bağlıdır. Bu katmanda, önceki katmandan alınan bilgiler tek bir katmana dönüştürülür her veriye ağırlık uygulanarak, nesnelerin sınıfları tespit edilir. Softmax katmanı, girdi olarak bir vektör alır ve elde edilen öznelilik vektörlerinin sınıf tespiti için logistik işlevi uygulanır. Çıktı katmanında, bir önceki katmandan gelen değerlere sınıf ataması yapılır. Katmanlarda, doğrusal olmayan aktivasyon fonksiyonu uygulanır.



Şekil 3.7: Nonlinear Aktivasyon Fonksiyonu (a) ReLU (b) TanH


Doğrusal olmayan fonksiyonlar, evrişim ve tam bağlı katmanlarda uygulanır. ANN’lerde genellikle sigmoid veya tanh (Şekil 3.7:) aktivasyon fonksiyonu kullanılır. Ancak katmanların derinliği ile gelen parametre artışı modelin daha yavaş çalışmasına neden olur. Bu amaçla, modelin hızlı çalışmasını sağlamak için DL mimarisinde, ReLU aktivasyon fonksiyonu (Şekil 3.7:) kullanılır [74]. Bu fonksiyon, negatif değerleri sıfıra çekerken, pozitif değerlerde herhangi bir değişiklik yapmadan verinin çıktıya aktarılmasını sağlar.

3.4.2.1. Transfer Öğrenimi


Transfer öğrenme yaklaşımı, insanların daha önce öğrendikleri problem çözme becerisini, yeni problemlerde çözmeyi sağlamaktadır. [75; 76]. Veri sayısı az ise, transfer öğrenimi yöntemi ile, model oluşumunda oluşabilecek overfitting gibi olumsuzluklar da giderilir.

3.4.2.2. AlexNet

ImageNet 2012 yarışmasını kazanan AlexNet mimarisi (Şekil 3.8:), Krizhevsky tarafından tasarlanan bir tür evrişimli sinir ağıdır [77]. Ağ; giriş, evrişim, havuzlama, tam bağlantılı katman ve softmax katmanlarından oluşmaktadır. LeNet ağına çok benzeyen AlexNet katmanı, daha fazla katman sayısı yönüyle LeNet ağından farklılık göstermektedir. Imagenet üzerinde eğitilen AlexNet mimarisinin girdi boyutları 227*227*3 dür. Erişim katmanında, boyutu 3*3 veya 5*5 olan filtreler gezdirilerek, bir sonraki katmana girdi niteliğinde olan yeni görüntü oluşturulur. Havuzlama katmanı ile verilerin bilgileri bozulmadan görüntünün boyutu azaltılır. AlexNet ağı hiper parametreleri, ilk öğrenme hızı 0.01 ve momentum 0.9 dur. Bu yöntem, çevirme, kırpma, titreme gibi veri artırım teknikleri ile veriyi artırır.




Şekil 3.8: AlexNet Mimarisi



Şekil 3.10: Artık Bloklar

3.4.2.5. SqueezeNet

SqueezeNet, 50 kat daha az parametre ile AlexNet'ten daha başarılı performans sağlayan bir CNN türüdür [79]. Daha az parametre, daha az bant genişliğini gerektirdiğinden, farklı platformda örneğin buluttan veriyi dışarı aktarmada önemli bir avantaj sağlamaktadır. SqueezeNet, sınırlı belleğe sahip donanım üzerinde sorunsuz çalıştırılması nedeniyle de tercih edilir. SqueezeNet (Şekil 3.11:.) üç maksimum havuz katmanı, sekiz ateş katmanı, bir genel havuz katmanı ve bir çıktı katmanına sahip olup 15 katmanlıdır.



Şekil 3.11: SqueezeNet Mimarisi

3.4.2.6. *Inception-ResNet*


Google tarafından önerilen Inception-ResNet mimarisi, Inception blokları ve ResNet mimarisinin bir kombinasyonudur. Yüksek doğrulukta sonuçlar, artırılmış derinlik içeren başlangıç blokları kullanılarak elde edilir [80]. Bu çalışmanın ilk metodolojisinde, Inception-ResNet mimarisi kullanılmıştır.

3.4.2.7. *Önerilen CNN Mimarisi*


Yeni ağ mimarimiz, 25 katmanlı AlexNet katmanlı model örnek alınarak tasarlanmıştır. Bütün dilimleri içeren 2.veri kümesinin karakterize edilmesinde, AlexNet mimarisi ile yüksek performans değerleri gözlemlendi. Daha kısa sürede, daha az katmanla yüksek sınıflandırma performansı elde etmek amacıyla, AlexNet mimarisinin daha kısaltılmış bir mimarisi tasarlandı. Amaç, hesaplama maliyetini düşürürken, sınıflandırma performansı yükseltmektir. AlexNet mimarisinin grafiksel gösterimi **Şekil 3.12:** ve önerilen CNN ağının parametreleri **Şekil 3.13:** te gösterilmektedir. Farklı merkezlerden alınan MR boyutları sabit bir boyutta olmayıp, $227 \times 227 \times 3$ boyutları ile yeniden boyutlandırılarak önerilen ağa girdi olarak verildi. İlk aşamada, evrişim katmanı filtre boyutu 5×5 olup, adım aralığı 3 dür. Bunu takiben, relu ve normalization katmanları yer alır. Ardından, ilk aşamadaki özelliklere sahip evrişim katmanı uygulanır. Ardından, reLU, normalization, tam bağlı katman, drop out, softmax ve sınıflandırma katmanı yer alır. Önerilen CNN mimarisinin Alexnet mimarisinden farklı kılan yanları; az sayıda katman kullanılması (11 katmanlı), filtre boyutunun daha küçük olması, farklı katmanların art arda gelmesi olarak sıralanabilir. Mimari, DEHB tanı modelinde, en iyi CNN mimarisini tespit etmek amacıyla, yazarın kendisi tarafından tasarlanmış ve adını GulayNet :), yani yazarın isminden almıştır.

3.5. ÖZNETELİK SEÇME

Öznitelik seçimi, model oluşturmada kullanılacak ilgili öznitelikleri tespit etme işlemidir. Modelin oluşumunu olumsuz etkileyecek öznitelikler çıkarılmış olabilir. Bu yöntem ile,



Şekil 3.12: Detaylı AlexNet Mimarisi



Şekil 3.13: Önerilen CNN Mimarisi [GulayNet Mimari :)]

ilgisiz öznitelikler tespit edilerek, modellerin anlaşılması sağlanır ve eğitim süreleri kısaltılır.

3.5.1. Temel Bileşenler Analizi

Temel Bileşenler Analizi yüksek boyutlu verilerde boyut indirgeme işlemini sağlamaktadır. Bu yöntem, yüksek korelasyonlu verileri birleştirerek, verinin temel bileşenlerini tespit eder. Böylece veride güçlü örüntüler bulunarak, sınıflama ve veri sıkıştırma gibi işlemler yapılır. ML algoritmaları ile çok boyutlu bir verinin eğitimi ile,

- Eğitim süreci yavaşlar.
- Modelin analizini zorlaştır.
- Gürültülü bilgileri içeren veriden, düşük performansı sonuçlar elde edilir.

Gerek eğitimi hızlandırma gerekse modelin analizini kolaylaştırma gibi nedenler ile uygulanan PCA yöntemi ile, yüksek boyutlu veri seti, daha düşük boyutlu veri setine dönüştürülerek bilgi kaybını minimize edilir ve maximum performans yakalanır. Bir

normalizasyon işlemi uygulanan veri kümesine PCA uygulanacak ise, aşağı adımlar sırasıyla gerçekleştirilerek, verinin temel bileşenleri bulunur.

- Kovaryans matrisi hesaplanır.
- Öz değerler ve öz vektörler hesaplanır.
- Temel bileşenler seçilerek, yeni veri kümesi oluşturulur.

3.6. SINIFLANDIRMA


Sınıflandırma, önceden kategorileri bilinen verilerin, eğitim kümesine dayalı olarak test verilerinin kategorisini belirleme işidir. Çalışmamız, sağlıklı bireyler ile DEHB'li bireylerin verilerini yapısal MR görüntülere dayanarak ayırt etmek olduğundan, iki sınıfımız bulunmaktadır.

3.6.1. K En Yakın Komşu Algoritması


K En yakın komşu (KNN) algoritması (Şekil 3.14:.), basit ve başarılı sınıflandırma algoritmalarından biridir. Bu algoritma, tüm durumları saklayıp, test verisini benzerlik ölçüsüne göre sınıflandırmaktadır. K, bilinmeyen verinin en yakın komşusunu temsil etmektedir. Veriler arasındaki mesafe (Şekil 3.15:), Öklid (Denklem 3.9), Manhattan (Denklem 3.10) Chebyshev (Denklem 3.11) benzerliği ile ölçülebilir.

$$I_{euclid}(x,y) = \sqrt{\sum_1^m (x_i - y_i)^2} \quad (3.9)$$

$$I_{manhattan}(x,y) = \sum_1^n (|x_i - y_i|)^2 \quad (3.10)$$



Şekil 3.14: En Yakın Komşu Sınıflandırıcısı



Şekil 3.15: Mesafe Ölçüleri


$$I_{Chebyshev}(x,y) = \max(|x_i - y_i|) \quad (3.11)$$

KNN algoritmasına göre, verinin sınıfını tespit etmek için sırayla aşağıdaki işlemler yapılır.

- K değeri belirlenir.
- Uzaklık fonksiyonu belirlenir.
- Test verisi, eğitim kümesindeki her veri ile uzaklığı hesaplanır.
- Uzaklıklar küçükten büyüğe doğru sıralanır.
- En yakın k komşunun oy çokluğunda göre, verinin sınıf tespiti yapılır.

3.6.2. Karar Ağaçları

Karar ağacı, anlaşılması ve yorumlanması kolay güçlü bir sınıflandırma algoritmasıdır. Bu algoritma, gözetimli öğrenmede çok yaygın olarak kullanılmaktadır. Böl ve Fethet yöntemini kullanarak bir ağaç oluşturur. Ağaçta (Şekil 3.16:), her düğüm bir özneliği, her bağlantı bir kararı, her bir yaprak ise bir sonucu temsil etmektedir.




Şekil 3.16: İkili Ağaç

Ağaç oluşturmak için, iki farklı yöntem kullanılmaktadır. Bunlar CART ve ID3 algoritmalarıdır. ID3 algoritması, arama alanını sürekli olarak belirli bir parametreye göre böler. Bu parametre, örnekleri eğitim setinden en iyi şekilde ayıran özneliğe sahiptir. Algoritma, bilgi kazancı ve entropi yöntemine dayanmaktadır. Shannon tarafından ortaya atılan entropi kavramı; rastgeleliğin, belirsizliğin ve beklenmeyen durumun ortaya çıkma olasılığını göstererek bir sistemin düzensizliğini gösterir. Bir özneliğin sınıf hakkında verdiği bilgiyi bilgi kazancı ile ölçülür. Eğitim setindeki en ayırt edici özneliğin tespitinde, her öznelik için bilgi kazancı hesaplanır. Bilgi kazancı veri setindeki, tüm numuneler üzerinden hesaplanır ve alt düğümler belirlenir. Bu prosedür örnek kalmayana kadar, diğer bir değişle, ağacın yapraklarını bulana kadar bu işlem devam eder. Yapraklar verinin sınıflarını temsil eder. Karar ağacı algoritmasına göre, verinin sınıfını tespit etmek için sırayla aşağıdaki işlemler yapılır.

- Veri kümesi için entropi hesaplanır
- Her bir özniteliğe karşılık; özniteliğin her bir değeri için entropi hesaplanır.
- Her bir öznitelik için ortalama bilgi entropisi hesaplanarak kazanç hesaplanır.
- Bilgi kazancı yüksek olan bulunur ve düğüm olarak yerleştirilir.
- Ağaç tamamlayıncaya kadar bu işlemler tekrarlanır.

3.6.3. Destek Vektör Makinesi

Bir destek vektör makinesi, ayırıcı bir hiper düzlem tarafından resmen tanımlanmış ayırt edici bir sınıflandırıcıdır. Destek vektör makineleri (Şekil 3.17:), sınıfları birbirinden en iyi ayıran bir sınırdır. Gözetimli bir sınıflandırma algoritması olan destek vektör makinesi, n-boyutlu bir uzayda bu verileri en iyi şekilde ayırt edecek bir hiper düzlemi bularak, verileri sınıflandırmaktadır.



Şekil 3.17: Destek Vektör Makinesi

3.6.4. Topluluk Öğrenme Algoritmaları

Topluluk öğrenme Algoritmaları (Şekil 3.18:), modelin performansının iyileştirmek amacıyla, birden fazla sınıflandırma algoritmasının birlikt kullanıldığı makine öğrenme modelidir. Modelin kararlılığı ve tahmin gücünü artırmak için birden çok makine öğrenim modelini tek bir tahmin modelinde birleştirilerek, yüksek tahmin performansına izin verir. Genelde, zayıf modellerin doğru bir şekilde birleştirilmesi ile yüksek performans sonuçları


elde edildiğinden ötürü, birçok prestijli makine öğrenme algoritmalarında kullanılmalarının nedenini teşkil etmektedir.



Şekil 3.18: Topluluk Öğrenme Algoritmaları

3.6.4.1. Torbalama

Veri kümesi parçalara ayrılarak çoklu alt kümeler oluşturulur. Her alt kümenin temel modeli oluşturulur. Modeller eş zamanlı çalışır. Bütün modellerden elde edilen sonuçlar birleştirilerek sonuçlar test edilir. Kısaca torbalama (Şekil 3.19:), birden çok tahminin ortalamasını alarak, tahminin varyansını azaltır. Torbalama için, Denklem ?? uygulanır.




Şekil 3.19: Torbalama Algoritması

3.6.4.2. Yükseltme

Yükseltme algoritması, orjinal veri kümesinden oluşturulan alt kümelerde yanlış tahminlerin ağırlıklarını artırarak, yeni modeller oluşturup, sınıflandırma başarısını artırmayı amaçlar. Algoritmanın çalışma prensibi şu şekildedir. Orijinal veri kümesinden bir alt küme oluşturulur. Alt kümede yer alan her bir veriye eşit ağırlık verilerek bir model oluşturulur. Yanlış tahminler tespit edilerek, ağırlıklar artırılır ve yeni bir model oluşturulur. Aynı adım

tekrarlanarak, model ile tespit edilen yanlış tahminler ağırlıklandırılır. Her bir model, bir önceki modelin hatalarını düzeltmek amacıyla oluşturulur. Elde edilen çoklu modellerin ağırlıkları ortalaması ile yeni bir model (Şekil 3.20:) oluşur.



Şekil 3.20: Yükseltme Algoritması

3.6.4.3. Rastgele Orman

Genelleştirilmiş bir model üretmek için, çeşitli karar ağaçlarını birleştirmeye dayalı iyi bilinen topluluk öğrenme algoritmalarındandır. Rastgele orman (Şekil 3.21:), veri kümesinden rastgele alt kümeler oluşturur. Bu alt kümeler ile ağaç çeşitliliği sağlanarak, aşırı uyum problemi önlenmiş olur.



Şekil 3.21: Rastgele Orman Algoritması

3.7. DEĞERLENDİRME ÖLÇÜTLERİ

3.7.1. Karmaşıklık Matrisi

Bu çalışmada, önerilen her bir DEHB algılama modelinin performansı, sınıflandırma doğruluğu, duyarlılık, özgüllük, kesinlik ve f-ölçütü açısından değerlendirilmiştir. Karmaşıklık Matrisi (Tablo 3.2:), bir sınıflandırma algoritmasının performansını gösteren bir tablodur. Doğruluk (Denklem 3.12), sınıfları doğru bir şekilde ayırt etme metriğidir ve şu şekilde tanımlanır:

Tahmin Sınıf	Gerçek Sınıf		Total
	Pozitif	Negatif	
	Pozitif	Negatif	Total
	TP	FP	$TP + FP$
	FN	TN	$FN + TN$
Total	$TP + FN$	$FP + TN$	N

Tablo 3.2: Karmaşıklık Matrisi

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.12)$$

Burada TP gerçek pozitifdir, DEHB olarak kategorize edilen bireylerin DEHB olarak tahmin edildiği durumdur. TN gerçek negatiftir, sağlıklı olarak sınıflandırılan bireylerin sağlıklı olarak öngörüldüğü durumdur. FP yanlış pozitifdir, DEHB'li verilerin, sağlıklı olarak öngörüldüğü durumdur. FN yanlış negatiftir, sağlıklı verilerin, DEHB olarak tahmin edildiği anlamına gelir.

