

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
GÖRÜNTÜLER ÜZERİNDE İNSAN HAREKETLERİNİN VE
HASTALIKLARININ SINIFLANDIRILMASI

Muhammed YILDIRIM

Doktora Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

HAZİRAN 2021

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

**DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK GÖRÜNTÜLER
ÜZERİNDE İNSAN HAREKETLERİNİN VE HASTALIKLARININ
SINIFLANDIRILMASI**

Tez Yazarı

Muhammed YILDIRIM

Danışman

Doç. Dr. Ahmet ÇINAR

HAZİRAN 2021

ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

Başlığı: Derin Öğrenme Yöntemleri Kullanılarak Görüntüler Üzerinde İnsan Hareketlerinin ve Hastalıklarının Sınıflandırılması

Yazarı: Muhammed YILDIRIM

İlk Teslim Tarihi: 18.05.2021

Savunma Tarihi: 21.06.2021

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Ahmet ÇINAR Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Ali KARCI İnönü Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Prof. Dr. Bilal ALATAŞ Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Doç. Dr. Taner TUNCER Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Taner UÇKAN Van Yüzüncü Yıl Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Doç. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Derin Öğrenme Yöntemleri Kullanılarak Görüntüler Üzerinde İnsan Hareketlerinin ve Hastalıklarının Sınıflandırılması” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

21.06.2021

Muhammed YILDIRIM



ÖNSÖZ

“Derin Öğrenme Yöntemleri Kullanılarak Görüntüler Üzerinde İnsan Hareketlerinin ve Hastalıklarının Sınıflandırılması” başlıklı doktora tezinde amaç, insan hareketlerinin ve hastalıklarının derin öğrenme yöntemleri kullanılarak sınıflandırılmasıdır. Bu tez çalışmasında üç farklı uygulama gerçekleştirilmiştir. İlk uygulamada insan hareketlerinin önerilen CNN tabanlı modelle sınıflandırılması, ikinci uygulamada beyin MR görüntülerinin önerilen hibrit yöntemle sınıflandırılması ve son uygulamada ise göğüs X-Ray görüntüleri kullanılarak zatürre hastalığının önerilen hibrit yöntemle sınıflandırılması gerçekleştirilmiştir. Bu uygulamalar farklı modellerde test edilmiştir. Elde edilen sonuçlar karşılaştırılmıştır.

Yüksek lisans ve doktora çalışmalarım boyunca bana çalışmalarımda her türlü desteği veren, beni yönlendiren, bilgi birikimini ve tecrübelerini benimle paylaşan ve en önemlisi bu zor süreçte benden hoş görüşünü esirgemeyen değerli hocam Doç. Dr. Ahmet ÇINAR’a, hayatım boyunca benden desteğini esirgemeyen kıymetli aileme, bu zor süreçte yanımda olan değerli eşime ve kızlarıma ayrıca üstümde emeği olan tüm hocalarıma ve dostlarıma sonsuz teşekkürlerimi sunarım.

Muhammed YILDIRIM

ELAZIĞ, 2021

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xii
SİMGELER VE KISALTMALAR	xiv
1. GİRİŞ	1
2. MAKİNE ÖĞRENMESİ VE SINIFLANDIRICILAR	4
2.1. Denetimli Makine Öğrenmesi.....	5
2.1.1. Sınıflandırma.....	6
2.1.2. Karar Ağaçları	8
2.1.3. Regresyon.....	8
2.2. Denetimsiz Makine Öğrenmesi	10
2.2.1. Kümeleme Algoritmaları.....	10
2.2.2. Saklı Markov Modeli	11
2.2.3. Birliktelik Kuralları	12
2.3. Takviyeli Makine Öğrenmesi	12
3. DERİN ÖĞRENME	14
3.1. Derin Öğrenme Mimarileri	16
3.1.1. Tekrarlayan Sinir ağları.....	16
3.1.2. Uzun Kısa Vadeli Hafıza Ağları	17
3.1.3. Boltzmann Makineleri.....	18
3.1.4. Derin İnanc Ağları.....	19
3.1.5. Oto Kodlayıcılar.....	19
3.1.6. Evrişimsel Sinir Ağları.....	20
3.2. Evrişimsel Sinir Ağları	21
3.2.1. Evrişimsel Sinir Ağları Modelleri	22
3.2.2. ESA katmanları	28
3.2.3. Aktivasyon Fonksiyonları	35
3.3. Derin Öğrenme Mimarilerinde Kullanılan Performans Ölçütleri	41
4. İNSAN HAREKETLERİN DERİN ÖĞRENME MİMARİLERİ İLE SINIFLANDIRILMASI.....	43
4.1. Literatür Taraması	43
4.2. Veri Seti.....	45
4.3. Materyal ve Yöntem	46
4.4. Uygulama	49
4.5. Sonuçlar ve Tartışma.....	66
5. BEYİN MR GÖRÜNTÜLERİNİN DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK	
SINIFLANDIRILMASI.....	67
5.1. Literatür Taraması	67
5.2. Veri Seti.....	69

5.3. Materyal ve Yöntem	70
5.4. Uygulama	71
5.5. Sonuçlar ve Tartışma	81
6. GÖĞÜS X-RAY GÖRÜNTÜLERİNİN DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK SINIFLANDIRILMASI	83
6.1. Literatür Taraması	83
6.2. Veri Seti	84
6.3. Materyal ve Yöntem	85
6.4. Uygulama	86
6.5. Sonuçlar ve Tartışma	93
7. SONUÇLAR VE TARTIŞMA	94
KAYNAKLAR	96
ÖZGEÇMİŞ	



ÖZET

Derin Öğrenme Yöntemleri Kullanılarak Görüntüler Üzerinde İnsan Hareketlerinin ve Hastalıklarının Sınıflandırılması

Muhammed YILDIRIM

Doktora Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Haziran 2021, Sayfa: xiv + 105

Derin öğrenme modelleri son yıllarda oldukça popüler ve yaygın bir hale gelmiştir. Gelişen teknoloji ile birlikte veri tabanlarında tutulan verilerin miktarları her geçen gün artmaktadır. Bu tez çalışmasında da derin öğrenme tabanlı yöntemler kullanılarak veri setlerinde tutulan bu verilerin işlenmesi ve bunların sınıflandırılması amaçlanmıştır. Gerçekleştirilen bu tez çalışmasında 3 farklı uygulama gerçekleştirilmiştir.

İlk uygulamada insan hareketleri görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri setindeki videolardan belirli sayıda görüntü örnekleri alınarak bir veri seti oluşturulmuştur. Oluşturulan veri setindeki insan hareketlerinin sınıflandırılması için ESA tabanlı bir model geliştirilmiştir. Gerçekleştirilen ikinci uygulamada ise beyin MR görüntüleri kullanılarak, bu görüntüler tümörlü ve tümörsüz görüntüler olmak üzere sınıflandırılmıştır. Bu uygulamada hibrit bir model önerilmiştir. Son uygulamada ise göğüs X-Ray görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri setinde ki görüntüleri zatürre ya da normal olarak sınıflandırmak için önerilen hibrit yöntemde başarılı sonuçlar elde edilmiştir. Beyin MR görüntüleri ve göğüs X-Ray görüntülerinin sınıflandırılmasında, önerilen hibrit modelde ESA mimarilerinden olan Resnet50 taban olarak kullanılmıştır. Her üç çalışmada da halka açık veri setleri kullanılmıştır.

Gerçekleştirilen derin öğrenme tabanlı uygulamalarda başarılı sonuçlar elde edilmiştir. Önerilen bu yöntemlerin çalışmada kullanılan önceden eğitilmiş modellerden daha başarılı oldukları görülmüştür. Ayrıca gerçekleştirilen uygulamalar literatürdeki benzer çalışmalarla da kıyaslanmıştır.

Anahtar Kelimeler: Beyin Tümörü, Derin Öğrenme, İnsan hareketleri, Sınıflandırma, Zatürre.

ABSTRACT

Classification of Human Movements and Diseases on Images Using Deep Learning Methods

Muhammed YILDIRIM

Ph.D. Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

June 2021, Pages: xiv + 105

Deep learning models have become very popular and widespread in recent years. With the developing technology, the amount of data kept in databases is increasing day by day. In this thesis, it is aimed to process and classify these data kept in data sets by using deep learning-based methods. In this thesis study, 3 different applications were carried out.

In the first application, a data set consisting of images of human movements was used. A data set was created by taking a certain number of image samples from the videos in this data set. An ESA-based model has been developed for the classification of human movements in the created data set. In the second application, using brain MR images, these images were classified as tumor and tumor-free images. In this application, a hybrid model is proposed. In the last application, a data set consisting of chest X-Ray images was used. Successful results were obtained in the proposed hybrid method to classify the images in this data set as pneumonia or normal. In the classification of brain MR images and chest X-Ray images, Resnet50, one of the ESA architectures, was used as the basis in the proposed hybrid model. Publicly available datasets were used in all three studies.

Successful results have been obtained in improved deep learning-based applications. These proposed methods were seen to be more successful than the pre-trained models used in the study. In addition, the applications were compared with similar studies in the literature.

Keywords: Brain Tumor, Deep Learning, Human Activity, Classification, Pneumonia.

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Verilerin makine öğrenmesiyle işlenmesi	4
Şekil 2.2. Makine öğrenmesi yöntemleri	5
Şekil 2.3. Denetimli makine öğrenmesi modelinin çalışma prensibi.....	5
Şekil 2.4. Naive Bayes veri sınıflandırma	6
Şekil 2.5. Destek Vektör Makinaları	7
Şekil 2.6. Karar Ağaçları	8
Şekil 2.7. Doğrusal Regresyon	9
Şekil 2.8. Polinomsal Regresyon.....	9
Şekil 2.9. Denetimsiz öğrenme modelinin çalışma prensibi.....	10
Şekil 2.10. Takviyeli makine öğrenmesi modeli	13
Şekil 3.1. Klasik makine öğrenmesi ve derin öğrenme modellerinin akış şeması	14
Şekil 3.2. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin kabaca gösterimi	15
Şekil 3.3. Derin öğrenme sinir ağı.....	15
Şekil 3.4. RNN mimarisi	16
Şekil 3.5. LSTM ağı	17
Şekil 3.6. Boltzmann Makinesi	18
Şekil 3.7. Sınırlı Boltzmann Makinesi.....	18
Şekil 3.8. Derin inanç ağları	19
Şekil 3.9. Oto kodlayıcı mimarisi.....	20
Şekil 3.10. Derin oto kodlayıcı mimarisi.....	20
Şekil 3.11. ESA mimarilerinin kabaca gösterimi	21
Şekil 3.12. Alexnet mimarisi [77]	23
Şekil 3.13. Resnet mimarisi kısa yol bağlantısı.....	23
Şekil 3.14. Üstteki şekil artık (residual) bir ağ mimarisi, alttaki şekil düz (plain) ağ mimarisi [79].	24
Şekil 3.15. Googlenet mimarisi [80]	25
Şekil 3.16. Vgg16 mimarisi.....	25
Şekil 3.17. Densenet201 mimarisi [83]	26
Şekil 3.18. InceptionV3 mimarisi [86].	26
Şekil 3.19. 8x8 boyutundaki giriş görüntüsüne 3x3'lük bir filtre uygulanması	30
Şekil 3.20. Sıfır dolgu uygulama	31
Şekil 3.21. Evrişim İşlemi	31