DEHB algılama modelini düşündüğümüzde, duyarlılık (Denklem 3.13) aslında DEHB'li bireyleri DEHB olarak öngörme yeteneğini ifade eder. Bu nedenle, DEHB'li bireyler arasında DEHB ile öngörülen oran, şu şekilde ifade edilir.

$$\text{Sensitivity} = \frac{(TP)}{(TP + FN)} \quad (3.13)$$

Özgüllük (Denklem 3.13), sağlıklı bireylerin sağlıklı olarak kategorize edilme yeteneğini ifade eder. Böylece, sağlıklı bireyler arasında sağlıklı tahmin edilme oranı şu şekilde hesaplanır:

$$\text{Duyarlılık} = \frac{TN}{TN + FP} \quad (3.14)$$

Kesinlik (Denklem 3.15), DEHB'ye atanan DEHB tahminlerini ölçer. Kesinlik şu şekilde tanımlanır:

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.15)$$

F-ölçütü (Denklem 3.16) ise, duyarlılığın ve kesinliğin harmonik ortalamasıdır. F-ölçütü şu şekilde tanımlanır.

$$\text{F-Ölçütü} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.16)$$

3.7.2. Çapraz Doğrulama Yöntemi

Çapraz doğrulama, sınıflandırma algoritmalarının performansını değerlendirmek ve karşılaştırmak için kullanılan bölme yöntemidir. Veriler, eğitim ve test amacıyla bölümlere ayrılmıştır. Bölüm biçimi, seçilen değerlendirme yöntemine göre değişir.

3.7.2.1. *K-Katlamalı Çapraz Doğrulama*

Makine öğrenme algoritmalarının performansını değerlendirmek ve karşılaştırmak için yaygın olarak kullanılan bir prosedürdür. Çapraz doğrulama (**Şekil 3.22:**), bir hiper parametresi "k" ile veri kümesinin alt kümelerinin sayısı belirlenir. *K* hiper parametresinin belirlenmesi ile eğitim ve test kümeleri belirlenir. Yöntemin çalışma adımları şu şekildedir.

- Veri kümesi *k* alt kümeye bölünür.
- İlk alt küme test, diğeri, *k* – 1 alt küme eğitim amaçlı kullanılır.
- Modelin doğruluk değeri ve hata değeri hesaplanır.
- Her seferinde test alt küme değiştirilerek, ikinci ve üçüncü adımlar sırasıyla gerçekleştirilir.
- Tüm *k* denemelerin ortalama doğruluk değerleri ve hata değerleri hesaplanır.




Şekil 3.22: 10 Kat Çapraz Doğrulama Diyagramı

$$E = \sum_{n=1}^K E_i \quad (3.17)$$

Denklem 3.17. de ifade edilen E_i , i'inci grubun çapraz doğrulama hatasını ve K de fold sayısını temsil etmektedir.

3.7.2.2. Dışarıda Bırakma Çapraz Geçerleme

Bu yaklaşımda (Şekil 3.23:) veriler iki bölüme ayrılmıştır. Bir parça eğitim, diğer parça sınıflandırıcıyı test etmek için kullanılır. Genelde, veri kümesinin %30 'u eğitim, % 70'i test amaçlı kullanılır.




Şekil 3.23: Dışarıda Bırakma Çapraz Doğrulama Diyagramı

3.7.2.3. Birini Dışarıda Bırakma Yöntemi

Bu yöntemde (Şekil 3.24:), veri kümesindeki her örnek için modelin oluşturulmasını ve değerlendirilmesini sağlar. Çok sayıda uygun ve değerlendirilmiş modelin yararı, sağlam

bir modelin tespitini göstermesi açısından önem taşımaktadır. Büyük veri kümelerinde, hesaplama maliyetini artırdığından, tercih edilmemektedir.



Şekil 3.24: Birini Dışarıda Bırakma Çapraz Doğrulama Diyagramı

4. BULGULAR

4.1. MAKİNE ÖĞRENME ALGORİTMALARI İLE MODEL SONUÇLARI (YÖNTEMİ)

DEHB - Sağlıklı sınıflandırma deneylerimizde, NPIstanbul ve ADHD-200 veri kümesinden alınan yapısal MRI verileri kullanıldı. Bilindiği gibi, yapısal MR verileri kesitlerden oluşmaktadır. Bu kesitlerin DEHB modeli üzerindeki etkilerini tespit etmek amacıyla, iki farklı veri kümesi oluşturuldu; Verikümesi1 ve Verikümesi2. Verikümesi2, yapısal MR'ın tüm dilimlerini içerirken, Verikümesi1 önerdiğimiz algoritma ile belirlenen yararlı dilimleri içermektedir. Bir başka deyişle, gri ve beyaz maddenin tam ve net görüldüğü dilimleri göstermektedir. Bu veri kümelerini karakterize edecek özniteliklerin tespiti için ML ve DL algoritmaları kullanılmıştır. Özniteliklerin tespiti ML algoritmalarında, kullanıcı tarafından belirlenirken, DL algoritmalarında ise, yöntemin kendisi veriden otomatik olarak öğrenmektedir. Bu nedenle, ML algoritması el ile öznitelik çıkartma yöntemi olarak adlandırılırken, DL algoritmaları ise, otomatik öznitelikler çıkartma yöntemi olarak tanımlanır. Bu çalışmada, el ile öznitelik çıkartma yöntemi olarak istatistiksel temelli (Birinci Mertebe, ikinci mertebe (LBP, GLCM, Haralick)) yöntemler kullanılırken, otomatik öznitelik çıkartma yöntemi olarak AlexNet, VGGNet, ResNet, SqueezeNet ve Inception-ResNet otomatik öznitelik çıkarma yöntemi kullanıldı. Öznitelik kümeleri, tek (single) ve topluluk (ensemble) sınıflandırıcı algoritmalar kullanılarak sınıflandırıldı. Tekil sınıflandırıcı algoritma olarak, Linear SVM, Quadratic SVM, Cubic SVM, Fine Gaussian SVM, Medium Gaussian SVM, Coarse Gaussian SVM, Fine KNN, Medium KNN, Coarse KNN, Cosine KNN, Cubic KNN, Weighted KNN, Fine Tree, Medium Tree ve Coarse Tree, sınıflandırma algoritması kullanılırken, topluluk sınıflandırma algoritması olarak, Ensemble Boosted Tree, Ensemble Bagged Tree, Ensemble Subspace Discriminant, Ensemble Subspace KNN ve Ensemble RUSBoosted Tree sınıflandırma algoritması kullanıldı.

Tüm algoritmaların performans ölçümlerini hesaplamasında, 10 kat çapraz doğrulama (10 Fold Cross Validation) yöntemi kullanıldı. Veri Kümesi1 ve Veri Kümesi2 'nin tüm öznitelik çıkartma yöntemlerinin ayrıntılı performans sonuçları, **Tablo 4.1:**, **Tablo 4.2:**, **Tablo 4.3:**, **Tablo 4.4:**, **Tablo 4.5:**, **Tablo 4.6:**, **Tablo 4.7:**, **Tablo 4.8:** de gösterilmektedir. Bu tablolarda, doğruluk oranları % 90.0 ve üzerindeki sonuçlar koyu olarak ifade edilmiştir. Deneylerimizde en başarılı sonuçlar, önerdiğimiz algoritma ile tespit edilen gri ve beyaz maddelerin net olarak görüldüğü dilimleri içeren verikümesinde (verikümesi1) gerçekleşmiştir. Verikümesi1'i karakterize etmede LBP yöntemi (**Tablo 4.1:**), çalışmamızda kullanılan hemen hemen bütün algoritmalarda başarılı sonuçlar vermiştir.

Dokudaki küçük değişiklikleri iyi bir şekilde algılayan LBP yöntemi ile, önerdiğimiz algoritma ile tespit edilen yapısal MR kesitlerini içeren Verikümesi1'i karakterize etmede hem tekil hem de çoğul sınıflandırma algoritmalarında yüksek performans sonuçları elde edilmiştir. LBP algoritması bu veri kümesinde, %100 doğruluk, %100 duyarlılık, %100 özgüllük sonuçlarını vermiştir.

Birinci dereceden istatistiksel öznitelikler ile yapılan sınıflandırmada (**Tablo 4.2:**), gri ve beyaz maddenin net görüldüğü dilimleri içeren verikümesinde (verikümesi1) daha başarılı sonuçlar elde edilmiştir. Birinci dereceden istatistiksel algoritması bu veri kümesinde, %97.0 doğruluk, %96.0 duyarlılık, %97.0 özgüllük ile en yüksek performans sonuçlarını vermiştir.

Tablo 4.3: de, Haralick özelliklerinin sınıflandırma performans sonuçları gösterilmektedir. Sınıflandırma tüm yapısal MR dilimlerini barındıran veri kümesine (verikümesi2) kıyasla, önerdiğimiz algoritma ile tespit edilen anlamlı bilgileri içeren veri kümesinde (verikümesi1) çok daha başarılı sonuçlar vermiştir.

GLCM algoritması ile yapılan sınıflandırmada (**Tablo 4.4:**), önerdiğimiz algoritma ile tespit edilen anlamlı kesitleri içeren verikümesinde (verikümesi1) başarılı sınıflandırma sonuçları elde edilmiştir. GLCM yöntemi ile bu veri kümesinde, %97.0 doğruluk, %96.0 duyarlılık, %97.0 özgüllük ile en yüksek sınıflandırma performans sonuçları gözlemlenmiştir.

Tablo 4.1: LBP Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	Local Binary Pattern									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.52	0.00	0.52	0.00	0.00	0.65	0.64	0.67	0.62	0.63
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.65	0.64	0.67	0.62	0.63
Ens. Bagged. Tree	PCA-OFF	0.89	0.81	1.00	1.00	0.90	0.72	0.67	0.78	0.80	0.73
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.72	0.67	0.78	0.80	0.73
Ens. Subspace. Disc.	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.68	0.66	0.70	0.68	0.67
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.68	0.66	0.70	0.68	0.67
Ens. Subspace. KNN.	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.67	0.69	0.65	0.65	0.67
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.67	0.69	0.65	0.65	0.67
Ens. RUSBoosted. Tree	PCA-OFF	0.52	0.00	0.52	0.00	0.00	0.67	0.64	0.69	0.67	0.66
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.67	0.64	0.69	0.67	0.66
SVM Linear	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.63	0.60	0.66	0.64	0.62
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.63	0.60	0.66	0.64	0.62
Quadratic SVM	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.68	0.67	0.69	0.64	0.65
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.68	0.67	0.69	0.64	0.65
Cubic SVM	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.71	0.69	0.72	0.69	0.69
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.71	0.69	0.72	0.69	0.69
FineGauss SVM	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.72	0.65	0.86	0.90	0.76
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.72	0.65	0.86	0.90	0.76
MediumGauss SVM	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.65	0.61	0.69	0.69	0.65
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.65	0.61	0.69	0.69	0.65
CoarseGauss SVM	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.54	0.56	0.54	0.18	0.27
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.54	0.56	0.54	0.18	0.27
Fine KNN	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.72	0.73	0.71	0.64	0.68
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.72	0.73	0.71	0.64	0.68
Medium KNN	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.63	0.62	0.65	0.60	0.61
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.63	0.62	0.65	0.60	0.61
Coarse KNN	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.53	0.50	0.54	0.39	0.44
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.53	0.50	0.54	0.39	0.44
Cosine KNN	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.60	0.58	0.62	0.59	0.58
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.60	0.58	0.62	0.59	0.58
Cubic KNN	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.64	0.62	0.66	0.62	0.62
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.64	0.62	0.66	0.62	0.62
Weighted KNN	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.71	0.72	0.71	0.64	0.68
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.71	0.72	0.71	0.64	0.68
Fine Tree	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.65	0.64	0.67	0.62	0.63
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.65	0.64	0.67	0.62	0.63
Medium Tree	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.65	0.63	0.67	0.64	0.63
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.65	0.63	0.67	0.64	0.63
Coarse Tree	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.61	0.59	0.62	0.55	0.57
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.61	0.61	0.61	0.61	0.61

Tablo 4.2: Birinci Mertebe Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	First Order Dataset									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.52	0.00	0.52	0.00	0.00	0.60	0.57	0.65	0.69	0.69
	PCA-ON	0.77	0.74	0.79	0.78	0.78	0.52	0.00	0.52	0.00	0.00
Ens. Bagged. Tree	PCA-OFF	0.97	0.96	0.97	0.97	0.97	0.64	0.60	0.67	0.67	0.67
	PCA-ON	0.76	0.74	0.78	0.78	0.78	0.52	0.00	0.52	0.00	0.00
Ens. Subspace. Disc.	PCA-OFF	0.80	0.77	0.82	0.82	0.82	0.55	0.52	0.60	0.64	0.64
	PCA-ON	0.64	0.61	0.68	0.70	0.70	0.52	0.00	0.52	0.00	0.00
Ens. Subspace. KNN.	PCA-OFF	0.89	0.86	0.92	0.92	0.92	0.69	0.68	0.70	0.64	0.64
	PCA-ON	0.76	0.74	0.79	0.78	0.78	0.52	0.00	0.52	0.00	0.00
Ens. RUSBoosted. Tree	PCA-OFF	0.93	0.91	0.96	0.96	0.94	0.61	0.57	0.65	0.68	0.68
	PCA-ON	0.75	0.71	0.79	0.80	0.80	0.52	0.00	0.52	0.00	0.00
SVM Linear	PCA-OFF	0.89	0.90	0.89	0.88	0.88	0.61	0.57	0.65	0.68	0.68
	PCA-ON	0.64	0.60	0.68	0.70	0.70	0.52	0.00	0.52	0.00	0.00
Quadratic SVM	PCA-OFF	0.89	0.90	0.89	0.88	0.88	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.54	0.52	0.57	0.60	0.60	0.52	0.00	0.52	0.00	0.00
Cubic SVM	PCA-OFF	0.97	0.97	0.97	0.97	0.97	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.46	0.44	0.49	0.47	0.47	0.52	0.00	0.52	0.00	0.00
FineGauss SVM	PCA-OFF	0.96	0.97	0.95	0.94	0.94	0.50	0.00	0.51	0.00	0.00
	PCA-ON	0.75	0.69	0.82	0.84	0.84	0.52	0.00	0.52	0.00	0.00
MediumGauss SVM	PCA-OFF	0.97	0.97	0.96	0.96	0.96	0.51	0.00	0.52	0.00	0.00
	PCA-ON	0.69	0.72	0.67	0.58	0.58	0.52	0.00	0.52	0.00	0.00
CoarseGauss SVM	PCA-OFF	0.81	0.78	0.86	0.86	0.86	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.66	0.63	0.68	0.68	0.68	0.52	0.00	0.52	0.00	0.00
Fine KNN	PCA-OFF	0.97	0.95	0.98	0.98	0.98	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.76	0.74	0.99	0.78	0.78	0.52	0.00	0.52	0.00	0.00
Medium KNN	PCA-OFF	0.96	0.96	0.96	0.96	0.96	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.75	0.71	0.81	0.82	0.82	0.52	0.00	0.52	0.00	0.00
Coarse KNN	PCA-OFF	0.78	0.79	0.77	0.73	0.73	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.69	0.72	0.67	0.58	0.58	0.52	0.00	0.52	0.00	0.00
Cosine KNN	PCA-OFF	0.95	0.92	0.98	0.98	0.98	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.47	0.47	0.00	1.00	1.00	0.52	0.00	0.52	0.00	0.00
Cubic KNN	PCA-OFF	0.96	0.96	0.96	0.96	0.96	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.75	0.71	0.81	0.82	0.82	0.52	0.00	0.52	0.00	0.00
Weighted KNN	PCA-OFF	0.97	0.96	0.97	0.97	0.97	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.76	0.74	0.78	0.78	0.78	0.52	0.00	0.52	0.00	0.00
Fine Tree	PCA-OFF	0.96	0.96	0.96	0.96	0.96	0.63	0.61	0.65	0.61	0.61
	PCA-ON	0.74	0.70	0.80	0.82	0.82	0.52	0.00	0.52	0.00	0.00
Medium Tree	PCA-OFF	0.96	0.96	0.96	0.96	0.96	0.60	0.58	0.63	0.61	0.61
	PCA-ON	0.75	0.82	0.80	0.81	0.81	0.52	0.00	0.52	0.00	0.00
Coarse Tree	PCA-OFF	0.93	0.93	0.93	0.92	0.92	0.58	0.53	0.84	0.94	0.94
	PCA-ON	0.79	0.75	0.82	0.82	0.82	0.52	0.00	0.52	0.00	0.00