Şekil 3.22. Maksimum ortaklama işlemi	33
Şekil 3.23. Ortalama ortaklama işlemi	33
Şekil 3.24. Seyreltme işlemi	34
Şekil 3.25. Tam bağlantı katmanı	34
Şekil 3.26. Relu aktivasyon fonksiyonu	35
Şekil 3.27. Sigmoid aktivasyon fonksiyonu	36
Şekil 3.28. TanH aktivasyon fonksiyonu.....	37
Şekil 3.29. Doğrusal aktivasyon fonksiyonu	38
Şekil 3.30. Basamak aktivasyon fonksiyonu	39
Şekil 3.31. Leaky Relu aktivasyon fonksiyonu	39
Şekil 3.32. Swish aktivasyon fonksiyonu	40
Şekil 3.33. Softmax aktivasyon fonksiyonu	41
Şekil 4.1. Çalışmada kullanılan sınıflar ve görüntü sayıları	45
Şekil 4.2. Kesit örnekleri	46
Şekil 4.3. Önerilen model	47
Şekil 4.4. Önerilen modelin blok diyagramı	48
Şekil 4.5. Alexnet modelinin doğruluk ve kayıp eğrisi	49
Şekil 4.6. Densenet201 modelin doğruluk ve kayıp eğrisi	52
Şekil 4.7. InceptionV3 modelin doğruluk ve kayıp eğrisi	54
Şekil 4.8. Resnet50 modelin doğruluk ve kayıp eğrisi	56
Şekil 4.9. Googlenet modelinin doğruluk ve kayıp eğrisi	58
Şekil 4.10. MobilenetV2 modelinin doğruluk ve kayıp eğrisi	60
Şekil 4.11. Effiecientnetb0 modelinin doğruluk ve kayıp eğrisi	62
Şekil 4.12. Önerilen modelin doğruluk ve kayıp eğrisi	64
Şekil 5.1. Veri setinden örnek MR görüntüleri.....	69
Şekil 5.2. Geliştirilen Resnet50 modelinin katman yapısı.....	70
Şekil 5.3. Önerilen modelin kaba gösterimi	71
Şekil 5.4. Googlenet mimarisinin doğruluk ve kayıp eğrisi	72
Şekil 5.5. InceptionV3 modelinin doğruluk ve kayıp eğrisi	73
Şekil 5.6. Alexnet modelinin doğruluk ve kayıp eğrisi	74
Şekil 5.7. Densenet201 modelinin doğruluk ve kayıp eğrisi	75
Şekil 5.8. Vgg16 modelinin doğruluk ve kayıp eğrisi	77
Şekil 5.9. Resnet50 modelinin doğruluk ve kayıp eğrisi	78
Şekil 5.10. Darknet53 modelinin doğruluk ve kayıp eğrisi	79

Şekil 5.11. Önerilen hibrit modelin doğruluk ve kayıp eğrisi	80
Şekil 6.1. Kullanılan veri setinden X-Ray görüntü örnekleri	85
Şekil 6.2. Önerilen hibrit modelin katman yapısı	85
Şekil 6.3. Önerilen modelin kaba gösterimi	86
Şekil 6.4. Alexnet modelinin doğruluk ve kayıp eğrisi	87
Şekil 6.5. Googlenet modelinin doğruluk ve kayıp eğrisi	88
Şekil 6.6. Resnet50 modelinin doğruluk ve kayıp eğrisi	89
Şekil 6.7. Densenet201 modelinin doğruluk ve kayıp eğrisi	90
Şekil 6.8. Önerilen modelin doğruluk ve kayıp eğrisi	92



TABLULAR LİSTESİ

	Sayfa
Tablo 3.1. EfficienNetb0 temel ağ yapısı.....	27
Tablo 3.2. Modellerin giriş boyutu	29
Tablo 3.3. Karışıklık matrisi	41
Tablo 4.1. Önerilen modelin eğitiminde kullanılan parametre değerleri	47
Tablo 4.2. Önerilen modelin genel yapısı	48
Tablo 4.3. Uygulamada kullanılan modellerin parametre değerleri.....	49
Tablo 4.4. Alexnet modelinin karışıklık matrisi	50
Tablo 4.5. Alexnet modelinde elde edilen performans değerleri	51
Tablo 4.6. Densenet201 modelinin karışıklık matrisi	52
Tablo 4.7. Densenet201 modelinde elde edilen performans değerleri	53
Tablo 4.8. InceptionV3 modelinin karışıklık matrisi	54
Tablo 4.9. InceptionV3 modelinde elde edilen performans değerleri	55
Tablo 4.10. Resnet50 modelinin karışıklık matrisi	56
Tablo 4.11. Resnet50 modelinde elde edilen performans değerleri	57
Tablo 4.12. Googlenet modelinin karışıklık matrisi.....	58
Tablo 4.13. Googlenet modelinde elde edilen performans değerleri	59
Tablo 4.14. MobilenetV2 modelinin karışıklık matrisi.....	60
Tablo 4.15. MobilenetV2 modelinde elde edilen performans değerleri.....	61
Tablo 4.16. Efficientnetb0 modelinin karışıklık matrisi	62
Tablo 4.17. Efficientnetb0 modelinin performans değerleri	63
Tablo 4.18. Önerilen modelin karışıklık matrisi	64
Tablo 4.19. Önerilen modelin performans değerleri	65
Tablo 4.20. Modellerin doğruluk oranları.....	66
Tablo 5.1. Çalışmada kullanılan parametre değerleri	71
Tablo 5.2. Googlenet modelinin karışıklık matrisi	72
Tablo 5.3. Googlenet modelinin performans metrikleri.....	72
Tablo 5.4. InceptionV3 modelinin karışıklık matrisi	73
Tablo 5.5. InceptionV3 modelinin performans ölçütleri	74
Tablo 5.6. Alexnet mimarisinin karışıklık matrisi	74
Tablo 5.7. Alexnet mimarisinin performans metrikleri.....	75
Tablo 5.8. Densenet201 modelinin karışıklık matrisi	76

Tablo 5.9. Densenet201 modelinin performans metrikleri.....	76
Tablo 5.10. Vgg16 modelinin karışıklık matrisi	77
Tablo 5.11. Vgg16 modelinin performans metrikleri.....	77
Tablo 5.12. Resnet50 modelinin karışıklık matrisi	78
Tablo 5.13. Resnet50 modelinin performans metrikleri.....	79
Tablo 5.14. Darknet53 modelinin karışıklık matrisi	79
Tablo 5.15. Darknet53 modelinin performans metrikleri.....	80
Tablo 5.16. Önerilen modelin karışıklık matrisi	81
Tablo 5.17. Önerilen modelin performans metrikleri.....	81
Tablo 5.18. Çalışmada kullanılan modellerin doğruluk değerleri	82
Tablo 6.1. Çalışmada kullanılan parametre değerleri.....	86
Tablo 6.2. Alexnet modelinin karışıklık matrisi	87
Tablo 6.3. Alexnet modelinin performans metrikleri.....	87
Tablo 6.4. Googlenet modelinin karışıklık matrisi	88
Tablo 6.5. Googlenet modelinin performans metrikleri.....	89
Tablo 6.6. Resnet50 modelinin karışıklık matrisi	90
Tablo 6.7. Resnet50 modelinin performans metrikleri.....	90
Tablo 6.8. Densenet201 modelinin karışıklık matrisi	91
Tablo 6.9. Densenet201 modelinin performans metrikleri.....	91
Tablo 6.10. Önerilen modelin karışıklık matrisi	92
Tablo 6.11. Önerilen modelin performans metrikleri.....	92
Tablo 6.12. Çalışmada kullanılan modellerin doğruluk oranları.....	93

SİMGELER VE KISALTMALAR

Simgeler

*	: Evrişim İşlemi
Σ	: Toplam

Kısaltmalar

ACC	: Accuracy (Doğruluk)
BM	: Boltzmann Makinası
BT	: Bilgisayarlı Tomografi
CONV	: Convolution (Evrişim)
DA	: Diskriminant Analizi
DİA	: Derin İnanç Ağları
DMÖ	: Denetimsiz Makine Öğrenmesi
DOK	: Derin Oto Kodlayıcılar
DVM	: Destek Vektör Makinası
ESA	: Evrişimsel Sinir Ağları
F1	: F Ölçümü
FDR	: False Discovery Rate (Yanlış Bulgu Oranı)
FN	: False Negative (Yanlış Negatif)
FNR	: False Negative Rate (Yanlış Negatif Oranı)
FP	: False Positive (Gerçek Negatif)
FPR	: False Positive Rate (Yanlış Pozitif Oranı)
GPU	: Graphics Processing Unit (Grafik İşlemci Birimi)
KNN	: k- En Yakın Komşu
LSTM	: Long-Short Term Memory (Uzun-Kısa Vadeli Hafıza Ağları)
MBCONV	: Mobile Tersine Çevrilmiş Darboğaz
MÖ	: Makine Öğrenmesi
MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme
NB	: Naive Bayes
OK	: Oto Kodlayıcılar
PRE	: Precision (Keskinlik)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağları)
SBM	: Sınırlı Boltzmann Makinası
SEN	: Sensitivity (Duyarlılık)
SPE	: Specifity (Özgünlük)
TanH:	: Hiperbolik Tanjant
TN	: True Negative (Gerçek Negatif)
TÖ	: Takviyeli Öğrenme
TP	: True Positive (Gerçek Pozitif)
X-RAY	: Röntgen
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Gelişen teknolojiyle birlikte veri tabanlarında tutulan verilerin boyutu gün geçtikçe artmaktadır. Bu verilerin işlenip, anlamlandırılması büyük bir önem arz etmektedir [1]. Bu tez çalışmasında veri tabanlarında tutulan görüntülerin derin öğrenme yöntemleri kullanılarak sınıflandırılması amaçlanmıştır. Sınıflandırma konusu birçok alanda yaygın bir şekilde kullanılan popüler konulardan biridir. Gelişen teknolojiyle birlikte derin öğrenme mimarileri veri tabanlarında tutulan büyük miktarlardaki verilerin sınıflandırılması işleminde yaygın bir şekilde kullanılmaktadır. Son yıllarda oldukça popüler hale gelen birçok derin öğrenme mimarisi mevcuttur [2]. Derin öğrenme mimarilerinden biri olan Evrişimsel Sinir Ağları (ESA) görüntü işleme konusunda yaygın bir şekilde kullanılmaktadır. ESA mimarilerinin en büyük özelliklerinden biri sınıflandırılacak olan özelliklerin uzman bilgisine ihtiyaç olmadan otomatik olarak elde edilebilmesidir. Klasik makine öğrenmesi yöntemlerinde bu özelliklerin çıkarılması için uzman bilgisi gereklidir ve bu da daha fazla zaman ve maliyet gerektiren bir süreçtir [3].

Bu tez çalışmasında derin öğrenme yöntemleri kullanılarak üç farklı sınıflandırma uygulaması gerçekleştirilmiştir. Bu uygulamalardan birincisi olan insan hareketlerinin derin öğrenme yöntemleri kullanılarak sınıflandırılmasıdır. İnsan hareketlerinin sınıflandırılması gelişen teknolojiyle birlikte zaruri bir ihtiyaç haline gelmiştir. İnsan hareketleri sağlık ve güvenlik sistemleri başta olmak üzere birçok alanda yaygın bir şekilde kullanılmaktadır. İnsan hareketlerini sınıflandırmak, mevcut durum hakkında bilgi verebileceği gibi, gelecekteki davranışlar hakkında da tahminlerde bulunabilmeye olanak tanımaktadır. Gerçekleştirilen ilk uygulamada insan hareketlerini derin öğrenme yöntemleriyle sınıflandırmak amaçlanmıştır. Bunun için video görüntülerinden oluşan halka açık bir veri seti kullanılmıştır. Bu veri seti 10 farklı hareket grubundan oluşmaktadır. Bu videolardan elde edilen görüntüler geliştirilen derin öğrenme tabanlı bir modelle sınıflandırılmıştır. Önerilen bu model toplamda 43 katmandan oluşmaktadır. Bu modelle elde edilen sonuçlar, mevcut önceden eğitilmiş ESA modelleriyle karşılaştırılmıştır. Elde edilen sonuçlar incelendiğinde geliştirilen modelin insan hareketlerini sınıflandırmada başarılı olduğu görülmüştür.

Bu tez çalışması kapsamında gerçekleştirilen bir başka uygulamada ise beyin MR görüntülerinin sınıflandırılması amaçlanmıştır. Beyin tümörü çocuklarda ve yetişkinlerde anormal hücrelerin çoğalması sonucunda meydana gelen ölümcül bir hastalıktır. Beyin tümörlerinin erken ve doğru bir şekilde teşhis edilmesi, hastalığın takibi ve tedavisi için oldukça önemlidir [4]. Bundan dolayı bilgisayar destekli sistemlerin önemi oldukça fazladır. Bu sistemler ile hastalığın erken teşhis edilmesi ve daha doğru sonuçların elde edilmesi büyük bir önem arz etmektedir. Bu sistemler uzmanların olmadığı yerlerde ön teşhis işlemi için kullanılabilmesi gibi ayrıca uzmana yardımcı olmak için de kullanılabilir [5]. Bu sayede uzmanların yapabileceği hatalarda önlenmiş olunur. Bu

uygulamada beyin MR görüntüleri kullanarak tümörlü ve tümörsüz görüntülerin sınıflandırılması amaçlanmıştır. Kullanılan veri setinde 2 sınıf mevcuttur. Bu sınıfların ilkinde tümörlü beyin MR görüntüleri, diğer sınıfta ise tümörsüz beyin MR görüntüleri vardır. Bu görüntülerin sınıflandırılması için önceden eğitilmiş ESA modelleri ve geliştirilen hibrit model kullanılmıştır. Elde edilen sonuçlar Resnet50 modeli taban olarak kullanılan hibrit modelle karşılaştırılmıştır. Önerilen hibrit model çalışmada kullanılan diğer ESA mimarilerine göre daha başarılı sonuçlar üretmiştir. Ayrıca konuyla ilgili yapılmış çalışmalarda incelendiğinde geliştirilen modelin başarılı olduğu sonucuna varılmıştır.

Gerçekleştirilen son uygulamada ise göğüs X-Ray görüntülerinin sınıflandırılması amaçlanmıştır. Burada ki amaç zatürreli X-Ray göğüs görüntüleri ile normal X-Ray göğüs görüntülerinin birbirlerinden ayırt edilmesidir. Yani 2 sınıftan oluşan halka açık bu veri setinde ki görüntülerin derin öğrenme yöntemleriyle sınıflandırılmasıdır. Zatürre her yıl birçok insanı etkileyen ölümcül bir hastalıktır. Zatürre özellikle 0-5 yaş arası çocuklarda ve 65 yaş üstü bireylerde ciddi bir ölüm nedenidir. Zatürre çeşitli nedenlerden dolayı ortaya çıkabilmektedir. Zatürrenin ortaya çıkmasında bakteri, virüs ve mantar gibi mikroorganizmalar başta olmak üzere asitli-alkali maddelerin solunması en başlıca etmenlerdendir [6]. Zatürre hastalığının erken ve doğru teşhisi tedavi için büyük bir önem arz etmektedir. Zatürrenin teşhisi için sıklıkla görüntüleme cihazlarından faydalanılır. Bu cihazlardan alınan görüntülerin doğru ve hızlı bir şekilde sınıflandırılması büyük bir önem arz etmektedir. Bu çalışmada bu görüntülerin sınıflandırılması için önerilen hibrit modelde elde edilen sonuçlar diğer ESA mimarileri ve önceden yapılmış benzer çalışmalarla karşılaştırılmıştır. Önerilen hibrit modelin göğüs X-Ray görüntülerini sınıflandırma işleminde başarılı olduğu görülmüştür. Önerilen yöntemin zatürre görüntülerinin sınıflandırılması sürecinde kullanılabileceği kanaatine varılmıştır.


Tezin organizasyonu;

- Tezin ilk bölümü giriş bölümüdür. Bu bölümde genel bilgiler verilmiştir.
- İkinci bölümde makine öğrenmesi ve makine öğrenmesinin alt başlıkları incelenmiştir. Makine öğrenmesi 3 alt başlık halinde sunulmuş olup, sınıflandırıcılarda bu bölümde detaylandırılmıştır.
- Üçüncü bölümde derin öğrenme konusu ele alınmış olup, literatürde sıklıkla kullanılan derin öğrenme mimarileri incelenmiştir. Ayrıca bu bölümde ESA mimarileri, ESA katmanları ve ESA mimarilerinde kullanılan aktivasyon fonksiyonları sunulmuştur.
- Dördüncü bölümde insan hareketleri görüntülerinin derin öğrenme mimarileriyle sınıflandırılması amaçlanmıştır. Bu bölümde kullanılan veri seti, önceden eğitilmiş ESA modellerinde alınan sonuçlar ve geliştirilmiş yöntemde elde edilen sonuçlara değinilmiştir. Elde edilen sonuçlar literatürde yapılmış benzer çalışmalarla karşılaştırılmıştır.

- Beşinci bölüm beyin MR görüntülerinin derin öğrenme yöntemleri kullanılarak sınıflandırılmasını kapsamaktadır. Bu bölümde beyin MR görüntüleri tümörlü ve tümörsüz olmak üzere sınıflandırılmıştır. Bu bölümde ayrıca kullanılan ve geliştirilen yöntemler sunulmuştur. Elde edilen sonuçlar değerlendirilmiş ve konu detaylı bir şekilde tartışılmıştır.
- Altıncı bölümde göğüs X-Ray görüntülerinin derin öğrenme yöntemleri kullanılarak sınıflandırılması incelenmiştir. Bu bölümde göğüs X-ray görüntüleri zatürre ve normal olmak üzere sınıflandırılmıştır. Bu bölümde önerilen yöntem ve çalışmada kullanılan önceden eğitilmiş diğer ESA mimarilerinde alınan sonuçlar incelenmiştir. Elde edilen sonuçlar detaylı bir şekilde tartışılmıştır.
- Yedinci bölümde ise konuyla ilgili elde edilen sonuçlara değinilmiştir. Yapılan çalışmaların literatüre olan katkısı hakkında bilgi verilmiştir.

2. MAKİNE ÖĞRENMESİ VE SINIFLANDIRICILAR

Gelişen teknolojiyle birlikte veri tabanlarında tutulan veri miktarları her geçen gün artmaktadır. Fakat veri setlerinde tutulan bu bilgiler işlenip, gerekli çıkarımlar yapılmadıktan sonra bir anlam ifade etmemektedir. Gelişen teknolojiyle birlikte veri setlerinde tutulan bu verilerin işlenip, kurumlara, şirketlere veya kullanıcılara fayda sağlaması büyük bir önem arz etmektedir. Veri tabanlarında tutulan bu büyük veri setlerini işlenmesi ve analiz edilmesi geleneksel veri tabanı sistemleri ile oldukça zordur [7]. Makine öğrenmesi (MÖ) verilerin işlenip analiz edilebilmesi için gerekli yöntemler ve algoritmalar bütünüdür. Burada probleme göre bir model üretilmektedir. MÖ yöntemleri geçmiş tecrübelerden de faydalanabilmektedir. MÖ yöntemleri sadece büyük verilerde değil, dağıtık veri setlerinde de kullanılabilir. Literatürde birden fazla MÖ yöntemi mevcuttur. MÖ yönteminin mantığında zaten büyük verileri işlemek yatmaktadır [8]. Örneğin herhangi bir hastanenin veri setinde tutulan beyin tümörü MR görüntüleri verilebilir. Bu veri setinde tutulan veriler MÖ yöntemleriyle işlendikten sonra bir anlam kazanabilir. Bunu kabaca Şekil 2.1'deki gibi açıklamak mümkündür.

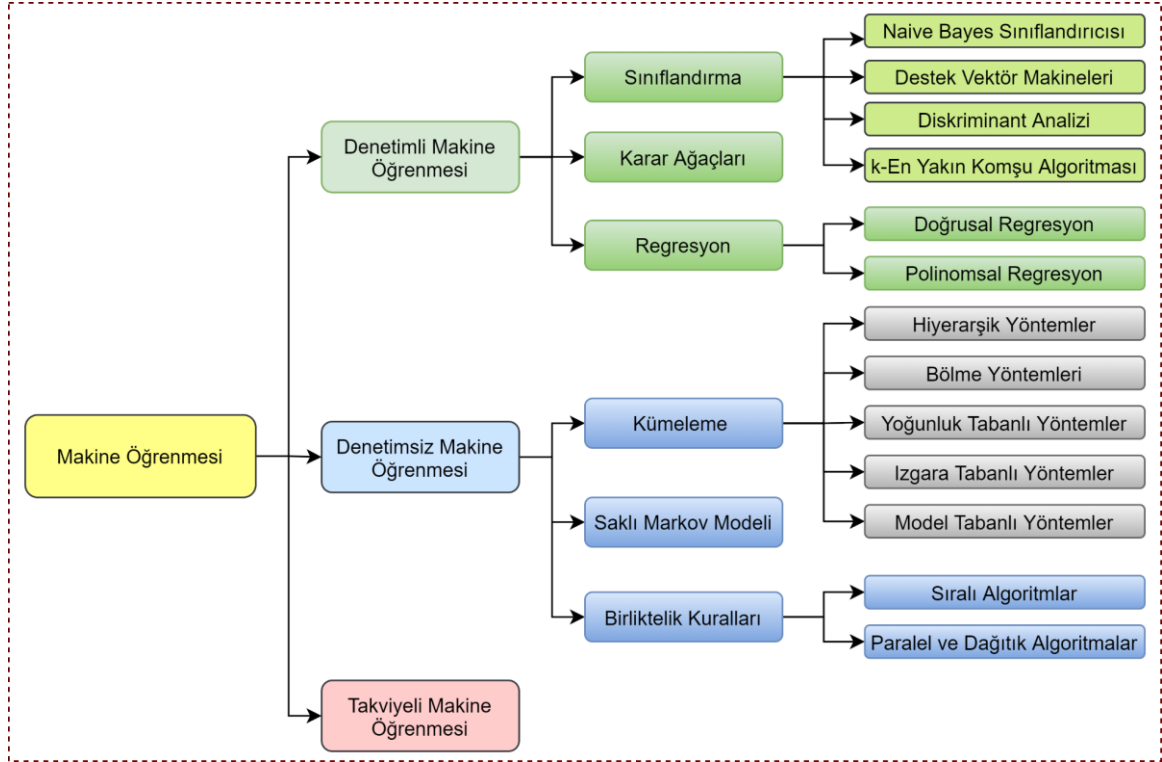


Şekil 2.1. Verilerin makine öğrenmesiyle işlenmesi

Şekil 2.1'de de görüleceği gibi veri setinden alınan bilgilerin MÖ yöntemleriyle işlenmiştir. İşlenen bu veriler 2 sınıfa ayrıştırılmıştır. İşlenen bu bilgiler artık bir anlam ifade etmektedir. Örneğin beyin tümörü görüntüleri sınıflandırılıp uzmana sunulunca, uzmanın bu verileri yorumlaması daha kolay olacaktır. Ve uzmanın yapabileceği hatalarında önüne geçilmiş olunacaktır.