Tablo 4.3: Haralick Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	Haralick									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.52	0.00	0.52	0.00	0.00	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Ens. Bagged. Tree	PCA-OFF	0.99	0.1	0.99	0.99	0.99	0.95	0.93	0.97	0.97	0.95
	PCA-ON	0.95	0.92	0.99	0.99	0.95	0.52	0.00	0.52	0.00	0.00
Ens. Subspace. Disc.	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.74	0.76	0.72	0.65	0.70
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Ens. Subspace. KNN.	PCA-OFF	0.96	1.00	0.99	0.99	0.00	0.96	1.00	0.94	0.93	0.96
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Ens. RUSBoosted. Tree	PCA-OFF	0.55	1.00	0.54	0.03	0.06	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.56	1.00	0.54	0.09	0.18	0.52	0.00	0.52	0.00	0.00
SVM Linear	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Quadratic SVM	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Cubic SVM	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.51	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
FineGauss SVM	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.51	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
MediumGauss SVM	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.50	0.00	0.51	0.69	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
CoarseGauss SVM	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.50	0.00	0.51	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Fine KNN	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Medium KNN	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Coarse KNN	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Cosine KNN	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Cubic KNN	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Weighted KNN	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Fine Tree	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.99	1.00	0.99	0.99	0.99
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Medium Tree	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.99	1.00	0.99	0.99	0.99
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00
Coarse Tree	PCA-OFF	0.99	1.00	0.99	0.99	0.99	0.99	1.00	0.98	0.98	0.99
	PCA-ON	0.93	0.88	0.99	0.99	0.93	0.52	0.00	0.52	0.00	0.00

Birinci Mertebe ve İkinci Mertebe (LBP, GLCM, Haralick) manuel özniteliklerine ek olarak, öznitelik setleri, farklı katmanlarda oluşturulan dokudaki gizli özniteliklerin otomatik temsilini sağlayan AlexNet, ResNet, VGGNet, SqueezeNet, Inception-ResNet gibi DL algoritmaları ile elde edilir.

Tablo 4.4: GLCM Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	Second Order Dataset									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.52	0.00	0.52	0.00	0.00	0.73	0.71	0.75	0.73	0.73
	PCA-ON	0.75	0.73	0.77	0.76	0.76	0.52	0.00	0.52	0.00	0.00
Ens. Bagged. Tree	PCA-OFF	0.96	0.98	0.95	0.94	0.94	0.69	0.67	0.72	0.71	0.71
	PCA-ON	0.73	0.70	0.76	0.75	0.75	0.52	0.00	0.52	0.00	0.00
Ens. Subspace. Disc.	PCA-OFF	0.81	0.75	0.92	0.93	0.93	0.56	0.65	0.55	0.16	0.16
	PCA-ON	0.44	0.33	0.47	0.15	0.15	0.52	0.00	0.52	0.00	0.00
Ens. Subspace. KNN.	PCA-OFF	0.95	0.97	0.94	0.93	0.93	0.67	0.66	0.68	0.64	0.64
	PCA-ON	0.73	0.71	0.75	0.74	0.74	0.52	0.00	0.52	0.00	0.00
Ens. RUSBoosted. Tree	PCA-OFF	0.95	0.97	0.94	0.93	0.93	0.71	0.67	0.74	0.74	0.74
	PCA-ON	0.77	0.73	0.81	0.81	0.81	0.52	0.00	0.52	0.00	0.00
SVM Linear	PCA-OFF	0.88	0.95	0.84	0.80	0.80	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.49	0.37	0.51	0.07	0.07	0.51	0.00	0.52	0.00	0.00
Quadratic SVM	PCA-OFF	0.93	0.99	0.90	0.88	0.88	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.42	0.36	0.46	0.26	0.26	0.51	0.00	0.52	0.00	0.00
Cubic SVM	PCA-OFF	0.93	0.94	0.92	0.92	0.92	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.48	0.47	0.51	0.60	0.60	0.51	0.00	0.52	0.00	0.00
FineGauss SVM	PCA-OFF	0.94	1.00	0.90	0.88	0.88	0.50	0.00	0.51	0.00	0.00
	PCA-ON	0.68	0.69	0.67	0.59	0.59	0.51	0.00	0.52	0.00	0.00
MediumGauss SVM	PCA-OFF	0.92	0.99	0.88	0.85	0.85	0.50	0.00	0.51	0.00	0.00
	PCA-ON	0.56	0.53	0.60	0.65	0.65	0.52	0.00	0.52	0.00	0.00
CoarseGauss SVM	PCA-OFF	0.84	0.76	0.96	0.97	0.97	0.51	0.00	0.52	0.00	0.00
	PCA-ON	0.51	0.47	0.52	0.11	0.11	0.52	0.00	0.52	0.00	0.00
Fine KNN	PCA-OFF	0.97	0.97	0.96	0.96	0.96	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.73	0.71	0.75	0.74	0.74	0.52	0.00	0.52	0.00	0.00
Medium KNN	PCA-OFF	0.92	0.94	0.91	0.90	0.90	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.77	0.73	0.81	0.82	0.82	0.52	0.00	0.52	0.00	0.00
Coarse KNN	PCA-OFF	0.82	0.74	0.95	0.96	0.96	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.71	0.76	0.69	0.59	0.59	0.52	0.00	0.52	0.00	0.00
Cosine KNN	PCA-OFF	0.92	0.92	0.92	0.91	0.91	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.47	0.47	0.00	1.00	1.00	0.52	0.00	0.52	0.00	0.00
Cubic KNN	PCA-OFF	0.92	0.93	0.91	0.90	0.90	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.77	0.73	0.81	0.82	0.82	0.52	0.00	0.52	0.00	0.00
Weighted KNN	PCA-OFF	0.94	1.00	0.90	0.88	0.88	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.75	0.72	0.77	0.76	0.76	0.52	0.00	0.52	0.00	0.00
Fine Tree	PCA-OFF	0.95	0.96	0.94	0.93	0.93	0.68	0.67	0.68	0.63	0.63
	PCA-ON	0.72	0.69	0.76	0.76	0.76	0.52	0.00	0.52	0.00	0.00
Medium Tree	PCA-OFF	0.95	0.96	0.94	0.93	0.93	0.67	0.64	0.70	0.69	0.69
	PCA-ON	0.74	0.70	0.79	0.80	0.80	0.52	0.00	0.52	0.00	0.00
Coarse Tree	PCA-OFF	0.95	0.97	0.86	0.82	0.82	0.62	0.58	0.67	0.71	0.71
	PCA-ON	0.73	0.71	0.74	0.72	0.72	0.52	0.00	0.52	0.00	0.00

AlexNet özneteliklerinin sınıflandırma performans ölçümleri **Tablo 4.5:** 'de gösterilmektedir. Bu yöntemle, Veri Kümesi1'de 100% doğruluk, 100% duyarlılık, 100% özgüllük ile en yüksek performans sonuçlarını gözlemlendi.

Tablo 4.5: AlexNet Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	AlexNet									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.52	0.00	0.52	0.00	0.00	0.71	0.67	0.75	0.75	0.71
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.66	0.65	0.66	0.59	0.62
Ens. Bagged. Tree	PCA-OFF	0.94	0.95	0.93	0.92	0.93	0.74	0.71	0.79	0.79	0.74
	PCA-ON	0.99	1.00	0.99	0.99	0.99	0.69	0.67	0.69	0.65	0.66
Ens. Subspace. Disc.	PCA-OFF	0.85	0.85	0.85	0.83	0.84	0.72	0.71	0.73	0.69	0.70
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.58	0.57	0.58	0.45	0.50
Ens. Subspace. KNN.	PCA-OFF	0.99	0.99	0.99	0.99	0.99	0.72	0.70	0.73	0.71	0.70
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.70	0.69	0.70	0.66	0.67
Ens. RUSBoosted. Tree	PCA-OFF	0.52	0.00	0.52	0.00	0.00	0.69	0.65	0.73	0.74	0.69
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.64	0.65	0.64	0.55	0.59
SVM Linear	PCA-OFF	0.92	0.97	0.88	0.85	0.91	0.62	0.60	0.65	0.62	0.61
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.58	0.58	0.58	0.41	0.48
Quadratic SVM	PCA-OFF	0.94	0.97	0.91	0.90	0.93	0.70	0.66	0.73	0.73	0.69
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.60	0.58	0.61	0.54	0.56
Cubic SVM	PCA-OFF	0.96	0.98	0.94	0.94	0.96	0.72	0.69	0.76	0.75	0.72
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.60	0.58	0.61	0.54	0.56
FineGauss SVM	PCA-OFF	0.95	0.96	0.94	0.88	0.92	0.66	0.61	0.74	0.78	0.68
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.57	0.59	0.57	0.34	0.43
MediumGauss SVM	PCA-OFF	0.92	0.96	0.90	0.88	0.92	0.62	0.59	0.66	0.66	0.62
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.52	0.00	0.52	0.00	0.00
CoarseGauss SVM	PCA-OFF	0.85	0.97	0.79	0.72	0.82	0.54	0.52	0.54	0.30	0.38
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.52	0.00	0.52	0.00	0.00
Fine KNN	PCA-OFF	0.96	0.97	0.94	0.94	0.95	0.67	0.64	0.70	0.69	0.66
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.69	0.68	0.70	0.66	0.67
Medium KNN	PCA-OFF	0.87	0.88	0.87	0.85	0.86	0.62	0.57	0.69	0.75	0.65
	PCA-ON	0.99	0.98	1.00	1.00	0.99	0.58	0.56	0.60	0.54	0.55
Coarse KNN	PCA-OFF	0.78	0.91	0.72	0.60	0.72	0.58	0.54	0.67	0.77	0.64
	PCA-ON	0.99	0.98	1.00	1.00	0.99	0.58	0.56	0.60	0.54	0.55
Cosine KNN	PCA-OFF	0.89	0.92	0.87	0.85	0.88	0.58	0.55	0.62	0.63	0.59
	PCA-ON	0.97	0.95	0.99	0.99	0.97	0.58	0.59	0.58	0.38	0.46
Cubic KNN	PCA-OFF	0.85	0.87	0.84	0.80	0.83	0.61	0.57	0.67	0.72	0.63
	PCA-ON	0.99	0.98	1.00	1.00	0.99	0.61	0.59	0.62	0.56	0.58
Weighted KNN	PCA-OFF	0.94	0.96	0.93	0.92	0.94	0.72	0.67	0.79	0.80	0.73
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.69	0.68	0.71	0.67	0.67
Fine Tree	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.68	0.66	0.69	0.66	0.66
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.64	0.62	0.65	0.60	0.61
Medium Tree	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.65	0.62	0.67	0.65	0.63
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.61	0.60	0.62	0.54	0.57
Coarse Tree	PCA-OFF	1.00	1.00	1.00	1.00	1.00	0.57	0.55	0.60	0.58	0.56
	PCA-ON	1.00	1.00	1.00	1.00	1.00	0.61	0.59	0.63	0.59	0.59

VGGNet özniteliklerinin performans sonuçları **Tablo 4.6:** de sunuldu. Burada, VGGNet mimarisinde katman sayısının AlexNet'ten daha yüksek olduğunu, ancak elde ettiğimiz performansın daha düşük olduğunu unutmayalım. Verikümesi1'de VGGNet özellikleriyle %91 doğruluk, %95 duyarlılık, %88 özgüllük ile performans sonuçları gözlemlendi.

Tablo 4.6: VGGNet Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	VGGNet									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.90	0.90	0.91	0.91	0.90	0.52	0.48	0.52	0.19	0.27
	PCA-ON	0.89	0.92	0.87	0.85	0.88	0.50	0.47	0.52	0.39	0.42
Ens. Bagged. Tree	PCA-OFF	0.91	0.95	0.88	0.86	0.90	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.89	0.92	0.86	0.83	0.87	0.49	0.45	0.51	0.36	0.40
Ens. Subspace. Disc.	PCA-OFF	0.79	0.91	0.73	0.61	0.73	0.52	0.33	0.52	0.00	0.01
	PCA-ON	0.73	0.66	0.85	0.88	0.76	0.52	0.00	0.52	0.00	0.00
Ens. Subspace. KNN.	PCA-OFF	0.92	0.86	0.98	0.98	0.92	0.50	0.48	0.68	0.94	0.64
	PCA-ON	0.82	0.76	0.89	0.89	0.82	0.50	0.48	0.70	0.95	0.64
Ens. RUSBoosted. Tree	PCA-OFF	0.87	0.89	0.86	0.83	0.86	0.52	0.49	0.62	0.84	0.62
	PCA-ON	0.88	0.91	0.85	0.82	0.86	0.51	0.49	0.67	0.91	0.64
SVM Linear	PCA-OFF	0.90	0.94	0.88	0.85	0.89	0.51	0.43	0.52	0.10	0.16
	PCA-ON	0.78	0.77	0.79	0.76	0.77	0.49	0.46	0.52	0.55	0.50
Quadratic SVM	PCA-OFF	0.89	0.92	0.87	0.84	0.88	0.52	0.50	0.53	0.27	0.35
	PCA-ON	0.67	0.61	0.78	0.83	0.70	0.52	0.49	0.53	0.29	0.37
Cubic SVM	PCA-OFF	0.90	0.92	0.88	0.85	0.89	0.51	0.43	0.52	0.10	0.17
	PCA-ON	0.50	0.48	0.61	0.87	0.62	0.51	0.48	0.53	0.37	0.42
FineGauss SVM	PCA-OFF	0.90	0.90	0.89	0.88	0.89	0.51	0.00	0.52	0.00	0.00
	PCA-ON	0.74	0.67	0.86	0.89	0.76	0.52	0.00	0.52	0.00	0.00
MediumGauss SVM	PCA-OFF	0.90	0.92	0.89	0.88	0.90	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.53	0.83	0.53	0.02	0.05	0.52	0.00	0.52	0.0	0.00
CoarseGauss SVM	PCA-OFF	0.79	0.89	0.73	0.63	0.74	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.52	0.00	0.52	0.00	0.00
Fine KNN	PCA-OFF	0.86	0.79	0.96	0.96	0.86	0.50	0.48	0.70	0.95	0.64
	PCA-ON	0.81	0.76	0.87	0.87	0.81	0.50	0.48	0.70	0.95	0.64
Medium KNN	PCA-OFF	0.77	0.74	0.81	0.80	0.77	0.49	0.48	0.62	0.92	0.63
	PCA-ON	0.76	0.70	0.84	0.86	0.77	0.49	0.48	0.62	0.92	0.63
Coarse KNN	PCA-OFF	0.72	0.89	0.6	0.47	0.62	0.47	0.47	0.00	1.00	0.64
	PCA-ON	0.66	0.60	0.76	0.81	0.69	0.47	0.47	0.00	1.00	0.64
Cosine KNN	PCA-OFF	0.81	0.79	0.82	0.81	0.80	0.50	0.48	0.57	0.81	0.60
	PCA-ON	0.72	0.67	0.79	0.80	0.73	0.50	0.48	0.57	0.81	0.60
Cubic KNN	PCA-OFF	0.76	0.72	0.80	0.80	0.76	0.49	0.48	0.60	0.92	0.63
	PCA-ON	0.76	0.70	0.83	0.85	0.77	0.49	0.48	0.60	0.92	0.63
Weighted KNN	PCA-OFF	0.80	0.76	0.85	0.85	0.80	0.36	0.47	0.11	0.53	0.50
	PCA-ON	0.82	0.77	0.89	0.90	0.83	0.48	0.47	0.58	0.92	0.63
Fine Tree	PCA-OFF	0.85	0.86	0.84	0.82	0.84	0.51	0.47	0.52	0.14	0.22
	PCA-ON	0.87	0.89	0.85	0.82	0.85	0.50	0.45	0.52	0.29	0.35
Medium Tree	PCA-OFF	0.85	0.87	0.84	0.80	0.84	0.50	0.42	0.51	0.12	0.19
	PCA-ON	0.86	0.88	0.84	0.81	0.85	0.50	0.45	0.52	0.29	0.35
Coarse Tree	PCA-OFF	0.82	0.86	0.79	0.74	0.80	0.49	0.42	0.51	0.18	0.25
	PCA-ON	0.77	0.75	0.79	0.77	0.76	0.50	0.45	0.52	0.18	0.2g6

ResNet özniteliklerinin, sınıflandırma performans ölçümlerini **Tablo 4.7:** de sunuldu. Verikümesi1’ de ResNet öznitelikleri VggNet’den daha yüksek performans sonuçları elde edilirken, AlexNetten daha düşük performans sonuçları gözlemlenmiştir. Verikümesi1’de ResNet ile 93% doğruluk, 98% duyarlılık, 90% özgüllük oranları gözlemlendi.