MÖ yöntemleri görüntü, ses, sinyal, metin vb. birçok veri üzerinde çalışabilmektedir. Bundan dolayı makine öğrenmesi yöntemlerinin oldukça geniş bir kullanım alanı vardır. Bankacılık, otomotiv, sağlık vb. birçok alanda bu yöntemler sıklıkla kullanılmaktadır [8].


Veri kümelerinin işlenmesi, bu veri kümelerinin analiz edilmesi için geliştirilmiş birden fazla MÖ yöntemleri ve algoritmaları mevcuttur. Şekil 2.2'de bu yöntemler kabaca verilmiştir.



Şekil 2.2. Makine öğrenmesi yöntemleri

2.1. Denetimli Makine Öğrenmesi

Denetimli makine öğrenmesi (DMÖ) yöntemleri literatürde oldukça yaygın bir şekilde kullanılmaktadır. DMÖ'nün asıl amacı, ağa veriler vererek ağı eğitmektir. Ağ bu sayede öğrenme işlemini gerçekleştirmiş olur. Bu MÖ yöntemindeki en büyük özellik etiketli verilerin kullanılmasıdır. Bundan sonraki adımda ise eğitilen ağa yeni girdiler geldiği zaman ağın istenilen değere en yakın sonucu üretmesi istenir. Bu sayede yeni gelen girdinin doğru sınıfa yerleştirilmesi amaçlanır [9]. Denetimli makine öğrenmesi modelinin çalışma prensibi Şekil 2.3'te verilmiştir.



Şekil 2.3. Denetimli makine öğrenmesi modelinin çalışma prensibi

Denetimli makine öğrenmesini kendi içerisinde Sınıflandırma, Karar Ağaçları ve Regression olmak üzere 3 sınıfta kategorize etmemiz mümkündür.

2.1.1. Sınıflandırma

Makine öğrenme algoritması ile gözlemlenen verilerden bir sonuç çıkararak bu verilerin kategorilere ayrılması ve daha sonra gelecek olan yeni verilerin hangi kategoriye ait olduğunun tespit edilmesi işlemidir. Kabaca kullanılan veriler kategorilere ayrıştırılmak isteniyorsa bu yöntem kullanılabilir [10]. Burada sınıf sayısının bir önemi yoktur, önemli olan verilerin etiketli olmasıdır. Etiketten kasıt verilerin sınıfının belli olmasıdır. Gelişen teknolojiyle birlikte şu anda kullanılmakta olan birden çok sınıflandırma metodu mevcuttur. Naive Bayes Sınıflandırıcısı, Destek Vektör Makineleri, Diskriminant Analizi ve K-En Yakın Komşu algoritması literatürde sıklıkla kullanılan sınıflandırma yöntemleridir [11].


Naive Bayes Sınıflandırıcısı

İstatistiksel bir sınıflandırma yöntemi olan Naive Bayes (NB) sınıflandırması istatistikteki Bayes teoremine dayanmaktadır. Mevcut verilerin belirlenmiş olan sınıflara ait olup olmadığı olasılığı değerlendirilir. Verilerin her bir kriterinin sonuca olan etkisinin olasılıksal olarak hesaplanması mantığını içerir. NB yöntemi diğer sınıflandırma algoritmalarından basit ve sade olmasından dolayı literatürde sıklıkla kullanılmaktadır [12]. NB sınıflandırıcısı Bayes teoreminin bağımsızlık önermesiyle basitleştirilmiş halidir. Bayes teoremi Denklem 2.1’de gösterilmiştir.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2.1)$$

Burada $P(A|B)$, B olayı gerçekleştiği durumda A olayının meydana gelme olasılığıdır. $P(B|A)$, A olayı gerçekleştiği durumda B olayının meydana gelme olasılığıdır. $P(A)$ ve $P(B)$, A ve B olaylarının olma olasılıklarıdır.

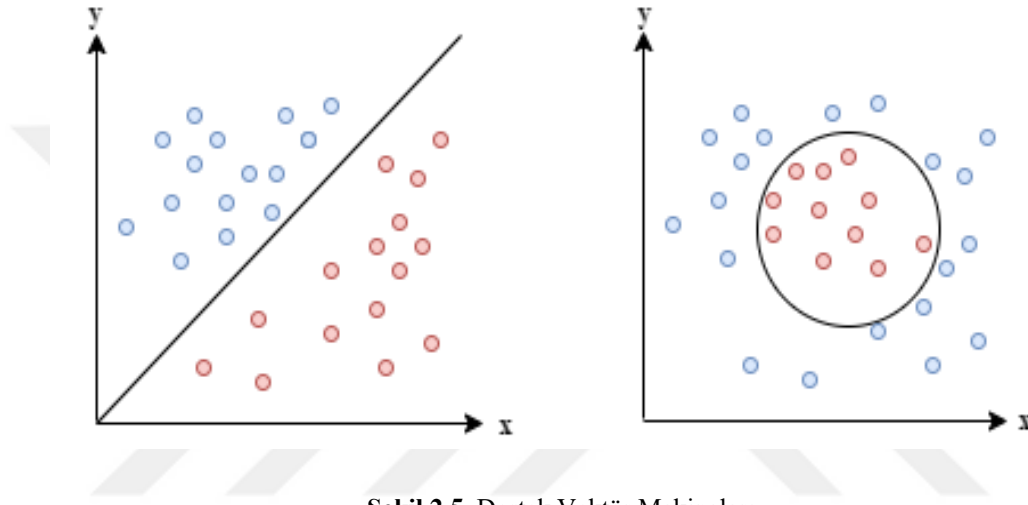
Şekil 2.4’te NB ile veri sınıflandırma örneği verilmiştir.



Şekil 2.4. Naive Bayes veri sınıflandırma

Destek Vektör Makinaları

Destek Vektör Makinaları (DVM), mantık olarak birden fazla sınıfa ait verileri birbirinden en uygun şekilde ayırmak için kullanılan bir tekniktir. Bunun için karar sınırları ya da diğer bir ifadeyle hiper düzlemler belirlenir. DVM yüksek boyutlu uzaylarda başarılı sonuçlar üretebilmektedirler. Ayrıca kullanmış oldukları eğitim noktaları sayesinde bellek verimli bir şekilde kullanılmış olur. Kullanılan veri seti 2 türlü olabilmektedir. Bunlardan ilki doğrusal ayrışabilen, diğeri ise doğrusal ayrışamayan veri setleridir [13]. DVM kullanılarak doğrusal ayrışabilen ve doğrusal ayrışamayan veri setleri şekil 2.5'te kabaca gösterilmiştir



Şekil 2.5. Destek Vektör Makinaları

Diskriminant Analizi

Diskriminant analizi (DA) yöntemi daha çok veri setinin karmaşık olduğu durumlarda veriyi daha kolay ayrılabilir hale getirmek için tercih edilen bir yöntemdir. Bu işlemi gerçekleştirmek için kovaryans matristen yararlanır. DA, veri setindeki sınıfları birbirinden ayırt etmek için sınıfların dağılımını inceleyip, bu sınıfların ortalama değerleri arasındaki farklılığı kullanmaktadır [14, 15].

k-En Yakın Komşu Algoritması

k-En Yakın Komşu Algoritması (KNN) sınıflandırılmak istenen verinin daha önceki verilerden k tanesine olan yakınlığına bakarak çalışan bir algoritmadır. KNN algoritması sınıflandırma aşamasında test ve eğitim verileri birbirleriyle karşılaştırılır. Bu karşılaştırma işlemlerinde komşuluk mesafelerinin ölçülmesinde daha çok Öklid bağlantısı tercih edilir [16]. Bu yöntem bulut teknolojisiyle birlikte gelen büyük veri setlerinden bilgi çıkarımında bulunmak için de tercih edilebilir. Bu algoritma gürültülü verilere karşı başarılı olabilen bir algoritma çeşididir [17].

2.1.2. Karar Ağaçları

Karar ağaçları sınıflandırma işleminde en çok tercih edilen yöntemlerden biridir. Karar ağaçları önceden tanımlanmış bir değişkene sahiplerdir. Yapıları gereği tepeden aşağıya doğru genişleyen bir yapıya sahiptirler. Karar ağaçları çok sayıda veriye sahip olan veri setlerini daha küçük kümelerle bölmek için kullanılan bir yöntemdir. Anlaşılmasının ve yorumlanmasının kolay olması, hem sayısal hem kategorik verileri işleyebilmesi bu yöntemin sıkça tercih edilmesinin sebeplerindedir. Karar ağaçları düğüm ve yapraklardan oluşmaktadır [18]. Karar ağacının yapısı şekil 2.6'da gösterilmiştir.



Şekil 2.6. Karar Ağaçları


Algoritma seçimi, hedef değişkenin tipine dayanır. Karar ağaçlarında en sık kullanılan algoritmalar; kategorik değişkenler için Entropi, Gini, Sınıflandırma Hatası; sürekli değişkenler için ise En Küçük Karalar yöntemi şeklindedir.

2.1.3. Regresyon

Regresyon Analizi, istatistik biliminin temel alanlarından biridir. Regresyon analizi bir rastgele değişkenin davranışının model kullanarak tahmin edilmesi işlemi olarak tanımlanabilir. Burada bağımlı ve bağımsız değişkenlerin birbiriyle olan ilişkileri incelenmektedir. Değişkenler arasındaki bu ilişki sayesinde modelleme veya tahmin işlemi gerçekleştirilir. İstatistik biliminde kullanılan birden fazla regresyon çeşidi bulunmaktadır. Ayrıca regresyon analizi, bulut teknolojisiyle gündeme gelen büyük veri setlerinin sınıflandırılması işleminde de sıklıkla kullanılan yöntemlerden biri haline gelmiştir [19, 20].

Doğrusal Regresyon

Yapılacak çalışmada tahmin edilen veriler ile değişkenlerin arasında doğrusal bir ilişki mevcut ise doğrusal regresyon tercih edilmektedir [21]. Doğrusal Regresyon eğrisi ve verilerin gösterimi Şekil 2.7’de verilmiştir.



Şekil 2.7. Doğrusal Regresyon


Makine öğreniminde doğrusal regresyon modeli Denklem 2.2’de gösterilmiştir.

$$y' = b + \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n \quad (2.2)$$

Burada y' istenen ya da öngörülen etikettir, b bias değeri, ω ilgili özelliğin ağırlık katsayısıdır, x ise bilinen girdi özelliğidir.