Tablo 4.7: ResNet Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	ResNet									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.92	0.97	0.89	0.86	0.92	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.91	0.96	0.87	0.84	0.90	0.00	0.00	0.00	0.00	0.00
Ens. Bagged. Tree	PCA-OFF	0.92	0.96	0.90	0.88	0.92	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.90	0.96	0.86	0.83	0.89	0.00	0.00	0.00	0.00	0.00
Ens. Subspace. Disc.	PCA-OFF	0.93	0.98	0.90	0.88	0.92	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.76	0.71	0.83	0.84	0.77	0.00	0.00	0.00	0.00	0.00
Ens. Subspace. KNN.	PCA-OFF	0.73	0.63	0.98	0.99	0.77	0.47	0.47	0.00	1.00	0.64
	PCA-ON	0.62	0.56	0.89	0.95	0.70	0.00	0.00	0.00	0.00	0.00
Ens. RUSBoosted. Tree	PCA-OFF	0.88	0.95	0.83	0.79	0.86	0.47	0.47	0.00	1.00	0.64
	PCA-ON	0.88	0.95	0.84	0.80	0.87	0.00	0.00	0.00	0.00	0.00
SVM Linear	PCA-OFF	0.93	0.98	0.90	0.88	0.93	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.81	0.77	0.86	0.86	0.81	0.00	0.00	0.00	0.00	0.00
Quadratic SVM	PCA-OFF	0.92	0.97	0.88	0.86	0.91	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.86	0.87	0.85	0.83	0.85	0.00	0.00	0.00	0.00	0.00
Cubic SVM	PCA-OFF	0.92	0.97	0.89	0.86	0.92	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.85	0.87	0.84	0.82	0.84	0.00	0.00	0.00	0.00	0.00
FineGauss SVM	PCA-OFF	0.92	0.97	0.89	0.86	0.92	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.76	0.70	0.84	0.86	0.77	0.00	0.00	0.00	0.00	0.00
MediumGauss SVM	PCA-OFF	0.92	0.95	0.90	0.89	0.92	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.55	1.00	0.54	0.05	0.10	0.00	0.00	0.00	0.00	0.00
CoarseGauss SVM	PCA-OFF	0.81	0.91	0.76	0.67	0.78	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.00	0.00	0.00	0.00	0.00
Fine KNN	PCA-OFF	0.84	0.78	0.91	0.92	0.84	0.47	0.47	0.00	1.00	0.64
	PCA-ON	0.61	0.55	0.86	0.94	0.70	0.00	0.00	0.00	0.00	0.00
Medium KNN	PCA-OFF	0.57	0.52	0.75	0.89	0.66	0.47	0.47	0.00	1.00	0.64
	PCA-ON	0.56	0.52	0.72	0.88	0.65	0.00	0.00	0.00	0.00	0.00
Coarse KNN	PCA-OFF	0.75	0.87	0.69	0.55	0.67	0.47	0.47	0.00	1.00	0.64
	PCA-ON	0.75	0.68	0.86	0.88	0.77	0.00	0.00	0.00	0.00	0.00
Cosine KNN	PCA-OFF	0.60	0.54	0.89	0.96	0.69	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.55	0.51	0.71	0.88	0.65	0.00	0.00	0.00	0.00	0.00
Cubic KNN	PCA-OFF	0.56	0.52	0.72	0.88	0.65	0.47	0.47	0.00	1.00	0.64
	PCA-ON	0.55	0.51	0.70	0.87	0.65	0.00	0.00	0.00	0.00	0.00
Weighted KNN	PCA-OFF	0.63	0.56	0.89	0.95	0.71	0.47	0.47	0.00	1.00	0.64
	PCA-ON	0.61	0.55	0.84	0.93	0.69	0.00	0.00	0.00	0.00	0.00
Fine Tree	PCA-OFF	0.86	0.94	0.82	0.76	0.84	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.85	0.89	0.82	0.78	0.83	0.00	0.00	0.00	0.00	0.00
Medium Tree	PCA-OFF	0.72	0.68	0.76	0.76	0.72	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.85	0.89	0.82	0.78	0.83	0.00	0.00	0.00	0.00	0.00
Coarse Tree	PCA-OFF	0.85	0.89	0.82	0.77	0.83	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.80	0.83	0.78	0.75	0.79	0.00	0.00	0.00	0.00	0.00

Tablo 4.8: SqueezeNet öznitelikleriyle elde edilen sınıflandırma sonuçlarını gösterir. Bu yöntem ile, ResNet ve VGGNet'ten daha başarılı ve AlexNet'ten daha az başarılı sonuçlar elde edildi. Verikümesi1'de SqueezeNet özniteliklerini kullanarak %93 doğruluk, %91 duyarlılık, %95 özgüllük sonuçlarını gözlemlendi.

Tablo 4.8: SqueezeNet Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	SqueezeNet									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.93	0.91	0.95	0.94	0.92	0.56	0.54	0.57	0.44	0.48
	PCA-ON	0.90	0.91	0.88	0.86	0.89	0.54	0.52	0.57	0.51	0.52
Ens. Bagged. Tree	PCA-OFF	0.91	0.96	0.88	0.85	0.90	0.51	0.00	0.52	0.00	0.00
	PCA-ON	0.89	0.90	0.88	0.86	0.88	0.56	0.53	0.61	0.66	0.59
Ens. Subspace. Disc.	PCA-OFF	0.85	0.86	0.79	0.72	0.82	0.58	0.59	0.58	0.39	0.47
	PCA-ON	0.76	0.72	0.82	0.82	0.77	0.57	0.58	0.57	0.37	0.45
Ens. Subspace. KNN.	PCA-OFF	0.88	0.84	0.92	0.92	0.88	0.50	0.49	0.62	0.88	0.62
	PCA-ON	0.82	0.78	0.86	0.86	0.82	0.51	0.49	0.65	0.89	0.63
Ens. RUSBoosted. Tree	PCA-OFF	0.91	0.89	0.92	0.92	0.90	0.56	0.54	0.57	0.42	0.48
	PCA-ON	0.89	0.90	0.88	0.86	0.98	0.58	0.52	0.64	0.56	0.54
SVM Linear	PCA-OFF	0.88	0.93	0.85	0.81	0.86	0.49	0.46	0.51	0.39	0.42
	PCA-ON	0.80	0.86	0.77	0.70	0.77	0.51	0.47	0.52	0.33	0.39
Quadratic SVM	PCA-OFF	0.89	0.93	0.86	0.83	0.88	0.52	0.50	0.54	0.36	0.42
	PCA-ON	0.82	0.86	0.79	0.74	0.80	0.53	0.51	0.53	0.22	0.31
Cubic SVM	PCA-OFF	0.86	0.90	0.83	0.80	0.84	0.50	0.45	0.52	0.26	0.33
	PCA-ON	0.85	0.89	0.83	0.79	0.83	0.48	0.45	0.51	0.41	0.43
FineGauss SVM	PCA-OFF	0.90	0.90	0.89	0.88	0.89	0.60	0.62	0.59	0.40	0.49
	PCA-ON	0.76	0.78	0.74	0.69	0.73	0.57	0.58	0.57	0.36	0.45
MediumGauss SVM	PCA-OFF	0.90	0.95	0.87	0.83	0.89	0.54	0.76	0.53	0.05	0.11
	PCA-ON	0.54	0.81	0.53	0.05	0.10	0.52	0.00	0.52	0.00	0.00
CoarseGauss SVM	PCA-OFF	0.80	0.93	0.74	0.63	0.75	0.52	0.00	0.52	0.00	0.00
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.52	0.00	0.52	0.00	0.00
Fine KNN	PCA-OFF	0.84	0.78	0.91	0.92	0.84	0.51	0.49	0.67	0.91	0.64
	PCA-ON	0.80	0.77	0.84	0.83	0.80	0.50	0.49	0.62	0.88	0.62
Medium KNN	PCA-OFF	0.76	0.72	0.80	0.79	0.75	0.50	0.49	0.68	0.93	0.64
	PCA-ON	0.72	0.68	0.76	0.76	0.72	0.51	0.49	0.62	0.88	0.63
Coarse KNN	PCA-OFF	0.73	0.90	0.67	0.50	0.64	0.50	0.48	0.54	0.67	0.56
	PCA-ON	0.67	0.60	0.85	0.91	0.72	0.51	0.48	0.54	0.53	0.51
Cosine KNN	PCA-OFF	0.76	0.71	0.84	0.86	0.77	0.50	0.48	0.60	0.88	0.62
	PCA-ON	0.70	0.65	0.78	0.80	0.72	0.51	0.49	0.62	0.86	0.62
Cubic KNN	PCA-OFF	0.76	0.73	0.80	0.79	0.76	0.50	0.49	0.68	0.93	0.64
	PCA-ON	0.73	0.70	0.77	0.77	0.73	0.50	0.48	0.61	0.87	0.62
Weighted KNN	PCA-OFF	0.83	0.81	0.85	0.83	0.82	0.54	0.51	0.71	0.89	0.65
	PCA-ON	0.82	0.82	0.83	0.80	0.81	0.54	0.51	0.71	0.89	0.65
Fine Tree	PCA-OFF	0.89	0.89	0.88	0.87	0.88	0.57	0.55	0.59	0.51	0.53
	PCA-ON	0.85	0.85	0.85	0.83	0.84	0.58	0.55	0.61	0.60	0.57
Medium Tree	PCA-OFF	0.89	0.89	0.88	0.87	0.88	0.54	0.52	0.55	0.38	0.43
	PCA-ON	0.85	0.87	0.84	0.81	0.84	0.55	0.53	0.57	0.48	0.50
Coarse Tree	PCA-OFF	0.82	0.84	0.81	0.77	0.80	0.59	0.60	0.59	0.45	0.52
	PCA-ON	0.77	0.77	0.77	0.73	0.75	0.54	0.55	0.54	0.26	0.35

Tablo 4.9: de Inception-ResNet öznitelikleri kullanılarak elde edilen ADHD algılama performans ölçütlerini sunuldu. Bu mimari ile, VGGNet, ResNet, SqueezeNet'e göre daha başarılı sınıflandırma performansı elde edilirken, AlexNet'e göre daha düşük performans sonuçları gözlemlendi. Verikümesi1'de Inception-ResNet özelliklerini kullanılarak %98 doğruluk, %96 duyarlılık, %100 özgüllük sonuçları gözlemlendi.


Tablo 4.9: Inception-ResNet Yönteminin Performans Sonuçları

Classification Alg.	PCA Mode	Inception-ResNet									
		DataSet-1 [Selected Slices]					DataSet-2 [All Slices]				
		Acc.	Sens.	Spec.	Prec.	FM.	Acc.	Sens.	Spec.	Prec.	FM.
Ens. Boost. Tree	PCA-OFF	0.97	0.97	0.97	0.97	0.97	0.58	0.64	0.57	0.27	0.39
	PCA-ON	0.95	0.97	0.94	0.93	0.95	0.69	0.67	0.72	0.70	0.68
Ens. Bagged. Tree	PCA-OFF	0.98	0.98	0.99	0.99	0.98	0.68	0.65	0.71	0.70	0.67
	PCA-ON	0.95	0.96	0.94	0.93	0.94	0.71	0.68	0.75	0.75	0.71
Ens. Subspace. Disc.	PCA-OFF	0.95	0.91	0.99	0.99	0.95	0.65	0.64	0.66	0.59	0.61
	PCA-ON	0.72	0.64	0.85	0.89	0.75	0.62	0.60	0.64	0.60	0.60
Ens. Subspace. KNN.	PCA-OFF	0.97	0.95	0.99	0.99	0.97	0.67	0.64	0.69	0.67	0.66
	PCA-ON	0.94	0.95	0.93	0.95	0.95	0.65	0.63	0.67	0.64	0.63
Ens. RUSBoosted. Tree	PCA-OFF	0.97	0.98	0.97	0.97	0.97	0.68	0.67	0.70	0.66	0.66
	PCA-ON	0.92	0.92	0.92	0.91	0.91	0.65	0.61	0.68	0.68	0.64
SVM Linear	PCA-OFF	0.78	0.69	0.95	0.97	0.81	0.65	0.61	0.69	0.69	0.65
	PCA-ON	0.72	0.64	0.87	0.91	0.75	0.63	0.59	0.67	0.67	0.63
Quadratic SVM	PCA-OFF	0.96	0.94	0.98	0.98	0.96	0.64	0.60	0.68	0.68	0.64
	PCA-ON	0.73	0.66	0.85	0.89	0.75	0.64	0.59	0.71	0.76	0.67
Cubic SVM	PCA-OFF	0.96	0.94	0.98	0.98	0.96	0.63	0.61	0.66	0.63	0.62
	PCA-ON	0.75	0.67	0.92	0.94	0.78	0.65	0.61	0.70	0.72	0.66
FineGauss SVM	PCA-OFF	0.96	0.94	0.98	0.98	0.96	0.63	0.61	0.66	0.63	0.62
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.52	0.00	0.52	0.00	0.00
MediumGauss SVM	PCA-OFF	0.96	0.94	0.98	0.98	0.96	0.65	0.73	0.62	0.42	0.54
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.52	0.00	0.52	0.00	0.00
CoarseGauss SVM	PCA-OFF	0.77	0.69	0.92	0.94	0.80	0.65	0.61	0.68	0.67	0.64
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.52	0.00	0.52	0.00	0.00
Fine KNN	PCA-OFF	0.67	0.60	0.83	0.89	0.72	0.65	0.66	0.64	0.54	0.59
	PCA-ON	0.95	0.96	0.93	0.92	0.94	0.68	0.64	0.72	0.72	0.68
Medium KNN	PCA-OFF	0.97	0.95	0.98	0.98	0.97	0.69	0.66	0.72	0.70	0.68
	PCA-ON	0.85	0.84	0.86	0.84	0.84	0.58	0.54	0.64	0.70	0.61
Coarse KNN	PCA-OFF	0.85	0.79	0.92	0.92	0.85	0.61	0.58	0.64	0.63	0.60
	PCA-ON	0.72	0.65	0.85	0.88	0.75	0.57	0.52	0.73	0.88	0.66
Cosine KNN	PCA-OFF	0.83	0.77	0.92	0.93	0.84	0.63	0.59	0.68	0.70	0.64
	PCA-ON	0.00	0.00	0.00	0.00	0.00	0.57	0.53	0.62	0.67	0.60
Cubic KNN	PCA-OFF	0.98	0.96	1.00	1.00	0.97	0.67	0.63	0.71	0.71	0.67
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.67	0.61	0.74	0.78	0.69
Weighted KNN	PCA-OFF	0.86	0.81	0.91	0.91	0.86	0.61	0.58	0.64	0.64	0.61
	PCA-ON	0.52	0.00	0.52	0.00	0.00	0.58	0.55	0.62	0.64	0.59
Fine Tree	PCA-OFF	0.97	0.95	0.98	0.98	0.97	0.67	0.66	0.68	0.64	0.65
	PCA-ON	0.96	0.96	0.95	0.94	0.95	0.67	0.66	0.67	0.61	0.64
Medium Tree	PCA-OFF	0.77	0.69	0.92	0.94	0.80	0.67	0.66	0.68	0.64	0.65
	PCA-ON	0.96	0.96	0.95	0.94	0.95	0.65	0.61	0.68	0.69	0.65
Coarse Tree	PCA-OFF	0.90	0.88	0.91	0.91	0.89	0.62	0.61	0.63	0.56	0.59
	PCA-ON	0.96	0.96	0.95	0.94	0.95	0.65	0.61	0.68	0.69	0.65


Bu deneylerde gözlemlenen sonuçları aşağıdaki gibi özetlenebilir.