Polinomsal Regresyon

Mevcut verilerin dağılımı eğer doğrusal olarak dağılmamışsa o zaman doğrusal regresyon eğrisi çizmek mümkün olmayacaktır. Bu durumda veri setini bölmek için polinomsal regresyon işleminden faydalanılabilir [22]. Çizilecek regresyon eğrisi polinomsal olup Şekil 2.8’de verilmiştir.



Şekil 2.8. Polinomsal Regresyon


Makine öğreniminde polinomsal regresyon modeli Denklem 2.3'te gösterilmiştir.

$$y' = b + \omega_1 x_1^1 + \omega_2 x_2^2 + \dots + \omega_n x_n^n \quad (2.3)$$

Burada y' istenen ya da öngörülen etikettir, b bias değeri, ω ilgili özelliğin ağırlık katsayısıdır, x ise bilinen girdi özelliğidir.

2.2. Denetimsiz Makine Öğrenmesi

Denetimsiz öğrenme modelleri tanımlayıcı model kategorisindedirler. Çünkü burada modellerin amacı belirli bir sonucu tahmin etmek değildir. Bu yöntemlerde veri setlerindeki veriler arasındaki ilişkiler ortaya çıkartılır. Tespit edilen ilişkiler aracılığıyla veriler yakınlık durumuna göre gruplara ayrılır. Bu sayede girdi olarak gelen yeni veriler yakınlık durumuna göre ilgili gruba alınır. Burada kullanılan verilerde denetimli öğrenmeden farklı olarak etiketsiz veriler kullanılır. Yani model eğitilirken verilerin etiketleri modele verilmez. Veriler etiketsiz verilerdir. Burada denetimli öğrenmeden farklı olarak çıkıştaki sınıf sayısı belli değildir. Veriler yakınlık durumlarına göre gruplandırılır [23, 24]. Denetimsiz makine öğrenmesi modelinin çalışma prensibi Şekil 2.9'da gösterilmiştir.



Şekil 2.9. Denetimsiz öğrenme modelinin çalışma prensibi

2.2.1. Kümeleme Algoritmaları

Veriyi birbirine benzer elemanlardan oluşan kümelere ayırarak, heterojen bir veri grubundan, homojen bir alt veri grubu elde edilmesi amaçlanır. Kümeleme yöntemlerinin birçoğu veriler arasındaki uzaklıkları kullanır. Bunlar arasında en çok kullanılanlar Öklid uzaklığı, Manhattan uzaklığı ve Minkowski uzaklığıdır. Bu uzaklık fonksiyonları Denklem 2.4-2.6'da gösterilmiştir. Kümeleme yöntemlerinde kullanılan başlıca yöntemler sırasıyla verilmiştir [25, 26].

$$|x_i - y_i|_{\text{Öklid}} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (2.4)$$

$$|x_i - y_i|_{\text{Manhattan}} = \sum_{i=1}^k |x_i - y_i| \quad (2.5)$$

$$|x_i - y_i|_{\text{Minkowski}} = \left(\sum_{i=1}^k |x_i - y_i|^q \right)^{1/q} \quad (2.6)$$

Hiyerarşik Yöntemler

Hiyerarşik yöntemler, nesnelere dendogram denilen ağaç yapısı biçiminde gruplandırma mantığına dayanır. Bu yöntemler küme sayısının bilinmesine ihtiyaç duymazlar. Bu yöntemler ayrı ayrı ele alınan kümelerin aşamalı olarak birleştirilmesini sağlayan yöntemlerdir. Literatürde birden fazla hiyerarşik yöntem mevcuttur. Bunlardan en çok bilinenler en yakın komşu algoritması ve en uzak komşu algoritmasıdır [27].

Bölme Yöntemleri

Bölme yöntemleri, n adet nesnenin meydana gelen veri tabanını, giriş parametresi olarak belirtilen k adet bölüme ayırma işlemidir. Veri tabanındaki her bir veri farklılık fonksiyonuna göre k adet bölüme birine yerleştirilir. Burada elde edilen her bir bölüme küme denir. K-means algoritması ve k-medoids algoritması en bilinen algoritmalarındandır [28].

Yoğunluk Tabanlı Yöntemler

Yoğunluk tabanlı yöntemlerde bir eşik değeri belirlenir. Daha sonra bu eşik değerine göre, nesnelere dağılımı bir yoğunluk fonksiyonuyla hesaplanarak kümelere ayrıştırılır. Kümelere bulma başarısı oldukça yüksek olan yöntemlerdir. Gürültü ve istisnalardan fazla etkilenmediği için bulut bilişimde de rahatça kullanılabilir [29].

Izgara Tabanlı Yöntemler

Bu yöntem veri uzayını incelemek için sınırlı sayıda kare biçimindeki hücrelerden oluşan ızgara yapılarını kullanır [30]. Kullandıkları ızgara biçiminden dolayı veri tabanındaki nesne sayısından bağımsız çalışabildikleri için bulut bilişim de tercih edilebilen yöntemler arasındadır [31].

Model Tabanlı Yöntemler

Bu yöntemde veriler cebirsel bir model ile ifade edilir. Model tabanlı yöntemler istatistiksel yaklaşım ve yapay zekâ yaklaşımını kullandıklarından dolayı bulut bilişimde tercih edilen modeller arasındadırlar [32].

2.2.2. Saklı Markov Modeli

Bu modelde durumlar dışarıdan gözlemlenemez, yalnızca her bir durumun gözlem çıktıları izlenebilir. Bu modelde gözlemlerin tümü modelden bağımsızdır. Markov süreci, şu anda meydana

gelen bir olayın gelecekteki durumu hakkında olasılıklı bilgiler edinmeyi sağlar. Bu modelin kullanım alanı oldukça geniştir. Bu model pazarlama, eğitim, finans gibi birçok alanda yaygın bir şekilde kullanılmaktadır. Bundan dolayı bu modelde bulut bilişimde kullanılabilen modeller arasındadır [33, 34].

2.2.3. Birliktelik Kuralları

Birliktelik kuralları olayların birlikte gerçekleşme durumlarını çözümleyen bir yöntemdir. Birliktelik kuralları eş zamanlı olarak gerçekleşen birlikteliklerin tanımlanmasında da kullanılır. Bulut bilişimle ortaya çıkan büyük veri setlerinden farklı veriler arasındaki ilişkileri bulup, yorumlama işlemini gerçekleştirebilir. Özellikle pazarlama sektöründe yoğun bir şekilde kullanılmaktadır. Ayrıca kullanışlılığı ve kolay anlaşılması gibi nedenlerden dolayı ekonomi, telekomünikasyon, e-ticaret, sağlık ve pazarlama gibi birçok alanda kullanılmaktadır. Birliktelik kuralları çıkarımında kullanılan algoritmaları sıralı ve paralel olmak üzere iki başlık altında toplamak mümkündür [35, 36].

Sıralı Algoritmalar

Birliktelik kuralları çıkartılırken birçok verinin sıralı olarak tanımlandığı ve veri tabanlarında bu şekilde tutulduğu kabul edilir. Sıralama algoritmalarında sıralı nesnelere nesne kümeleri oluşturulduğunda kolaylık sağladığı rastlanan bir yaklaşımdır. Ais, Apriori, Setm, Partitioning algoritması, Sampling algoritması, Carma ve Fp-Growth en bilinen sıralı algoritmalarıdır. Bu grup bulut bilişimde en çok tercih edilen algoritmalar grubunu oluşturmaktadırlar [37].


Paralel ve Dağıtılmış Algoritmalar

Paralel algoritmalar nesne kümelerinin bulunması işleminin paralelleştirilmesi üzerine odaklıdır. Paralel ve dağıtılmış algoritmalar genellikle paralelleştirme mantığı üzerine çalışır. Bu algoritmaların çalışma mantığında ya veri paralelleştirilir ya da görev paralelleştirilir. Bulut bilişim ile gelen büyük miktarlardaki veri setlerini işlerken bu modellerin paralel özelliklerinden faydalanılabilir. Count Distribution, Paralel Data Mining, Distributed Mining Algorithm, Common Candidate Partitioned Database, Data Distribution, Intelligent Data Distribution, Skew Handling ve Hybrid Distribution en bilinen algoritmalarıdır. Bu algoritmalar paralel çalışabildiği için bulut teknolojisinde tercih edilen algoritmalar arasında yerini almışlardır.

2.3. Takviyeli Makine Öğrenmesi

Takviyeli öğrenme (TÖ), denetimli ve denetimsiz makine öğrenmesinden farklı bir şekilde çalışmaktadır. TÖ'nün mantığında problemler bilinmemektedir fakat doğru cevap bilinmemektedir.

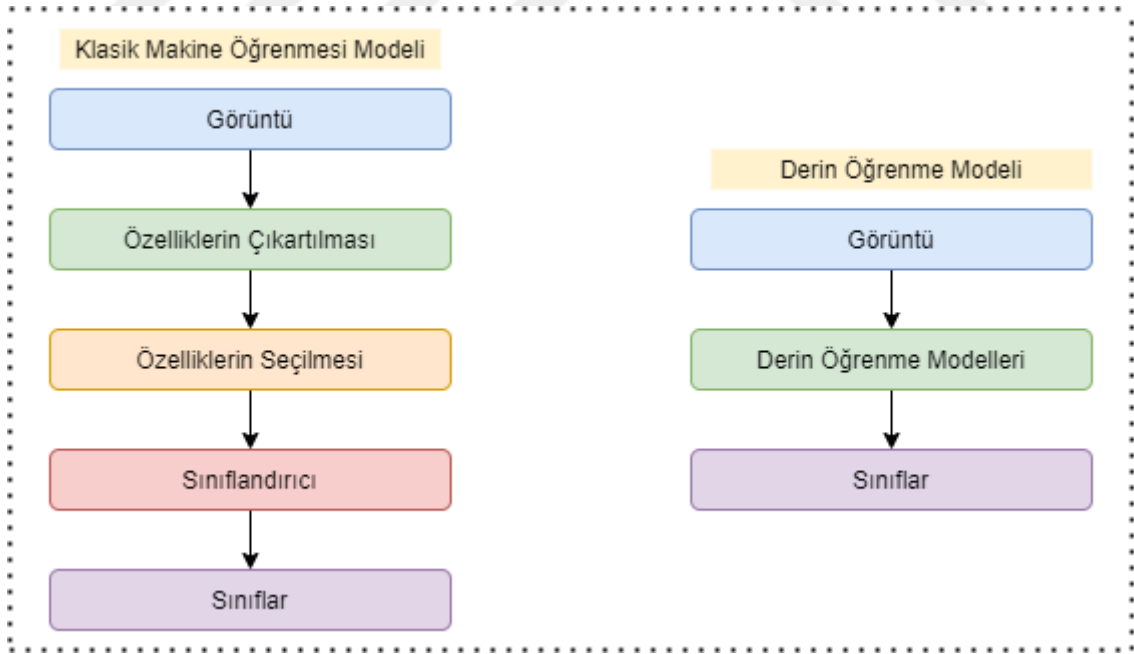
TÖ modelleri daha çok YSA'da kullanılmaktadır. Özellikle zamana bağlı değişen problemlerde etkin bir şekilde kullanılabilir. TÖ hastalık tanı ve teşhisi, oyun programlama, robotik ve otomasyon gibi sistemlerde yaygın bir şekilde kullanılmaktadır. TÖ ortamlarında etmenin bir hareketinin karşılığı olarak ödül veya ceza ile takviye işlemi gerçekleştirilir. Bu şekilde etmenin amaca ulaşması için gerçekleştirilebilecek en iyi eylemin seçilmesi amaçlanır. Takviyeli öğrenmede amaç en iyi çözümü bulmaktır. Etmenin en iyi çözümü bulması demek aynı zamanda en yüksek ödül değerine de ulaşması anlamına gelmektedir. TÖ modeli Şekil 2.10'da verilmiştir.