- Yalnızca faydalı MR kesitlerini içeren 1. veri kümesinin, 2.veri kümesine göre daha başarılı sınıflandırma performansına sahiptir.
- Birinci Mertebe, İkinci Mertebe (LBP, GLCM ve Haralick) manuel öznitelik çıkartma yöntemlerinde, otomatik öznitelik yönteminde göre daha iyi sınıflandırma performansı gözlemlenmiştir.
- Alexnet ve Inception-ResNet'in diğer DL algoritmalarına göre daha başarılı sınıflandırma performansı gözlemlenmiştir.


Gri ve beyaz maddenin tam ve net görüldüğü dilimleri içeren 1. veri kümesinin karakterize edilmesinde kullanılan algoritmaların doğruluk (Şekil 4.1:), duyarlılık (Şekil 4.2:), özgüllük (Şekil 4.2:), kesinlik (Şekil 4.2:) ve f-ölçütü (Şekil 4.2:) değerleri ayrıca grafiklerde ifade edilmiştir. Bütün dilimleri içeren 2.veri kümesinden elde edilen performans değerlerinin doğruluk (Şekil 4.6:), duyarlılık (Şekil 4.7:), özgüllük (Şekil 4.8:), kesinlik (Şekil 4.9:), ve f-ölçütü (Şekil 4.10:) değerleri ayrıntılı bir şekilde grafiklerde ifade edilmiştir. Bu veri kümesinin karakterize edilmesinde kullanılan ML ve DL yöntemleri ile düşük sınıflandırma sonuçları gözlemlenmiştir.




Şekil 4.1: Doğruluk Oranları [Veri Kümesi 1-PCAOFF]




Şekil 4.2: Duyarlılık Oranları [Veri Kümesi1-PCAOFF]




Şekil 4.3: Özgüllük Oranları [Veri Kümesi1-PCAOFF]




Şekil 4.4: Kesinlik oranları [Veri Kümesi1- PCAOFF]




Şekil 4.5: F-Olcutu Oranları [Veri Kümesi1- PCAOFF]




Şekil 4.6: Doğruluk Oranları [Veri Kümesi2-PCAOFF]




Şekil 4.7: Duyarlılık Oranları [Veri Kümesi2-PCAOFF]



Şekil 4.8: Özgüllük Oranları [Veri Kümesi2-PCAOFF]



Şekil 4.9: Kesinlik Oranları [Veri Kümesi2-PCAOFF]



Şekil 4.10: F-Olcutu Oranları [Veri Kümesi2-PCAOFF]

Bu çalışmada kullanılan sınıflandırıcılar, grafiklerde kısaltılmış harflerle ile belirtilmiştir: Ensemble Boosted Tree (A), Ensemble Bagged Tree (B), Ensemble Subspace Discriminant (C), Ensemble Subspace KNN (D), Ensemble RUSBoosted Tree (E), Linear SVM (F), Quadratic SVM (G), Cubic SVM (H), Fine Gaussian SVM (I), Medium Gaussian SVM (J), Coarse Gaussian SVM (K), Fine KNN (L), Medium KNN (M), Coarse KNN (N), Cosine KNN (O), Cubic KNN (P), Weighted KNN (R), Fine Tree (S), Medium Tree (T), Coarse Tree (U).

4.2. DERİN ÖĞRENME ALGORİTMALARI İLE DENEY SONUÇLARI (YÖNTEM 2)

DEHB Sınıflandırma deneyleri Matlab 2019 8GB RAM, Intel i5-8265U CPU üzerinde gerçekleştirildi. Önerdiğimiz algoritma ile seçilen kesitler CNN ağlarında eğitildi. Öğrenme oranı 0.001 olan, SGD optimizasyonu kullanıldı. Görüntülerin girdi boyutları kullanılan mimariye göre farklılık arz etmesinden dolayı kullanılan mimariye göre veriler tekrar boyutlandırıldı. Örneğin; AlexNet mimarisinde girdi boyutları 227*227*3 iken, SqueezeNet mimarisinde girdi boyutları 224*224*3 olarak belirlendi. Birkaç deneme sonucunda, eğitim aşamasında, hiper parametreler şu şekilde belirlendi. Initial Learning rate 0.001, Momentum 0.9, L2Regularization 1e-4, GradientThresholdMethod L2norm, MaxEpochs 40, MiniBatchSize 128, ValidationFrequency 10, ValidationPatience 8 olarak seçildi.

Bu yöntemde, 1 ve 2. veri kümeleri, ResNet18 (**Tablo 4.11:**), ResNet50 (**Tablo 4.12:**), ResNet101 (**Tablo 4.13:**), VGG-16 (**Tablo 4.14:**), VGG-19 (**Tablo 4.15:**), SqueezeNet (**Tablo 4.16:**) mimarileri ile modelleme sonuçları ile düşük sınıflandırma performansları gözlemlendi. Bütün dilimleri içeren 2. veri kümesinde, AlexNet mimarisi (**Tablo 4.10:**) ile % 90.00 üzerinde doğruluk değerleri gözlemlendi. AlexNet mimarisinden elde edilen yüksek sınıflandırma başarısı, kendi CNN ağını (**Tablo 4.17:**) tasarlarken, bu mimariden yararlanmamıza sebep olmuştur.

Önerilen CNN ağıımız, diğer bir deęişle GulayNet mimarisi, AlexNet mimarisine benzemekle birlikte daha az katman sayısı, daha küçük filtre boyutları, farklı katmanların art arda gelmesi gibi özellikleri ile AlexNet mimarisinden ayrılmaktadır. Katman sayısının azlığı performansta herhangi düşme yaratmamış aksine daha yüksek sınıflandırma başarısı, eğitim süresinde düşme, hızlı çalışma gibi olumlu özelliklere sahiptir. Yüksek sınıflandırma ve beraberinden getirdiğı avantajlı özellikler nedeniyle, DEHB tespitinde tercih edilebilecek bir CNN ağı olması umulmaktadır.

Tablo 4.10: Artırılmış Verinin AlexNet Mimarisi ile Performans Sonuçları

Veri Artırımının AlexNet Mimarisi ile Performans Sonuçları										
DataSet-1 [Specific Slices]						DataSet-2 [All Slices]				
Fold	Epoch	Iteration	T Acc.	V Acc.	T Loss.	V Loss.	T Acc.	V Acc.	T Loss.	V Loss.
Fold1	1	1	52.11	74.65	1.32	0.66	45.07	57.75	1.27	0.82
	10	10	74.65	80.28	0.50	0.42	73.24	83.10	0.62	0.38
	20	20	74.65	80.28	0.50	0.42	85.92	92.96	0.27	0.19
	30	30	78.87	78.87	0.42	0.41	94.37	100.0	0.12	0.09
	40	40	80.28	80.28	0.40	0.38	97.18	100.00	0.07	0.05
Fold2	1	1	59.15	67.61	1.05	0.60	56.34	47.89	1.52	1.06
	10	10	77.46	78.87	0.63	0.42	77.46	84.51	0.52	0.38
	20	20	76.06	80.28	0.42	0.40	88.73	95.77	0.26	0.17
	30	30	80.28	81.69	0.38	0.38	97.18	98.59	0.11	0.06
	40	40	78.87	81.69	0.39	0.37	98.59	98.59	0.03	0.0
Fold3	1	1	47.89	67.61	1.22	1.52	52.11	47.89	1.98	1.98
	10	10	66.20	57.75	0.58	0.55	73.24	80.28	0.62	0.46
	20	20	78.87	77.46	0.47	0.43	87.32	91.55	0.30	0.28
	30	30	81.69	78.87	0.35	0.39	95.77	98.59	0.15	0.09
	40	40	78.87	80.28	0.42	0.38	98.59	100.0	0.06	0.03
Fold4	1	1	59.15	67.61	1.10	0.67	57.75	56.34	1.04	0.64
	10	10	71.83	71.83	0.56	0.54	59.15	70.42	0.67	0.51
	20	20	74.65	78.87	0.46	0.41	94.37	97.18	0.16	0.13
	30	30	69.01	78.87	0.52	0.39	94.37	98.59	0.11	0.03
	40	40	83.10	78.87	0.39	0.39	100.0	100.0	0.01	0.09
Fold5	1	1	49.30	38.03	2.09	0.80	52.11	53.52	1.17	1.43
	10	10	73.24	74.65	0.79	0.51	64.79	81.69	0.63	0.46
	20	20	77.46	77.46	0.43	0.42	85.92	95.77	0.36	0.24
	30	30	77.46	81.69	0.42	0.39	98.59	100.0	0.12	0.06
	40	40	80.28	81.69	0.40	0.36	100.0	100.0	0.03	0.01

Tablo 4.11: Artırılmış Verinin ResNet-18 Mimarisi ile Performans Sonuçları

Veri Artırımının ResNet-18 Mimarisi ile Performans Sonuçları									
DataSet-1 [Specific Slices]					DataSet-2 [All Slices]				
Fold	Epoch	T Acc.	V Acc.	T Loss.	V Loss.	T Acc.	V Acc.	T Loss.	V Loss.
Fold1	1	51.56	52.11	1.36	0.76	41.41	57.75	1.25	0.91
	10	78.91	74.65	0.41	0.55	46.88	54.93	0.85	0.81
	20	82.81	73.24	0.39	0.49	56.25	61.97	0.71	0.76
	30	85.94	73.24	0.29	0.50	60.94	61.97	0.65	0.69
	40	86.72	77.46	0.34	0.49	50.78	59.15	0.81	0.70
Fold2	1	56.25	54.93	0.94	0.66	51.56	53.52	1.02	0.84
	10	76.56	78.87	0.53	0.52	56.25	52.11	0.69	0.75
	20	82.03	76.06	0.40	0.49	50.00	54.93	0.79	0.76
	30	85.94	77.46	0.32	0.50	51.56	54.93	0.80	0.82
	40	82.03	71.83	0.39	0.71	53.13	54.93	0.80	0.88
Fold3	1	38.28	32.39	1.61	0.89	50.00	47.89	1.24	0.88
	10	71.09	76.06	0.46	0.56	53.13	47.89	0.75	0.85
	20	85.94	73.24	0.36	0.46	58.59	53.52	0.72	0.73
	30	85.16	77.46	0.34	0.45	55.47	50.70	0.83	0.78
	40	78.91	73.24	0.39	0.44	50.00	54.93	0.96	0.75
Fold4	1	43.75	46.48	1.84	1.17	39.84	49.30	1.12	0.84
	10	74.22	53.52	0.46	0.68	64.84	53.52	0.73	0.81
	20	78.91	70.42	0.42	0.55	53.91	54.93	0.74	0.70
	30	80.47	71.83	0.41	0.66	50.78	54.93	0.91	0.73
	40	85.16	70.42	0.36	0.56	61.72	57.75	0.68	0.76
Fold5	1	49.22	64.79	1.10	0.72	55.47	42.25	0.84	0.88
	10	73.44	66.20	0.48	0.57	54.69	50.70	0.73	0.76
	20	80.47	73.24	0.40	0.50	47.66	56.34	0.89	0.73
	30	86.72	71.83	0.31	0.58	66.41	56.34	0.60	0.71
	40	84.38	73.24	0.39	0.50	64.06	59.15	0.64	0.68

Tablo 4.12: Artırılmış Verinin ResNet-50 Mimarisi ile Performans Sonuçları

Veri Artırımının ResNet-50 Mimarisi ile Performans Sonuçları									
DataSet-1 [Specific Slices]					DataSet-2 [All Slices]				
Fold	Epoch	T Acc.	V Acc.	T Loss.	V Loss.	T Acc.	V Acc.	T Loss.	V Loss.
Fold1	1	36.72	46.48	0.81	0.69	44.53	52.11	0.93	0.72
	10	76.56	78.87	0.49	0.51	46.09	54.93	0.90	0.69
	20	82.03	52.11	0.41	0.60	61.72	59.15	0.67	0.19
	30	80.47	61.97	0.40	0.54	58.59	59.15	0.74	0.69
	40	78.13	80.28	0.42	0.48	60.16	63.38	0.72	0.63
Fold2	1	57.03	57.75	0.73	0.66	53.91	38.03	0.79	0.88
	10	67.97	73.24	0.65	0.50	60.16	46.48	0.67	0.76
	20	81.25	67.61	0.40	0.54	57.81	53.52	0.71	0.77
	30	83.59	70.42	0.40	0.61	64.06	57.75	0.68	0.74
	40	83.59	74.65	0.34	0.53	61.72	53.52	0.66	0.79
Fold3	1	50.78	70.42	0.96	0.65	45.31	45.25	0.82	0.78
	10	70.31	71.83	0.53	0.52	57.03	54.93	0.76	0.74
	20	78.13	70.42	0.45	0.48	49.22	53.52	0.82	0.80
	30	78.13	78.87	0.43	0.39	57.03	60.56	0.69	0.69
	40	82.81	81.69	0.36	0.37	59.38	64.79	0.71	0.65
Fold4	1	51.56	66.20	0.75	0.67	54.69	57.75	0.75	0.73
	10	78.13	70.42	0.46	0.55	57.03	53.52	0.71	0.75
	20	79.69	76.06	0.44	0.49	59.38	60.56	0.70	0.70
	30	74.22	74.65	0.43	0.47	55.47	57.75	0.73	0.66
	40	83.59	77.46	0.36	0.46	66.41	56.64	0.59	0.63
Fold5	1	67.19	67.61	0.58	0.69	52.34	38.03	0.88	0.83
	10	80.47	60.56	0.50	0.66	52.34	60.56	0.77	0.70
	20	75.00	61.97	0.53	0.66	54.69	54.93	0.71	0.72
	30	83.59	69.01	0.32	0.62	64.06	66.20	0.66	0.68
	40	78.91	56.34	0.40	0.64	57.81	61.97	0.67	0.74

Tablo 4.13: Artırılmış Verinin ResNet-101 Mimarisi ile Performans Sonuçları

Veri Artırımının ResNet-101 Mimarisi ile Performans Sonuçları									
DataSet-1 [Specific Slices]					DataSet-2 [All Slices]				
Fold	Epoch	T Acc.	V Acc.	T Loss.	V Loss.	T Acc.	V Acc.	T Loss.	V Loss.
Fold1	1	48.44	71.83	1.03	0.57	41.41	57.75	1.25	0.91
	10	75.78	81.69	0.50	0.44	46.88	54.93	0.85	0.81
	20	82.81	80.28	0.38	0.37	56.25	61.97	0.71	0.76
	30	82.81	81.69	0.35	0.35	60.94	61.97	0.71	0.76
	40	79.69	77.46	0.39	0.36	50.78	59.15	0.81	0.70
Fold2	1	49.22	50.70	0.96	0.72	51.56	53.52	1.02	0.84
	10	56.25	52.11	0.69	0.85	56.25	52.11	0.69	0.85
	20	79.69	70.42	0.44	0.57	50.00	54.93	0.79	0.76
	30	80.47	66.20	0.40	0.54	51.56	54.93	0.80	0.82
	40	87.50	54.93	0.29	0.55	53.13	54.93	0.80	0.88
Fold3	1	46.88	52.11	0.74	0.69	50.00	47.89	1.24	0.88
	10	71.88	81.69	0.49	0.42	53.13	47.89	0.75	0.85
	20	79.69	57.75	0.42	0.59	58.59	53.52	0.72	0.73
	30	76.56	61.97	0.41	0.58	55.47	50.70	0.83	0.78
	40	82.03	84.51	0.38	0.41	50.00	54.93	0.96	0.75
Fold4	1	47.66	66.20	0.73	0.67	39.84	49.30	1.12	0.84
	10	83.59	76.06	0.39	0.55	64.84	53.52	0.73	0.81
	20	78.91	77.46	0.50	0.52	53.91	54.93	0.74	0.70
	30	82.03	76.06	0.36	0.50	50.78	54.93	0.91	0.73
	40	84.38	78.87	0.34	0.44	61.72	57.75	0.68	0.76
Fold5	1	76.56	80.28	0.50	0.37	55.47	42.25	0.84	0.88
	10	72.66	52.11	0.53	0.67	54.69	50.70	0.73	0.76
	20	79.69	81.69	0.42	0.46	47.66	56.34	0.89	0.73
	30	82.03	77.46	0.38	0.47	66.41	56.34	0.60	0.71
	40	76.56	80.28	0.50	0.37	64.06	59.15	0.64	0.68