Şekil 2.10. Takviyeli makine öğrenmesi modeli

3. DERİN ÖĞRENME

Derin öğrenme özellikle 2010'lu yıllardan sonra popüler olmaya başlamıştır. Derin öğrenme hakkında yapılmış birden fazla tanım mevcuttur. Bu tanımları genel anlamda birleştirecek derin öğrenmeyi makinelerin özellik çıkarımı, bu özellikleri algılaması, öğrenmesi ve yorumlaması olarak tanımlayabiliriz. Tanımından da anlaşılacağı üzere derin öğrenmeyi klasik makine öğrenmesinden ayıran en büyük özelliklerden biri, özneliklerin alanında uzman kişiler tarafından çıkarılmamasıdır [38, 39]. Klasik makine öğrenmesi yöntemlerinde özellikler alanında uzman kişiler tarafından çıkarıldığından dolayı zaman kaybına ve maliyetin yükselmesine sebep olmaktadır. Klasik makine öğrenmesi yöntemleri ham veriyi ön işlem adımından geçirmeden ve konu hakkında uzman yardımı almadan işleyemezler. Derin öğrenme ile klasik makine öğrenmesinin bu problemi ortadan kaldırılmıştır. Yani derin öğrenme mimarilerinde öznelikler kullanılan katmanlar sayesinde otomatik olarak çıkarılmaktadır. Ayrıca derin öğrenme mimarilerinde verilere ön işleme yapmaya gerek yoktur. Derin öğrenme ağları birbirini takip eden birden fazla katmandan oluşmaktadır. Her katmanın çıkışı kendisinden sonraki katmanın veya katmanların girişi olmaktadır [40, 41]. Klasik makine öğrenmesi ve derin öğrenme modelinin kabaca akış diyagramları Şekil 3.1'de verilmiştir.

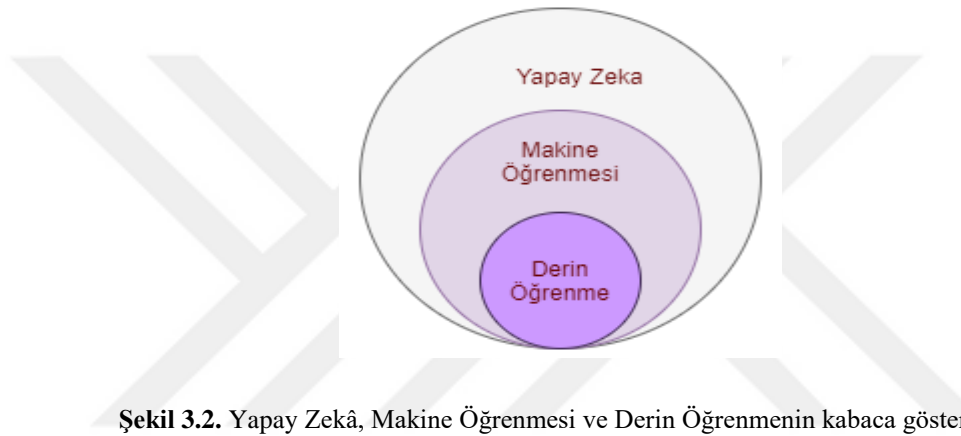


Şekil 3.1. Klasik makine öğrenmesi ve derin öğrenme modellerinin akış şeması

Derin öğrenme kavramı her ne kadar eskilere dayansa da son yıllarda popüler olmaya başlamıştır. Gelişen teknolojiyle birlikte veri tabanlarında tutulan verilerin miktarları artmaya

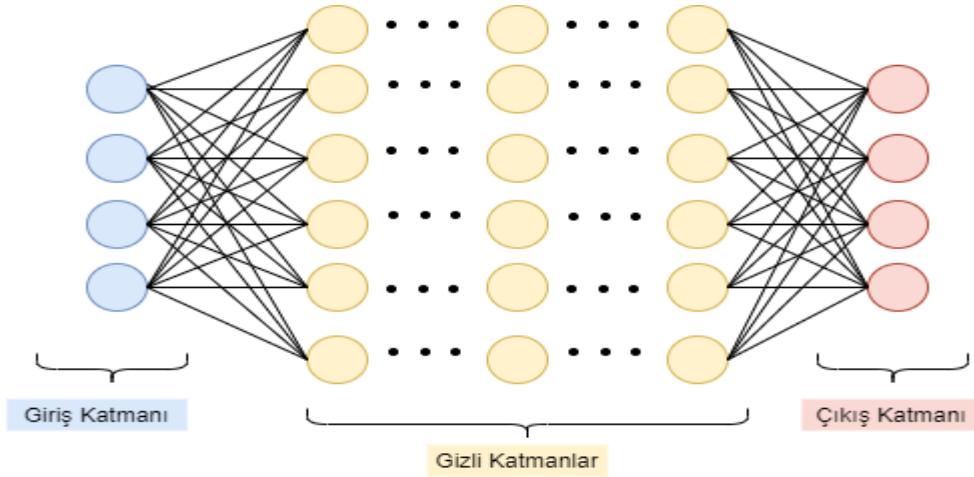
başlamıştır. Veri setlerinde tutulan bu bilgilerin değerli olabilmesi için işlenmesi gerekmektedir. İşlenen bu verilerin sonuçları kullanılırsa bu veri setlerindeki veriler anlam kazanmış olacaktır. Klasik makine öğrenmesi yöntemleriyle bu süreci gerçekleştirmek oldukça zor görünmektedir [42, 43]. Son yıllarda bilgisayarların hızlarının artması ve sonrasında grafik işlemci birimlerinin (GPU) kullanılması ile birlikte veri setlerinde tutulan bu verilerin daha kolay işlenmesine yol açmıştır. Özellikle 2012 yılında Alexnet mimarisinin ILSVRC ImageNet yarışmasını kazanmasıyla birlikte derin öğrenme yeniden gündeme gelip, popüler olmaya başlamıştır [44, 45].

Makine öğrenmesini yapay zekânın bir alt kolu, derin öğrenmeyi de makine öğrenmesinin bir alt kolu olarak tanımlarsak, bunu Şekil 3.2'deki gibi gösterebiliriz.



Şekil 3.2. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin kabaca gösterimi

Derin öğrenme ağlarının temeli YSA'lara dayanmaktadır. Derin öğrenme ağları birden fazla işlem birimi katmanı kullanarak ham veriden öznitelikleri çıkartabilen makine öğrenmesinin bir alt koludur. Derin öğrenme mimarilerinde birden fazla katman kullanılmaktadır [46]. Derin öğrenme mimarilerinin ağ yapısı Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Derin öğrenme sinir ağı


Derin öğrenme son yıllarda teknolojinin de gelişmesiyle birlikte oldukça fazla kullanılmaya başlanmıştır. Derin öğrenme hayatımıza sanal yardımcıları olarak girmiş durumdadır. Örneğin bir robotla konuştuğumuzda bizi anlayabilmesi buna bir örnektir. Derin öğrenme biyomedikal görüntülerden hastalık teşhisi ve derecelendirilmesi işleminde [47], insan hareketlerinin tanınmasında [48], alışveriş ve eğlence sektöründe [49], yüz tanımda [50], sürücüsüz arabalarda [51], görüntü sınıflandırmada [52], video işlemede [53], nesnelerin internetinde [54] ve benzeri birçok yerde kullanılmaya başlanmıştır. Bu tez çalışmasında derin öğrenme mimarileri görüntü sınıflandırma problemlerinde kullanılmıştır.

3.1. Derin Öğrenme Mimarileri

Gelişen teknolojiyle birlikte literatürde geliştirilen birden fazla derin öğrenme mimarisi mevcuttur. Derin öğrenme mimarileri tercih edilirken birden fazla parametrenin göz önünde bulundurulması gereklidir. Bu parametreler göz önünde bulundurularak ona göre mimari seçimi yapılması gerekmektedir. Kullanılan verinin türü, verinin miktarı ve çalışmanın konusu kullanılacak mimarinin seçimini etkileyecek ana parametrelerdendir. Bu bölümde Tekrarlayan Sinir Ağları (RNN), Uzun Kısa Vadeli Hafıza Ağları (LSTM), Boltzmann Makinaları (BM), Derin İnanç Ağları (DİA), Derin Oto Kodlayıcılar (DOK) ve Evrimsel Sinir Ağları (ESA) incelenmiştir [55]. Yapılan çalışmada daha çok ESA mimarileri kullanılmıştır.

3.1.1. Tekrarlayan Sinir ağları

Geleneksel sinir ağlarında giriş verisiyle çıkış verisinin birbirinden bağımsız olduğu kabul edilmektedir. Yani geleneksel sinir ağlarında geçmiş bilgisinin ihmal edildiği anlamına gelmektedir. RNN mimarisi geleneksel sinir ağları mimarilerinden farklı olarak, geçmiş ile alakalı bilgiyi sakladığından dolayı, herhangi bir noktada gelecek tahmini yapmak için önceden öğrenilmiş bilgileri kullanan döngülerden oluşmaktadır [56, 57]. Şekil 3.4'te RNN yapısı kabaca gösterilmiştir.