Tablo 4.14: Artırılmış Verinin VGG-16 Mimarisi ile Performans Sonuçları

Veri Artırımının VGG-16 Mimarisi ile Performans Sonuçları									
DataSet-1 [Specific Slices]					DataSet-2 [All Slices]				
Fold	Epoch	T Acc.	V Acc.	T Loss.	V Loss.	T Acc.	V Acc.	T Loss.	V Loss.
Fold1	1	56.25	52.11	6.47	7.63	46.09	52.11	8.23	7.63
	10	44.53	47.89	0.69	0.69	58.59	52.11	0.69	0.69
	20	49.22	47.89	0.69	0.69	45.31	52.11	0.69	0.69
	30	44.53	47.89	0.69	0.69	52.34	52.11	0.69	0.69
	40	43.75	47.89	0.69	0.69	48.44	52.11	0.69	0.69
Fold2	1	46.88	52.11	8.42	7.63	53.13	47.89	7.45	8.30
	10	46.88	47.89	0.69	0.69	53.91	47.89	6.38	8.30
	20	45.31	47.89	0.69	0.69	39.06	47.89	8.98	8.30
	30	50.00	47.89	0.69	0.69	38.28	52.11	8.60	7.63
	40	39.06	47.89	0.69	0.69	52.34	52.11	6.70	2.95
Fold3	1	48.44	47.89	8.10	8.30	39.84	52.11	9.45	7.63
	10	41.41	47.89	0.69	0.69	50.78	47.89	0.69	0.69
	20	50.78	47.89	0.69	0.69	48.22	53.52	0.82	0.80
	30	46.09	47.89	0.69	0.69	57.03	60.56	0.69	0.69
	40	43.75	47.89	0.69	0.69	59.38	64.79	0.71	0.65
Fold4	1	50.00	53.52	7.84	7.40	55.47	46.48	6.99	8.53
	10	47.66	46.48	0.69	0.69	53.91	53.52	0.69	0.69
	20	47.66	46.48	0.69	0.69	50.78	53.52	0.69	0.69
	30	48.44	46.48	0.69	0.69	50.00	53.52	0.69	0.69
	40	47.66	46.48	0.69	0.69	49.22	53.52	0.69	0.69
Fold5	1	50.78	49.30	4.64	8.08	44.53	53.52	8.82	7.40
	10	52.34	46.48	0.69	0.69	52.34	60.56	0.77	0.70
	20	51.56	46.48	0.69	0.69	54.69	54.93	0.71	0.72
	30	46.88	46.48	0.69	0.69	64.06	66.20	0.66	0.68
	40	51.56	46.48	0.69	0.69	57.81	61.97	0.67	0.74

Tablo 4.15: Artırılmış Verinin VGG-19 Mimarisi ile Performans Sonuçları

Veri Artırımının VGG-19 Mimarisi ile Performans Sonuçları									
DataSet-1 [Specific Slices]					DataSet-2 [All Slices]				
Fold	Epoch	T Acc.	V Acc.	T Loss.	V Loss.	T Acc.	V Acc.	T Loss.	V Loss.
Fold1	1	32.03	52.11	10.44	7.63	55.47	52.11	7.03	0.63
	10	46.09	47.89	0.69	0.69	55.47	52.11	7.03	7.63
	20	50.00	47.89	0.69	0.69	58.59	52.11	0.68	0.69
	30	47.66	47.89	0.69	0.69	58.59	52.11	0.68	0.69
	40	48.44	47.89	0.69	0.69	45.31	52.11	0.69	0.69
Fold2	1	49.22	52.11	7.41	7.63	51.56	47.89	7.64	8.30
	10	48.44	47.89	0.69	0.69	60.94	52.11	7.34	7.63
	20	48.44	47.89	0.69	0.69	42.19	47.89	8.71	8.30
	30	46.88	47.89	0.69	0.69	55.47	52.11	6.75	8.30
	40	48.44	47.89	0.69	0.69	41.41	52.11	8.66	7.63
Fold3	1	35.16	52.11	10.19	7.63	43.75	52.11	8.76	7.63
	10	43.75	47.89	0.69	0.69	57.03	54.93	0.76	0.74
	20	49.22	47.89	0.69	0.69	49.22	53.52	0.82	0.80
	30	47.66	47.89	0.69	0.69	57.03	60.56	0.69	0.69
	40	47.66	47.89	0.69	0.69	59.38	64.79	0.71	0.65
Fold4	1	52.34	46.48	7.49	8.53	50.00	53.52	7.82	7.40
	10	50.00	46.48	0.69	0.69	46.09	46.48	8.59	8.53
	20	45.31	46.48	0.69	0.69	52.34	53.52	7.59	7.40
	30	45.31	46.48	0.69	0.69	50.78	53.52	7.84	7.40
	40	46.09	46.48	0.69	0.69	40.63	46.48	9.19	4.76
Fold5	1	27.34	53.52	11.38	7.40	50.78	53.52	7.64	7.40
	10	48.44	46.48	0.69	0.69	52.34	60.56	0.77	0.70
	20	43.75	46.48	0.69	0.69	48.44	53.52	8.22	7.40
	30	46.88	46.48	0.69	0.69	53.13	53.52	7.17	7.40
	40	51.56	46.48	0.69	0.69	50.78	53.52	7.35	7.40

Tablo 4.16: Artırılmış Verinin SqueezeNet Mimarisi ile Performans Sonuçları

Veri Artırımının SqueezeNet Mimarisi ile Performans Sonuçları
 DataSet-1 [Specific Slices] DataSet-2 [All Slices]

Fold	Epoch	T Acc.	V Acc.	T Loss.	V Loss.	T Acc.	V Acc.	T Loss.	V Loss.
Fold1	1	43.75	47.89	8.88	8.30	46.88	52.11	8.44	7.63
	10	50.00	47.89	0.69	0.69	42.97	47.89	0.69	0.69
	20	42.97	47.89	0.69	0.69	46.88	47.89	0.69	0.69
	30	41.41	47.89	0.69	0.69	46.88	47.89	0.69	0.69
	40	50.00	47.89	0.69	0.69	50.00	47.89	0.69	0.69
Fold2	1	57.03	52.11	3.05	7.63	42.19	52.11	9.21	7.63
	10	50.00	47.89	0.69	0.69	45.31	47.89	0.69	0.69
	20	46.88	47.89	0.69	0.69	50.00	47.89	0.69	0.69
	30	42.97	47.89	0.69	0.69	47.66	47.89	0.69	0.69
	40	50.00	47.89	0.69	0.69	49.22	47.89	0.69	0.69
Fold3	1	47.66	47.89	7.96	8.30	40.63	52.11	9.35	7.63
	10	47.66	47.89	0.69	0.69	47.66	47.89	0.69	0.69
	20	48.44	47.89	0.69	0.69	51.56	47.89	0.69	0.69
	30	45.31	47.89	0.69	0.69	47.66	47.89	0.69	0.69
	40	45.31	47.89	0.69	0.69	49.22	47.89	0.69	0.69
Fold4	1	48.44	53.52	5.74	7.40	50.00	46.48	7.84	8.53
	10	45.31	46.48	0.69	0.69	49.22	46.48	0.69	0.69
	20	50.78	46.48	0.69	0.69	51.56	46.48	0.69	0.69
	30	42.97	46.48	0.69	0.69	50.00	46.48	0.69	0.69
	40	42.97	46.48	0.69	0.69	49.22	46.48	0.69	0.69
Fold5	1	63.28	53.52	5.43	7.40	46.88	53.52	7.97	7.40
	10	48.44	46.48	0.69	0.69	40.63	46.48	0.69	0.69
	20	50.00	46.48	0.69	0.69	45.31	46.48	0.69	0.69
	30	49.22	46.48	0.69	0.69	46.09	46.48	0.69	0.69
	40	50.00	46.48	0.69	0.69	53.13	46.48	0.69	0.69

Tablo 4.17: Artırılmış Verinin Önerilen CNN Ağı ile Performans Sonuçları

Veri Artırımının Önerilen Mimari ile Performans Sonuçları									
DataSet-1 [Specific Slices]					DataSet-2 [All Slices]				
Fold	Epoch	T Acc.	V Acc.	T Loss.	V Loss.	T Acc.	V Acc.	T Loss.	V Loss.
Fold1	1	47.89	52.11	5.18	7.64	46.48	52.11	3.65	7.63
	10	52.11	60.56	0.58	0.53	77.46	95.77	0.43	0.08
	20	54.93	60.56	0.57	0.54	76.06	95.77	0.29	0.07
	30	56.34	60.56	0.58	0.54	84.51	95.77	0.22	0.07
	40	53.52	70.42	0.57	0.52	87.32	95.77	0.18	0.07
Fold2	1	53.52	52.11	4.38	7.63	56.34	56.34	3.77	6.44
	10	71.83	76.06	0.58	0.55	80.28	97.18	0.24	0.05
	20	67.61	76.06	0.61	0.58	88.73	98.59	0.17	0.04
	30	67.61	76.06	0.57	0.54	85.92	98.59	0.19	0.04
	40	71.83	76.06	0.54	0.51	87.32	98.59	0.16	0.04
Fold3	1	56.34	52.11	3.93	7.63	56.34	54.93	2.43	6.45
	10	66.20	71.83	0.61	0.57	81.69	94.37	0.30	0.12
	20	64.79	73.24	0.58	0.55	83.10	95.77	0.21	0.07
	30	70.42	73.24	0.56	0.53	83.10	95.77	0.23	0.06
	40	61.97	73.24	0.53	0.51	84.51	95.77	0.21	0.05
Fold4	1	45.07	46.48	3.57	8.53	43.66	53.52	4.10	7.40
	10	40.85	53.52	0.69	0.69	73.24	92.96	0.46	0.46
	20	46.48	53.52	0.69	0.69	83.10	95.77	0.47	0.43
	30	50.15	53.52	0.69	0.69	85.92	98.59	0.34	0.24
	40	59.15	53.52	0.69	0.69	90.14	98.59	0.27	0.14
Fold5	1	46.48	53.52	4.60	7.40	54.93	59.15	2.37	2.39
	10	71.83	80.28	0.53	0.45	81.69	95.77	0.28	0.07
	20	77.46	81.69	0.45	0.40	85.92	100.0	0.22	0.02
	30	70.42	81.69	0.46	0.38	87.32	100.0	0.81	0.02
	40	70.42	81.69	0.48	0.37	85.92	100.0	0.17	0.01

5. TARTIŞMA VE SONUÇLAR

5.1. TARTIŞMA

Hastalıkların teşhisinde sağlam ve güvenilir modellerin oluşturulması önemlidir. Modelin güvenli olmasının şartlarından biri de yüksek doğruluklu değere sahip olmasıdır. [47], [50], [81], [36], [49], [52], [48] çalışmaslarındaki modellerin %75 in altında bir değere sahiptir. [46] de, dengesiz bir veri kümesi (234 DEHB ve 403 sağlıklı birey) oluşturularak modelin sağlamlığı gölgelenmiştir [82]. DEHB nöropsikiyatrik bir hastalıktır. Birçok çalışmada, DEHB’li bireylerin beyinlerinde, sağlıklı bireylere göre farklılık göstermiştir. Bu amaçla, çalışmamızda, yapısal MR verileri kullanılmıştır. Yapısal MR verileri kesitlerden oluşmaktadır. Kesitlerin DEHB modelindeki etkisini belirlemek amacıyla, yapısal MR verilerinin bütün kesitlerini içeren bir veri kümesi ile önerdiğimiz algoritma ile tespit edilen gri ve beyaz maddeleri tam ve net görüntüleri içeren başka bir veri kümesi oluşturularak, iki ayrı veri kümesi oluşturulmuştur. Bu iki ayrı veri kümesi yöntem1 de, DEHB tespit modeli için şu şekildeki aşamalardan geçerek modeller oluşturulmuştur. Her veri kümesinin karakterize edecek en iyi öznitelikler kümesini tespit amacıyla, hem ML hem de DL algoritmalarından yararlanılmıştır. Bu yöntemler ile elde edilen 9 ayrı öznitelikler kümesi, hem tekil hem de çoğul sınıflandırma algoritmalarına girdi verilerek, DEHB sınıflandırma modelleri oluşturulmuştur. Modellerin performans tespiti için 10 kat çapraz geçişleme kullanılmıştır. Buna ek olarak, her modelin doğruluk, duyarlılık, özgüllük, kesinlik ve f-ölçütü değerleri hesaplanmıştır. Deney sonuçlarımıza göre, Verikümesi1’in karakterize edilmesinde, Birinci Mertebe ve İkinci Mertebe (GLCM, LBP, Haralick) başarılı sonuçlar verdiği gözlemlenmiştir. ML algoritmalarını takiben ayrıca, AlexNet, Inception-ResNet gibi DL mimarilerinde de veri kümesi1’i karakterize edilmesinde yüksek sınıflandırma sonuçları gözlemlendi.

Tablo **Tablo 5.1:** da DEHB tespiti için geliştirilen modellerin ve bu çalışmada önerdiğimiz

Tablo 5.1: Mevcut Benzer Çalışmalarla Karşılaştırma

Ref	Participants	Sources	Feature Extraction	Classifiers	ACC
[37]	1394 (482 ADHD, 912 HC)	sMRI, fMRI	LEFM Learner	SVM	67.00%
[47]	3337 (1393 ADHD, 1984 HC)	sMRI	PFFA	EL	67.00%
[50]	776 (490 HC, 279 ADHD)	sMRI, fMRI	Deep Learning Meth.	SVM, KNN, LDA	74.93%
[81]	1083 (251 ADHD, 832 Cotrol)	fMRI	Deep Learning Meth.	EM-MI	70.40%
[46]	637 (234 ADHD, 403 HC)	fMRI	StockWell Transform	SVM	96.68%
[33]	117(67 ADHD, 50 HC)	sMRI	Fscore, SFS	ELM, SVM	90.18%
[36]	446 (210 ADHD, 226 HC)	sMRI	LBP-TOB	SVM	69.00%
[49]	947 (362 ADHD, 585 HC)	sMRI	Housdorff fractal dimension	3-D CNN	69.01%
[83]	39 (25 ADHD, 14 HC)	EEG	Deep Learning Meth.	3-D CNN	99.46%
[52]	468 (236 ADHD, 232 HC)	fMRI	Deep Learning Meth.	3-D CNN	73.1%
[48]	788 (359 ADHD, 429 HC)	fMRI	Deep Learning Meth	CNN + LSTM, 4D CNN	71.30%
[84]	788 (118 ADHD, 98 HC)	fMRI	Deep Learning Meth	Graph Kernel Prin. Comp.	94.91%
[43]	108 (70 ADHD, 38 HC)	EEG	TFHA	SVM	100.00%
[45]	72 (36 ADHD, 36 HC)	fMRI, MRI	Biomarkers with FreeSuffer	Bagging-based ELT	81.00%
[58]	871(451 ADHD, 420 HC)	fMRI	Deep Learning	2D CNN-LSTM	97.50%
[42]	61(31 ADHD, 30 HC)	EEG	Alfa,Beta, Theta	13 Layer CNN	98.48%
OurMeth.	355 (168 ADHD, 187 HC)	sMRI	Hand and Deep Feat.	Single and Ensemble	100.0%

yöntemin özeti niyetinde denek sayısı, öznelilik çıkartma yöntemleri ve sınıflandırıcılar gibi bazı parametreler verilmiştir. Tablo **Tablo 5.1:** de görüldüğü gibi, hem manuel hem de otomatik derin öznelilik çıkartma yöntemleri kullanan tek ve topluluk sınıflandırma algoritmalarından yararlanılarak önerilen yaklaşımız, dengeli bir veri kümesinde üstün sınıflandırma performansı ile sonuçlandı.

Tablo 5.2: Algoritmaların Ortalama Performans Sonuçları [VeriKümesi1-PCAOFF]

Average Performance Results of All Algorithm DataSet-1 [Selected Slices - PCA OFF]					
Feature Extracton Alg.	Acc.	Sens.	Spec.	Prec.	FM.
LBP	94	89	95	90	89
Haralick	94	95	94	89	89
AlexNet	92	85	86	79	82
VggNet	84	86	84	80	82
ResNet	80	81	85	84	81
SqueezeNet	84	86	84	81	83
InceptionResNet	88	85	94	95	89
En başarılı üç algoritma kalın-turuncu renkle belirtilmiştir					

Özellikle, LBP, Haralick, AlexNet yöntemleri ile oluşturulan modellerden %90.0 ve üzeri performans sonuçları elde edildi. **Tablo 5.2:** de 1. veri kümesinin bütün algoritmaların ortalama doğruluk, duyarlılık, kesinlik ve f-ölçütü değerlerini ifade etmektedir.

Diğer taraftan bütün dilimleri içeren 2. verikümesi ile modellerin bütün algoritmalarındaki ortalama performansı (**Tablo 5.3:**) %70 lere dahi erişemiştir. Karanlık, bilgi barındırmayan bu dilimler, veri kümesindeki gürültüler olarak adlandırıldığından, 1. veri kümesindeki üstün performans sonuçlarını bu veri kümesinde görelmemektedir.

Tablo 5.3: Algoritmaların Ortalama Performans Sonuçları [Verikümesi2-PCAOFF]

Average Performance Results of All Algorithm
DataSet-1 [Selected Slices - PCA OFF]

Feature Extractor Alg.	Acc.	Sens.	Spec.	Prec.	FM.
LBP	65	63	67	62	62
Haralick	28	64	64	27	27
AlexNet	62	65	69	68	64
VggNet	36	49	50	40	48
ResNet	36	49	50	40	48
SqueezeNet	47	53	58	50	45
InceptionResNet	62	64	66	60	61

İkinci yöntemde, bu iki ayrı veri kümesi, DEHB tespit modeli için şu şekildeki aşamalardan geçmiştir. Çevirim içi veri artırım teknikleri ile veri artırılmıştır. Her iki veri kümesinin (verikümesi1, verikümesi2) karakterize edilmesi için, AlexNet, ResNet, VGGNet ve SqueezeNet mimari ile modellenmiştir. Buna ilaveten, DL mimarilerinin performans sonuçlarına göre, kendi CNN ağımızın tasarımı belirlenmiştir. İkinci veri kümesinin karakterize edilmesinde başarılı sınıflandırma performansına sahip AlexNet mimarisi, önerilen CNN mimarisinde esinlendiğimiz bir klasik DL mimarisidir. Önerilen CNN ağı ile, daha az katmana sahip olan ağ, daha kısa sürede eğitilmekte, hesaplama maliyeti az ve daha yüksek sınıflandırma performansına sahiptir. ML mimarilerinin aksine, DL mimarileri daha yüksek sınıflandırma performansı için kilit faktör daha kompleks yapıların kullanılmasına bağlıdır. Daha basit mimari ile bu kompleks yapı kullanılmadığı zannının aksine, verilen girdi kompleks yapıyı destekler durumdadır. Daha az bilgi barındıran, birinci yöntemde ifade ettiğimiz gürültülü dilimler, burada gürültüden ziyade, girdinin tam olarak anlaşılması için gerekli bileşenlerdendir. Dolayısıyla, modelin ifade etmede kullanacağımız girdinin çok iyi belirlenmesi, daha basit mimari tasarlayarak, daha başarılı sınıflandırma performanslarına elde edeceğimizi göstermektedir.

5.2. SONUÇLAR

DEHB, çocuklukta başlayan ve doğru teşhis edilip tedavi edilmediği takdirde ömür boyu sürebilen nörogelişimsel bir bozukluktur. Sağlık uzmanları, DEHB'yi teşhis etmek

için birçok test gerçekleştirir. Klinik görüşmede yer almayan DEHB belirtileri, DEHB derecelendirme ölçekleri ile tespit edilir. Zeka testleri ile bireylerin IQ düzeyleri ve öğrenme güçlükleri belirlenir. Geniş spektrumlu ölçekler ile sosyal, duygusal ve psikiyatrik sorunları ele alınır. Dil gelişimi, hafıza durumu, motor becerilerini ölçmeye yönelik bazı özel testler yapılır. Bu testlerin gerçekleştirilmesi ve değerlendirilmesi uzun zaman alır. Buna ilaveten, testler farklı zamanlarda tekrarlandığında farklı sonuçlar vermektedir. Bu durum yanlış teşhise neden olur. Fiziksel hastalıklar gibi psikiyatrik hastalıkların teşhisinde objektif ve sağlam araçların geliştirilmesi gerekmektedir. Pek çok psikiyatrik hastalığın tanısında nörogörüntüleme çalışmalarının önemi yadsınamaz. DEHB olan bireylerin beyin dokusunda, yapısal değişiklikler olduğuna dair birçok çalışma vardır. DEHB'li bireylerin gri cevher hacminde azalma, kortikal kalınlıkta incelme ve prefrontal korteks, bazal gangliyonlar, serebellum ve parieto-temporal bölgelerde azalmış hacimlere sahip oldukları bulunmuştur. Bu çalışmada, birçok psikiyatrik hastalıklarda önemli bir parametre olarak kabul edilen gri ve beyaz cevher parametresi dikkate alınmıştır. Çalışmamızda, NPIstanbul NöroPsikiyatri hastanesi ile erişimi herkese açık olan DEHB-200 veri tabanından alınan yapısal MR verileri kullanılarak bir DEHB tespit modeli sunuyoruz. Yapısal MR kesitlerden oluşmaktadır. Gri ve beyaz maddenin tam ve net görüldüğü dilimlerin DEHB tespit modelinde katkı seviyesini ölçmek amacıyla, iki farklı verikümesi oluşturuldu; verikümesi1 ve verikümesi2. İkinci veri seti, elde edilen sMRI verilerinin tüm dilimlerini içerirken ve birinci veri seti, önerilen bir algoritma tarafından seçilen faydalı doku bilgisine sahip diğer bir değişle gri ve beyaz maddenin tam ve net görüldüğü dilimleri içermektedir. Bu veri kümelerinin karakterize edilmesinde, hem ML (Birinci Mertebe ve İkinci Mertebe istatistiksel öznitelikler) hem de DL (AlexNet, VGGNet, ResNet, SqueezeNet ve Inception-ResNet mimarileri) özellik çıkarma yöntemleri kullanılmıştır. Modeller, Matlab ortamında geliştirilmiştir. Örneklerden oluşan tam eğitim veri seti üzerinde deneyler gerçekleştirildi ve rastgele örnekleme, eğitim ve test için 10 kat Çapraz Doğrulama benimsendi. Bu çalışmada modellerin performansını değerlendirmek için doğruluk, duyarlılık, özgüllük ve kesinlik ve f-ölçütü hesaplanmıştır. DEHB tanı modelinde önerilen yöntemle seçilen dilimlerin başarısı hem ML hem de DL algoritmalarında başarılı sonuçlar vermiştir. En etkili model % 100.00 doğrulukla

LBP öznitelik çıkarma yöntemi ile elde edilmiştir. Çalışmamız, önerdiğimiz algoritma ile seçilen yararlı doku bilgilerini içeren sMRI dilimlerinin, otomatik tanı destek sistemleri için DEHB algılama modelleri oluşturmak için başarıyla kullanılabileceğini göstermektedir. Bu belirtilen sonuçlar, DEHB tespit için sunduğumuz methodolojilerden ilkinin oluşturmaktadır. İkinci yöntemde ise, çevirim içi veri artırım yöntemleri ile sentetik veriler oluşturulmuştur. Veriler, AlexNet, ResNet (18,50,101), VggNet (16,19) ve SqueezeNet mimarile ile modellenmiştir. İkinci veri kümesinin karakterize edilmesinde kullanılan 25 katmanlı AlexNet mimarisi ile başarılı sınıflandırma sonuçları elde edilmiştir. Bu mimariden elde edilen yüksek sınıflandırma performansı, kendi CNN ağımızın tasarlanmasında, örnek teşkil etmiştir. Bu nedenle, önerilen CNN mimarisi, AlexNet mimarisine benzemekle birlikte, kullanılan katman sayılarının azlığı, katmanların farklı sırada kullanılması, farklı boyutlarda filtre boyutlarının kullanılması gibi özellikler yönüyle ayrılmaktadır. Bu özellikler, önerilen CNN mimarisinin hesaplama maliyetinin düşük, eğitim süresinin daha kısa ve daha yüksek sınıflandırma performansı gibi avantajlara sahip olmasını sağlamaktadır. Sonuç olarak, DEHB tespit modeli için öne sürülen yöntemler, çeşitli yöntemlerin karşılaştırmalı sonuçları ve elde edilen yüksek başarılı sınıflandırma performansı gibi özellikler nedeniyle, bu alanda, literatüre önemli katkılarda bulunması nedeniyle, önemli bir tez çalışmasıdır.

KAYNAKLAR

- [1]. Anita Thapar, Miriam Cooper, and Michael Rutter. Neurodevelopmental disorders. *The Lancet Psychiatry*, 4(4):339–346, 2017.
- [2]. Dong Hyun Ahn. Introduction: neurodevelopmental disorders. *Hanyang Medical Reviews*, 36(1), 2016.
- [3]. Rita Vadalà, Elisabetta Giugni, Anna Pichiecchio, Umberto Balottin, and Stefano Bastianello. Attention deficit hyperactivity disorder (adhd): from a childhood neuropsychiatric disorder to an adult condition. *Functional neurology*, 26(3):117, 2011.
- [4]. Erlend Joramo Brevik, Astri J Lundervold, Jan Haavik, and Maj-Britt Posserud. Validity and accuracy of the adult attention-deficit/hyperactivity disorder (adhd) self-report scale (asrs) and the wender utah rating scale (wurs) symptom checklists in discriminating between adults with and without adhd. *Brain and behavior*, 10(6):e01605, 2020.
- [5]. Ditte Demontis, Raymond K Walters, Joanna Martin, Manuel Mattheisen, Thomas D Als, Esben Agerbo, Gísli Baldursson, Rich Belliveau, Jonas Bybjerg-Grauholm, Marie Bækvad-Hansen, et al. Discovery of the first genome-wide significant risk loci for attention deficit/hyperactivity disorder. *Nature genetics*, 51(1):63–75, 2019.
- [6]. Susan D Mayes, Susan L Calhoun, and Daniel A Waschbusch. Sluggish cognitive tempo in autism, adhd, and neurotypical child samples. *Research in Autism Spectrum Disorders*, 79:101678, 2020.
- [7]. Patricia O Quinn and Manisha Madhoo. A review of attention-deficit/hyperactivity disorder in women and girls: uncovering this hidden diagnosis. *The primary care companion for CNS disorders*, 16(3), 2014.
- [8]. Ewald Moser, Andreas Stadlbauer, Christian Windischberger, Harald H Quick, and Mark E Ladd. Magnetic resonance imaging methodology. *European journal of nuclear medicine and molecular imaging*, 36(1):30–41, 2009.
- [9]. Björn Bonath, Jana Tegelbeckers, Marko Wilke, Hans-Henning Flechtner, and Kerstin Krauel. Regional gray matter volume differences between adolescents with adhd and typically developing controls: further evidence for anterior cingulate involvement. *Journal of attention disorders*, 22(7):627–638, 2018.
- [10]. Luis Guillermo Almeida Montes, Hugo Prado Alcántara, Reyna Beatriz Martínez García, Lázaro Barajas De La Torre, David Avila Acosta, and Martín Gallegos Duarte. Brain cortical thickness in adhd: age, sex, and clinical correlations. *Journal of Attention Disorders*, 17(8):641–654, 2013.
- [11]. F Xavier Castellanos, Patti P Lee, Wendy Sharp, Neal O Jeffries, Deanna K Greenstein, Liv S Clasen, Jonathan D Blumenthal, Regina S James, Christen L Ebens, James M Walter, et al.

- Developmental trajectories of brain volume abnormalities in children and adolescents with attention-deficit/hyperactivity disorder. *Jama*, 288(14):1740–1748, 2002.
- [12]. Eve M Valera, Stephen V Faraone, Kate E Murray, and Larry J Seidman. Meta-analysis of structural imaging findings in attention-deficit/hyperactivity disorder. *Biological psychiatry*, 61(12):1361–1369, 2007.
- [13]. Sarah Durston, Hilleke E Hulshoff Pol, Hugo G Schnack, Jan K Buitelaar, Mark P Steenhuis, Ruud B Minderaa, René S Kahn, et al. Magnetic resonance imaging of boys with attention-deficit/hyperactivity disorder and their unaffected siblings. *Journal of the American Academy of Child & Adolescent Psychiatry*, 43(3):332–340, 2004.
- [14]. Wendy R Kates, Melissa Frederikse, Stewart H Mostofsky, Bradley S Folley, Karen Cooper, Patricia Mazur-Hopkins, Ora Kofman, Harvey S Singer, Martha B Denckla, Godfrey D Pearlson, et al. Mri parcellation of the frontal lobe in boys with attention deficit hyperactivity disorder or tourette syndrome. *Psychiatry Research: Neuroimaging*, 116(1-2):63–81, 2002.
- [15]. Anqi Qiu, Deana Crocetti, Marcy Adler, E Mark Mahone, Martha B Denckla, Michael I Miller, and Stewart H Mostofsky. Basal ganglia volume and shape in children with attention deficit hyperactivity disorder. *American Journal of Psychiatry*, 166(1):74–82, 2009.
- [16]. PK Douglas, Boris Gutman, Ariana Anderson, C Larios, Katherine E Lawrence, Katherine Narr, Biswa Sengupta, Gerald Cooray, David B Douglas, Paul M Thompson, et al. Hemispheric brain asymmetry differences in youths with attention-deficit/hyperactivity disorder. *NeuroImage: Clinical*, 18:744–752, 2018.
- [17]. Pauline A Filipek, M Semrud-Clikeman, RJ Steingard, PF Renshaw, DN Kennedy, and J Biederman. Volumetric mri analysis comparing subjects having attention-deficit hyperactivity disorder with normal controls. *Neurology*, 48(3):589–601, 1997.
- [18]. Garrett E Alexander, Mahlon R DeLong, and Peter L Strick. Parallel organization of functionally segregated circuits linking basal ganglia and cortex. *Annual review of neuroscience*, 9(1):357–381, 1986.
- [19]. Catherine J Stoodley. Distinct regions of the cerebellum show gray matter decreases in autism, adhd, and developmental dyslexia. *Frontiers in systems neuroscience*, 8:92, 2014.
- [20]. Sanne te Meerman, Laura Batstra, Justin E Freedman, Rink Hoekstra, and Hans Grietens. Adhd and brain anatomy: What do academic textbooks used in the netherlands tell students? *Children & society*, 34(2):136–150, 2020.
- [21]. Lilia Lazli, Mounir Boukadoum, and Otmame Ait Mohamed. A survey on computer-aided diagnosis of brain disorders through mri based on machine learning and data mining methodologies with an emphasis on alzheimer disease diagnosis and the contribution of the multimodal fusion. *Applied Sciences*, 10(5):1894, 2020.
- [22]. Matthew S Brown, Richard Pais, Peiyuan Qing, Sumit Shah, Michael F McNitt-Gray, Jonathan G Goldin, Iva Petkovska, Lien Tran, and Denise R Aberle. An architecture for computer-aided detection and radiologic measurement of lung nodules in clinical trials. *Cancer Informatics*, 4:117693510700400001, 2007.