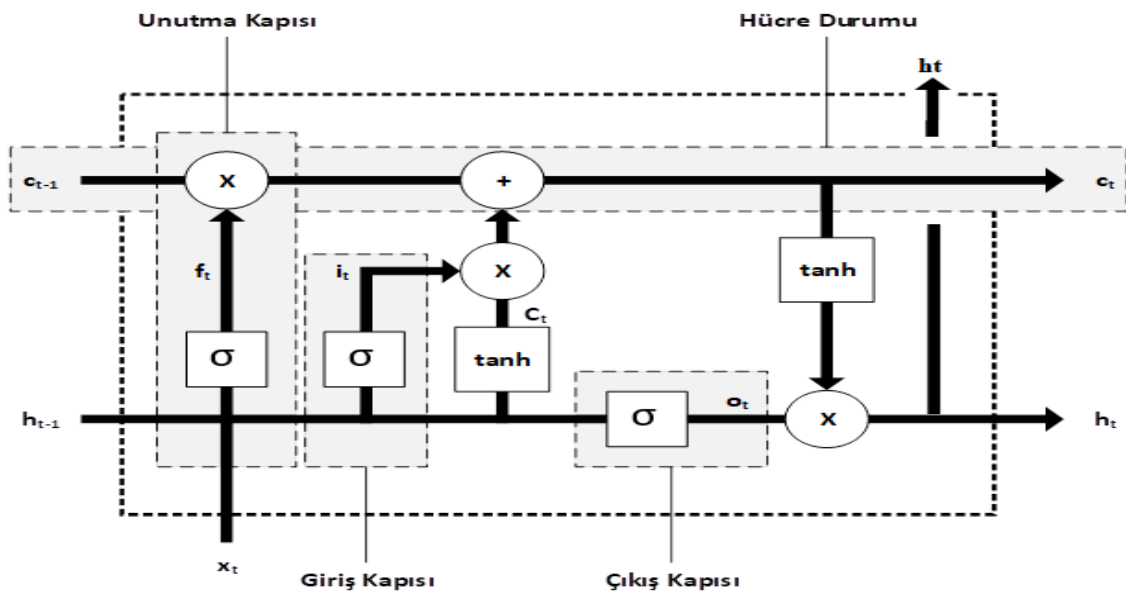


Şekil 3.4. RNN mimarisi

RNN mimarilerindeki her katmanın belirli bir ağırlığı vardır ve bu katmanlara has bir şekilde eşik değerleri seçilir. Burada yapılmak istenen şey sistemin daha iyi sonuçlar vermesinin istenmesidir. Tekrarlanan bu aşamalar sonucunda bir önceki giriş durumu saklanır ve elde edilen yeni giriş değeriyle birleştirilir. Bununla beraber yeni elde edilen girişin bir önceki girişle ilişkili olması sağlanmış olunur. RNN'ler teknolojinin gelişmesiyle birlikte farklı alanlarda kullanılmaya başlanmışlardır. Bu tarz çalışan mimarilerde dinamik hafıza olmak zorundadır. Bu alanların başında kelime tahmini gelmektedir. Konuşma tanıma, borsa tahmini, zaman serileri tahmini ve filmlerdeki altyazıların tahmini gibi alanlar bunlardan bazılarıdır [58, 59].

3.1.2. Uzun Kısa Vadeli Hafıza Ağları


RNN ağlarında geçmiş verilerin öğrenilebilmesi için geleneksel sinir ağlarında olduğu gibi bunda da geriye yayılım algoritması kullanılmaktadır. Ancak RNN ağlarında geriye doğru hesaplama yapıldığında türevlerinin ya azalarak yok olmasına (vanishing gradient) ya da çok yüksek değerlere (exploding gradient) çıkmasına sebep olacaktır [60]. Bundan dolayı RNN'lerin eğitimi zorlaşmaktadır. Ayrıca RNN mimarilerinde dizeler arasında bağlam boşlukları olması durumunda, sonraki dizenin tahmin edilmesi zor bir durum haline gelecektir. Hochreiter ve Schmidhuber yaptıkları çalışmalarında bu dezavantajları ortadan kaldırmak için LSTM'leri önermişlerdir [61]. LSTM ağlarının RNN ağlarından farkı önceki durumu ve girdi bilgisini tutan hücrelerin olmasıdır. LSTM ağlarında yer alan bu hücreler hangi verinin tutulup hangi verinin silineceğine karar verirler. Bu sayede LSTM ağları, zamansal verideki örüntülerin öğrenilebilmesinin önünü açmaktadır [62]. Şekilde 3.5'te LSTM ağının yapısı gösterilmiştir.



Şekil 3.5. LSTM ağı

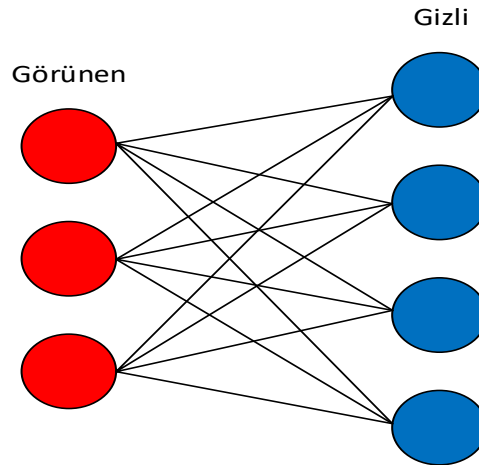
3.1.3. Boltzmann Makineleri

Boltzmann makineleri (BM) giriş veri setinde olasılıksal dağılımları öğrenebilen, regresyon, sınıflandırma ve özellik öğrenimi yapabilen bir sinir ağıdır. BM’de bütün birimler birbirine bağlı olduğundan dolayı özyinelemeli bir yapı söz konusudur. Bu makinelerde gizli katman ve görünen katman olmak üzere 2 tür katman mevcuttur. Gizli katmanda öğrenilen değerler, bir sonraki mimaride girdi değeri olmaktadır. Bu işlemler birden fazla kere tekrarlanarak istenen örüntüler oluşturulmaktadır [63]. Şekil 3.6’da BM’nin yapısı verilmiştir.



Şekil 3.6. Boltzmann Makinesi


BM’nin bazı dezavantajlarını ortadan kaldırmak için Sınırlı Boltzmann makineleri (SBM) geliştirilmiştir. SBM’de düğümler birbirlerine katmanlar halinde bağlanmaktadır fakat BM’de olduğu gibi aynı katmandaki düğümler arasında bağlantı yoktur [64]. SBM’nin mimarisi Şekil 3.7’de verilmiştir.



Şekil 3.7. Sınırlı Boltzmann Makinesi

3.1.4. Derin İnanç Ağları


Derin inanç ağları (DİA), Kısıtlı Boltzmann makinelerinin (SBM) bir araya gelmesiyle oluşmaktadır. Burada SBM'ler art arda eklenmektedir. DİA daha çok görüntü tanımlama, video dizeleri, hareket yakalama ve konuşma tanımlama gibi alanlarda tercih edilmektedir. Şekil 3.8'de de görüleceği gibi DİA'da katmanlar arasında bağlantı mevcutken, o katmanda ki düğümler arasında bağlantı yoktur [65, 66].



Şekil 3.8. Derin inanç ağları


3.1.5. Oto Kodlayıcılar

Oto kodlayıcılar (OK) denetimsiz öğrenme de tercih edilen bir yapay sinir ağı (YSA) çeşididir. OK'lar giriş katmanında aldığı veriyi çıktı katmanında tekrar elde etmek için eğitilmişlerdir. Yani giriş katmanında girdi olarak verilen veriler çıkış katmanında tekrardan elde edilir. OK'lar kabaca üç kısımdan oluşmaktadır. Bu kısımları giriş katmanı, gizli katman ve çıkış katmanı olarak tanımlamak mümkündür. Burada amaçlanan hedef giriş verisinin sıkıştırılmış halinden en iyi özelliklerin öğrenilmesidir. OK'lar kodlayıcı ve kod çözücü olmak üzere 2 kısımdan oluşmaktadır. Giriş katmanında ki giriş verisi gizli katmanda kodlanır. Kodlanan bu veri daha gizli ve daha karışık bir hale dönüşür. Kodlanan bu verinin boyutu da indirgenmiş olur. Kodlanan bu veri özellik çıkarımı içinde kullanılır. Gizli katmanın çıkış değeri kod çözücü ile çözülüp girdi verisi tekrar elde edilmeye çalışılır. Buradaki asıl amaç sıkıştırılmış veriden en iyi özelliklerin öğrenilmesinin sağlanmasıdır [67, 68]. Şekil 3.9'da OK mimarisi verilmiştir.



Şekil 3.9. Oto kodlayıcı mimarisi

Derin Oto Kodlayıcı (DOK)'larda ise her bir katmandaki çıktılar ardışık katmanındaki girişlere bağlanır. Yani tipik OK'ların çok katmanlı hali gibi düşünülebilir [69]. Şekil 3.10'da DOK mimarisinin kabaca gösterimi verilmiştir.



Şekil 3.10. Derin oto kodlayıcı mimarisi

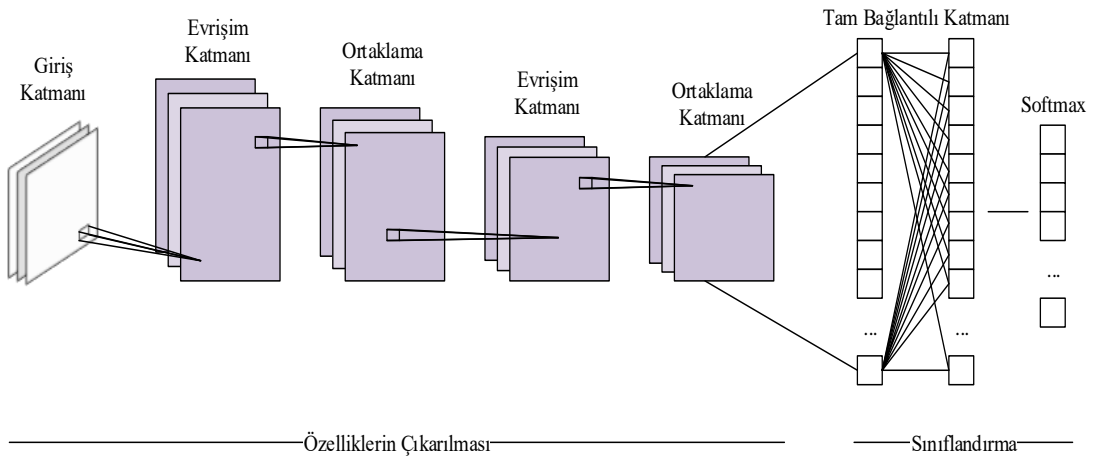
3.1.6. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (ESA) bilgisayarlı görü alanında yüksek başarımlar elde etmesinden dolayı görüntü tanıma, sinyal işleme, doğal dil işleme, duygu tanıma, segmentasyon, sınıflandırma,

nesne tanıma gibi çalışmalarda sıklıkla kullanılmaktadır. Derin öğrenme mimarileri içerisinde en fazla kullanılan mimarilerden biridir [70, 71]. Tez çalışmasında ESA mimarilerinden detaylı bir şekilde faydalandığı için ESA mimarileri başlık 3.2’de detaylı bir şekilde incelenmiştir.

3.2. Evrişimsel Sinir Ağları

ESA’lar 1989 yılında Yann Lecun ve arkadaşları tarafından yapılan çalışmayla gündeme gelmiştir [72]. Durağan bir dönem geçiren ESA mimarilerinin popüler olmasının sebeplerinden biri 2012 yılında Alexnet modelinin ILSVRC ImageNet yarışmasını kazanmasıdır. ESA mimarilerinin popüler olmaya başlamasının bir başka nedeni ise gelişen teknoloji ile birlikte veri tabanlarında tutulan bilgilerin artması ve bu büyük veri setlerini işlemek için güçlü makinelerin var olmasıdır. Yaşanan olumlu gelişmeler ve duyulan ihtiyaçtan dolayı duraksama döneminde olan ESA mimarileri her geçen gün daha popüler olmaya başlamıştır [73]. ESA mimarilerinin son dönemlerde popüler olmasının bir başka nedeni, klasik makine öğrenmesi mimarilerindeki öznitelik çıkarma sorununun ESA mimarilerinde çözülmüş olmasıdır. Klasik makine öğrenmesi yöntemlerinde öznitelik çıkarım işlemi oldukça sıkıntılı bir süreçtir. Bu süreçte alanında uzman kişilere ihtiyaç duyulmaktadır. Bu durumun hem maliyet açısından hem de zaman açısından olumsuz yönleri mevcuttur. ESA mimarileri ise klasik makine öğrenmesi yöntemlerinden farklı olarak öğrenme işlemi direk model üzerinde gerçekleştirilebilmektedir. ESA mimarilerinde veriler giriş katmanı üzerinden modele direk verilmektedir. Burada her hangi bir ön işlem adımına gerek duyulmamaktadır. ESA modelleri öznitelikleri kendisi çıkarabilmektedir. Bundan dolayı ESA mimarilerinde öznitelik çıkarma işlemi uzman tarafından değil, direk model tarafından yapılmaktadır. Bu da uzman tarafından öznitelik çıkarma sorununu ortadan kaldırmıştır [74, 75]. ESA’larda oluşturulan modeller genel olarak 2 kısımdan oluşmaktadır. İlk kısımda öznitelikler çıkarılmaktadır, ikinci kısımda ise sınıflandırma yapılmaktadır. Bu yapı Şekil 3.11’de verilmiştir.