- [23]. Valerie A Harpin. The effect of adhd on the life of an individual, their family, and community from preschool to adult life. *Archives of disease in childhood*, 90(suppl 1):i2–i7, 2005.
- [24]. Melis İpçi, Sevim Berrin İnci İzmir, Mehmet Hakan Türkçapar, Kadir Özdel, Ülkü Akyol Ardiç, and Eyüp Sabri Ercan. Dsm-iv’e göre dikkat eksikliği hiperaktivite bozukluğu (dehb) olan çocuk ve ergenlerde dehb alt tiplerinde psikiyatrik eş tanı varlığı. 2020.
- [25]. Derin Çocuk Otizm Rehabilitasyon Merkezi. Dikkat eksikliği, Hiperaktivite bozukluğu ve Dehb istatistikleri, howpublished=<https://derincocuk.com/dehb-dikkat-eksikligi-ve-hiperaktivite-bozuklugu-istatistikleri/>, note= Accessed: 2021-03-21.
- [26]. Michelle Kilpatrick Demaray, Katherine Schaefer, and Lauren K Delong. Attention-deficit/hyperactivity disorder (adhd): A national survey of training and current assessment practices in the schools. *Psychology in the Schools*, 40(6):583–597, 2003.
- [27]. AP American Psychiatric Association, American Psychiatric Association, et al. Diagnostic and statistical manual of mental disorders: Dsm-5, 2013.
- [28]. Steven Pliszka, AACAP Work Group on Quality Issues, et al. Practice parameter for the assessment and treatment of children and adolescents with attention-deficit/hyperactivity disorder. *Journal of the American Academy of Child & Adolescent Psychiatry*, 46(7):894–921, 2007.
- [29]. CM Maheshan and H Prasanna Kumar. Performance of image pre-processing filters for noise removal in transformer oil images at different temperatures. *SN Applied Sciences*, 2(1):1–7, 2020.
- [30]. Fengxi Song, Zhongwei Guo, and Dayong Mei. Feature selection using principal component analysis. In *2010 international conference on system science, engineering design and manufacturing informatization*, volume 1, pages 27–30. IEEE, 2010.
- [31]. Ani Eloyan, John Muschelli, Mary Beth Nebel, Han Liu, Fang Han, Tuo Zhao, Anita D Barber, Suresh Joel, James J Pekar, Stewart H Mostofsky, et al. Automated diagnoses of attention deficit hyperactive disorder using magnetic resonance imaging. *Frontiers in systems neuroscience*, 6:61, 2012.
- [32]. Dai Dai, Jieqiong Wang, Jing Hua, and Huiguang He. Classification of adhd children through multimodal magnetic resonance imaging. *Frontiers in systems neuroscience*, 6:63, 2012.
- [33]. Xiaolong Peng, Pan Lin, Tongsheng Zhang, and Jue Wang. Extreme learning machine-based classification of adhd using brain structural mri data. *PloS one*, 8(11):e79476, 2013.
- [34]. Matthew RG Brown, Gagan S Sidhu, Russell Greiner, Nasimeh Asgarian, Meysam Bastani, Peter H Silverstone, Andrew J Greenshaw, and Serdar M Dursun. Adhd-200 global competition: diagnosing adhd using personal characteristic data can outperform resting state fmri measurements. *Frontiers in systems neuroscience*, 6:69, 2012.
- [35]. Rubi Hammer, Gillian E Cooke, Mark A Stein, and James R Booth. Functional neuroimaging of visuospatial working memory tasks enables accurate detection of attention deficit and hyperactivity disorder. *NeuroImage: Clinical*, 9:244–252, 2015.

- [36]. Che-Wei Chang, Chien-Chang Ho, and Jyh-Horng Chen. Adhd classification by a texture analysis of anatomical brain mri data. *Frontiers in systems neuroscience*, 6:66, 2012.
- [37]. Bhaskar Sen, Neil C Borle, Russell Greiner, and Matthew RG Brown. A general prediction model for the detection of adhd and autism using structural and functional mri. *PloS one*, 13(4):e0194856, 2018.
- [38]. Tony W Wilson, John D Franzen, Elizabeth Heinrichs-Graham, Matthew L White, Nichole L Knott, and Martin W Wetzel. Broadband neurophysiological abnormalities in the medial prefrontal region of the default-mode network in adults with adhd. *Human Brain Mapping*, 34(3):566–574, 2013.
- [39]. Lucina Q Uddin, AM Clare Kelly, Bharat B Biswal, Daniel S Margulies, Zarrar Shehzad, David Shaw, Manely Ghaffari, John Rotrosen, Lenard A Adler, F Xavier Castellanos, et al. Network homogeneity reveals decreased integrity of default-mode network in adhd. *Journal of neuroscience methods*, 169(1):249–254, 2008.
- [40]. Hartmut Heinrich, Hartmut Dickhaus, Aribert Rothenberger, Verena Heinrich, and Gunther H Moll. Single-sweep analysis of event-related potentials by wavelet networks-methodological basis and clinical application. *IEEE Transactions on Biomedical Engineering*, 46(7):867–879, 1999.
- [41]. Atif Riaz, Muhammad Asad, Eduardo Alonso, and Greg Slabaugh. Fusion of fmri and non-imaging data for adhd classification. *Computerized Medical Imaging and Graphics*, 65:115–128, 2018.
- [42]. Majid Moghaddari, Mina Zolfy Lighvan, and Sebelan Danishvar. Diagnose adhd disorder in children using convolutional neural network based on continuous mental task eeg. *Computer Methods and Programs in Biomedicine*, 197:105738, 2020.
- [43]. Hüseyin Öztoprak, Mehmet Toycan, Yaşar Kemal Alp, Orhan Arıkan, Elvin Doğutepe, and Sirel Karakaş. Machine-based classification of adhd and nonadhd participants using time/frequency features of event-related neuroelectric activity. *Clinical Neurophysiology*, 128(12):2400–2410, 2017.
- [44]. Li Zhu, Liying Zhang, Yuntao Han, Quan Zeng, and Weike Chang. Study of attention deficit/hyperactivity disorder classification based on convolutional neural networks. *Sheng wu yi xue gong cheng xue za zhi= Journal of biomedical engineering= Shengwu yixue gongchengxue zazhi*, 34(1):99–105, 2017.
- [45]. Yuyang Luo, Tara L Alvarez, Jeffrey M Halperin, and Xiaobo Li. Multimodal neuroimaging-based prediction of adult outcomes in childhood-onset adhd using ensemble learning techniques. *NeuroImage: Clinical*, 26:102238, 2020.
- [46]. Shadi Sartipi, Hashem Kalbkhani, Peyman Ghasemzadeh, and Mahrokh G Shayesteh. Stockwell transform of time-series of fmri data for diagnoses of attention deficit hyperactive disorder. *Applied Soft Computing*, 86:105905, 2020.
- [47]. Yanli Zhang-James, Emily C Helminen, Jinru Liu, Barbara Franke, Martine Hoogman, Stephen V Faraone, ENIGMA-ADHD working group, et al. Machine learning classification of attention-deficit/hyperactivity disorder using structural mri data. *bioRxiv*, page 546671, 2019.

- [48]. Zhenyu Mao, Yi Su, Guangquan Xu, Xueping Wang, Yu Huang, Weihua Yue, Li Sun, and Naixue Xiong. Spatio-temporal deep learning method for adhd fmri classification. *Information Sciences*, 499:1–11, 2019.
- [49]. Tianyi Wang and Sei-ichiro Kamata. Classification of structural mri images in adhd using 3d fractal dimension complexity map. In *2019 IEEE International Conference on Image Processing (ICIP)*, pages 215–219. IEEE, 2019.
- [50]. Sahar Abdolmaleki and Mohammad Saniee Abadeh. Brain mr image classification for adhd diagnosis using deep neural networks. In *2020 International Conference on Machine Vision and Image Processing (MVIP)*, pages 1–5. IEEE, 2020.
- [51]. Xun-Heng Wang, Yun Jiao, and Lihua Li. Diagnostic model for attention-deficit hyperactivity disorder based on interregional morphological connectivity. *Neuroscience letters*, 685:30–34, 2018.
- [52]. Atif Riaz, Muhammad Asad, Eduardo Alonso, and Greg Slabaugh. Deepfmri: End-to-end deep learning for functional connectivity and classification of adhd using fmri. *Journal of neuroscience methods*, 335:108506, 2020.
- [53]. Stephen Faraone, Yanli Zhang James, Qi Chen, and Henrik Larsson. 15. predicting comorbid disorders in adhd using machine learning. *Biological Psychiatry*, 85(10):S6, 2019.
- [54]. B Miao, LL Zhang, JL Guan, QF Meng, and YL Zhang. Classification of adhd individuals and neurotypicals using reliable relief: A resting-state study. *IEEE Access*, 7:62163–62171, 2019.
- [55]. Zirui Zhang and Xiaoli Li. Use transfer learning to promote identification adhd children with eeg recordings. In *2019 Chinese Automation Congress (CAC)*, pages 2809–2813. IEEE, 2019.
- [56]. Senuri De Silva, Sanuwani Udara Dayarathna, Gangani Ariyaratne, Dulani Meedeniya, and Sampath Jayarathna. fmri feature extraction model for adhd classification using convolutional neural network. *International Journal of E-Health and Medical Communications (IJEHMC)*, 12(1):81–105, 2021.
- [57]. Senuri De Silva, Sanuwani Dayarathna, Gangani Ariyaratne, Dulani Meedeniya, Sampath Jayarathna, and Anne MP Michalek. Computational decision support system for adhd identification. *International Journal of Automation and Computing*, 18(2):233–255, 2021.
- [58]. Vikas Khullar, Karuna Salgotra, Harjit Pal Singh, and Davinder Pal Sharma. Deep learning-based binary classification of adhd using resting state mr images. *Augmented Human Research*, 6(1):1–9, 2021.
- [59]. Sahar Karimi Shahraki and Mahdi Khezri. Identification of attention deficit hyperactivity disorder patients using wavelet-based features of eeg signals.
- [60]. Susanta Sarangi, Md Sahidullah, and Goutam Saha. Optimization of data-driven filterbank for automatic speaker verification. *Digital Signal Processing*, 104:102795, 2020.

- [61]. Silvia Cateni, Marco Vannucci, Marco Vannocci, and Valentina Colla. Variable selection and feature extraction through artificial intelligence techniques. *Multivariate Analysis in Management, Engineering and the Science*, pages 103–118, 2012.
- [62]. Ramesh Jain, Rangachar Kasturi, and Brian G Schunck. *Machine vision*, volume 5. McGraw-hill New York, 1995.
- [63]. Ngoc-Son Vu, Thanh Phuong Nguyen, and Christophe Garcia. Improving texture categorization with biologically-inspired filtering. *Image and Vision Computing*, 32(6-7):424–436, 2014.
- [64]. Faleh H Mahmood and Wafaa A Abbas. Texture features analysis using gray level co-occurrence matrix for abnormality detection in chest ct images. *Iraqi Journal of Science*, 57(1A):279–288, 2016.
- [65]. Jing Yi Tou, Yong Haur Tay, and Phooi Yee Lau. Recent trends in texture classification: a review. In *Symposium on Progress in Information & Communication Technology*, volume 3, pages 56–59. Citeseer, 2009.
- [66]. Fritz Albrechtsen et al. Statistical texture measures computed from gray level cooccurrence matrices. *Image processing laboratory, department of informatics, university of oslo*, 5(01):01–14, 2008.
- [67]. Omar S Al-Kadi. Combined statistical and model based texture features for improved image classification. 2008.
- [68]. Andreas Wibmer, Hedvig Hricak, Tatsuo Gondo, Kazuhiro Matsumoto, Harini Veeraraghavan, Duc Fehr, Junting Zheng, Debra Goldman, Chaya Moskowitz, Samson W Fine, et al. Haralick texture analysis of prostate mri: utility for differentiating non-cancerous prostate from prostate cancer and differentiating prostate cancers with different gleason scores. *European radiology*, 25(10):2840–2850, 2015.
- [69]. Hamid Soltanian-Zadeh, Farshid Rafiee-Rad, et al. Comparison of multiwavelet, wavelet, haralick, and shape features for microcalcification classification in mammograms. *Pattern recognition*, 37(10):1973–1986, 2004.
- [70]. Vitoantonio Bevilacqua, Nicola Pietroleonardo, Vito Triggiani, Antonio Brunetti, Anna Maria Di Palma, Michele Rossini, and Loreto Gesualdo. An innovative neural network framework to classify blood vessels and tubules based on haralick features evaluated in histological images of kidney biopsy. *Neurocomputing*, 228:143–153, 2017.
- [71]. TR Sivapriya, V Saravanan, and P Ranjit Jeba Thangaiah. Texture analysis of brain mri and classification with bpn for the diagnosis of dementia. In *International Conference on Computational Science, Engineering and Information Technology*, pages 553–563. Springer, 2011.
- [72]. Nourhan Zayed and Heba A Elnemr. Statistical analysis of haralick texture features to discriminate lung abnormalities. *International journal of biomedical imaging*, 2015, 2015.
- [73]. Fatih Ertam and Galip Aydın. Data classification with deep learning using tensorflow. In *2017 international conference on computer science and engineering (UBMK)*, pages 755–758. IEEE, 2017.

- [74]. Wenquan Du, Zixin Wang, and Dihu Chen. Optimizing of convolutional neural network accelerator. In *Green Electronics*. IntechOpen, 2018.
- [75]. Rahul Paul, Samuel H Hawkins, Yoganand Balagurunathan, Matthew B Schabath, Robert J Gillies, Lawrence O Hall, and Dmitry B Goldgof. Deep feature transfer learning in combination with traditional features predicts survival among patients with lung adenocarcinoma. *Tomography*, 2(4):388, 2016.
- [76]. Emilio Soria Olivas, Jos David Mart Guerrero, Marcelino Martinez-Sober, Jose Rafael Magdalena-Benedito, L Serrano, et al. *Handbook of research on machine learning applications and trends: Algorithms, methods, and techniques: Algorithms, methods, and techniques*. IGI Global, 2009.
- [77]. Wenxian Zeng, Qinglin Meng, and Ran Li. Design of intelligent classroom attendance system based on face recognition. In *2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, pages 611–615. IEEE, 2019.
- [78]. Muneeb ul Hassan. Vgg16 convolutional network for classification and detection. *Neurohive*. Dostopno na: [https://neurohive.io/en/popular-networks/vgg16/\[10.4.2019\]](https://neurohive.io/en/popular-networks/vgg16/[10.4.2019]), 2018.
- [79]. Forrest N Iandola, Song Han, Matthew W Moskewicz, Khalid Ashraf, William J Dally, and Kurt Keutzer. Squeezenet: Alexnet-level accuracy with 50x fewer parameters and < 0.5 mb model size. *arXiv preprint arXiv:1602.07360*, 2016.
- [80]. Shuai Peng, Hongbo Huang, Weijun Chen, Liang Zhang, and Weiwei Fang. More trainable inception-resnet for face recognition. *Neurocomputing*, 411:9–19, 2020.
- [81]. Chengfeng Dou, Shikun Zhang, Hanping Wang, Li Sun, Yu Huang, and Weihua Yue. Adhd fmri short-time analysis method for edge computing based on multi-instance learning. *Journal of Systems Architecture*, 111:101834, 2020.
- [82]. Soyoung Yoo, Sunghee Lee, Seongsin Kim, Kwang Hyeon Hwang, Jong Ho Park, and Namwoo Kang. Integrating deep learning into cad/cae system: Case study on road wheel design automation. *arXiv preprint arXiv:2006.02138*, 2020.
- [83]. Amirmasoud Ahmadi, Mehrdad Kashefi, Hassan Shahrokhi, and Mohammad Ali Nazari. Computer aided diagnosis system using deep convolutional neural networks for adhd subtypes. *Biomedical Signal Processing and Control*, 63:102227, 2021.
- [84]. Junqiang Du, Lipeng Wang, Biao Jie, and Daoqiang Zhang. Network-based classification of adhd patients using discriminative subnetwork selection and graph kernel pca. *Computerized Medical Imaging and Graphics*, 52:82–88, 2016.