Şekil 3.11. ESA mimarilerinin kabaca gösterimi

ESA modelleri oluşturulurken belirli katmanlar kullanılır. Bu katmanlar ileri yönlü çalışmaktadır. Bu modellerde kullanılan katmanların sayısının veya dizilişinin belirli bir standardı yoktur. Literatürde kabul görmüş modellerde de bu katmanların sayıları veya dizilişleri birbirlerinden farklıdır. Geliştirilen modellerde kullanılan katman sayısının modelin başarımı ile orantılı değildir. Yani katman sayısı arttıkça modelin doğruluk oranının artacağına garanti yoktur. Modeller tasarlanırken önemli olan katmanların dizilişlerinin ve parametre değerlerinin nasıl ayarlandığıdır.


Bu bölümde ESA katmanları, önceden eğitilmiş ESA modelleri ve ESA modellerinde kullanılan aktivasyon fonksiyonları incelenmiştir.

3.2.1. Evrimsel Sinir Ağları Modelleri

Son yıllarda görüntü işleme alanında ESA mimarileri oldukça fazla kullanılmaya başlanmıştır. Bu ESA modelleri görüntü işlemeyle ilgili neredeyse tüm alanlarda kullanılmaktadır. Önceden eğitilmiş ESA modelleri sınıflandırma işlemini gerçekleştirebilmektedirler. ESA modellerinin özünde, modellerin eğitim verileriyle eğitilmesi ve daha sonra ağın performansını ölçmek için test verileriyle ağın test edilmesi yatmaktadır. Bu modellerin başarımlarını belirlemek için kullanılan başlıca parametreler mevcuttur. Modellerin başarı oranları farklı şekillerde hesaplanabilmektedir. Ayrıca literatürde farklı amaçlar için geliştirilmiş birçok ESA modeli bulunmaktadır. Bu modeller daha çok görüntü tanıma ve sınıflandırma, ses verilerinin tanınması, sinyal işleme gibi birçok alanda kullanılabilir [76]. Bu çalışmada kullanılan ESA modelleri görüntü sınıflandırma işleminde en yaygın kullanılan ve en bilinen mimarilerdir.

Alexnet

2012 yılında ILSVRC ImageNet yarışmasını kazanan Alexnet modeli, ESA'lar ve derin öğrenme için yeni bir dönemin başlangıcı olmuştur. Durağan bir dönem geçiren derin öğrenme 2012 yılından sonra tekrar gündeme gelmiştir. Bu ESA modeli Alex Krizhevsky, Ilya Sutskever and Geoffrey Hinton tarafından sunulmuştur. Alexnet modeli birbirini takip eden evrim ve ortaklama katmanlarından dolayı Lenet mimarisine benzetilmektedir. 2012 yılında yapılan ImageNet ILSVRC yarışmasında, sınıflandırma doğruluk oranını %74.3'den %83.6'ya çıkarmıştır. GPU mimarisi üzerinde çalışan oldukça derin ve güçlü bir modeldir. Yaklaşık 60 milyon parametre hesabına ulaşmaktadır. Alexnet mimarisi 1000 nesneyi sınıflandıracak şekilde tasarlanmıştır [77]. Alexnet mimarisinin yapısı Şekil 3.12'de verilmiştir.

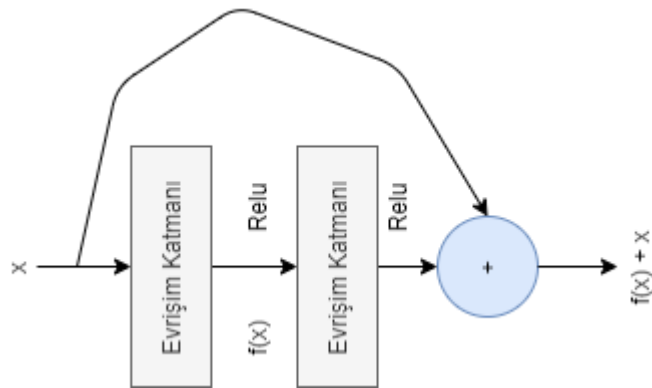


Şekil 3.12. Alexnet mimarisi [77]

Alexnet mimarisi 1 giriş katmanı, 5 evrişim katmanı, 7 Relu, 2 normalleştirme, 3 tam bağlı, 2 seyreltme, 3 ortaklama, 1 softmax ve 1 sınıflandırma olmak üzere 25 katmandan oluşmaktadır [78]. Alexnet Relu aktivasyon fonksiyonu ve seyreltme tekniğini derin öğrenme modellerinde kullanan öncü modellerdendir.


Resnet50

Derin öğrenme mimarilerinde fazla sayıda katman eklenmesi her zaman ağın başarımını artırmaz. Çünkü artan ağ derinliği beraberinde gradyan problemini de getirmektedir. Bir önceki katmanlardan gelen gradyanlar zincirleme olarak hesaplandığında sıfıra yaklaşmaktadır. Bundan dolayı katman sayısı artıkça gradyan değerleri küçülerek sıfıra yaklaşır ki bu da istenmeyen bir durumdur. Resnet modelinde bu problem artık (Residual) bloklar kullanılarak aşılmaya çalışılmıştır. Resnet modelinde gradyan hesaplamak yerine $f(x)$ fonksiyonuna aritmetik olarak x girdisi ekleyerek kısa yol bağlantısı sunulmuştur. Böylece bu değer $f(x) + x$ olarak diğer katmana aktarılmış olunur. Şekil 3.13'te bu yapı gösterilmiştir.



Şekil 3.13. Resnet mimarisi kısa yol bağlantısı


Resnet modeli 2015 yılında He vd. tarafından geliştirilen bir modeldir. Resnet modeli 2015 yılında yapılan ILSVRC ImageNet yarışmasının kazananıdır. Resnet modelini kendisinden önceki modellerden ayıran farklardan en önemlisi daha derin bir yapıya sahip olmasıdır. ILSVRC 2015 yılında yapılan yarışmada %3,6 hata oranı ile birinci olmuş bir yapıdır [79]. Toplu normalleştirmeyi ilk kullanan algoritmalardandır. 26 Milyon parametreye sahip olan bu model 152 katmandan oluşmaktadır. Şekil 3.14’de artık bir ağ ve düz bir ağ gösterimi verilmiştir.



Şekil 3.14. Üstteki şekil artık (residual) bir ağ mimarisini, alttaki şekil düz (plain) bir ağ mimarisini göstermektedir [79].

Googlenet

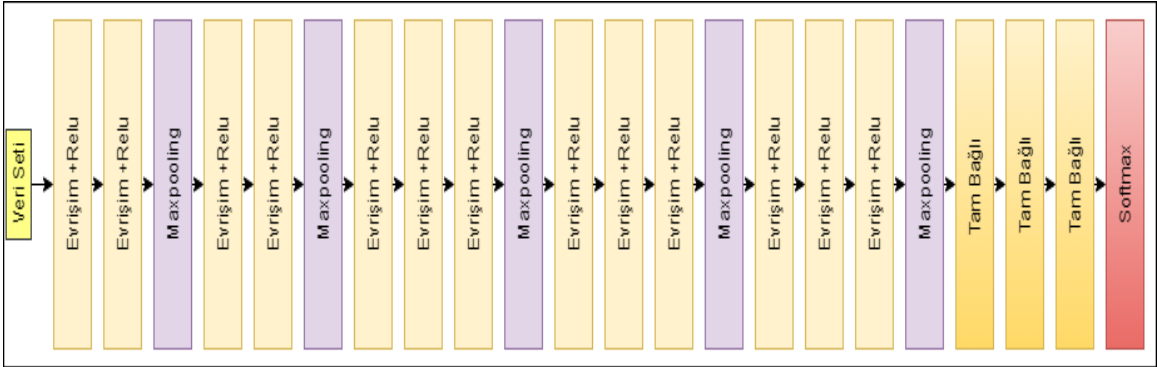
Googlenet %6.66 hata oranı ile 2014 yılında ILSVRC ImageNet yarışmasının kazananı olmuştur. Bu model ardışık bir yapıda katmanları sıralamaktan uzaklaşmaya başlayan ilk modellerden biridir. Googlenet ağın bellek maliyetini azaltmak ve ağın ezberleme olasılığını düşürmek için çok sayıda ardışık katmanları üst üste ekleyip filtreler kullanmak yerine birbirine paralel bağlı modüller kullanmıştır. Bu modüllere başlangıç (Inception) modülleri denilmiştir. Bu modüllerden dolayı Googlenet modeli kendisinden önceki modellere göre daha karmaşık bir mimariye sahiptir. Burada özetle 1x1, 3x3, 5x5 evrişim filtreleri sonra inception modülünde bu filtreler toplanarak bir sonraki katmana giriş olarak verilmektedir. Bu modül sayesinde bir nesneye ait hem genel hem de spesifik özellikler çıkartılmış olur [80]. Şekil 3.15’te Googlenet mimarisini göstermektedir.



Şekil 3.15. Googlenet mimarisi [80]

Vgg16

2014 yılında ILSVCR Imagenet yarışmasında önerilen Vgg modeli Simonyan ve Zisserman tarafından geliştirilmiştir [81]. Vgg modeli Alexnet modelinden sonra derin ağların yüksek performans sağlayacağına inanılarak tasarlanmıştır. Bu modelde 138 milyon civarı parametre mevcut olduğundan, modelin bellek kullanımı çok fazladır. Bu mimari her evrişim katmanında değişken 3x3 boyutlu filtreler kullanmıştır. Model giriş verilerini 224x224x3 boyutunda almaktadır. Toplamda 41 katmandan oluşan Vgg16 modelinde aktivasyon fonksiyonu olarak RELU, ortaklama işlemi için ise maksimum ortaklama tercih edilmiştir. Şekil 3.16'da Vgg16 derin öğrenme mimarisinin blok diyagramı verilmiştir.




Şekil 3.16. Vgg16 mimarisi

Densenet201

Huang ve arkadaşları tarafından önerilen bu mimari mantık olarak Resnet mimarisine benzemektedir [82]. Fakat üretilen aktivasyon fonksiyonları daha sonraki katmanlara eklenmek yerine, basit bir şekilde bir araya getirilir. Bundan dolayı önceki katmanlardan gelen aktivasyonlara ek olarak orijinal veriler, her tür katmanda tutulmaktadır. Bu mimaride girdi ve çıktıya yakın katmanlar arasında daha kısa bağlantılar olduğundan dolayı bu modelin daha yoğun ve daha verimli

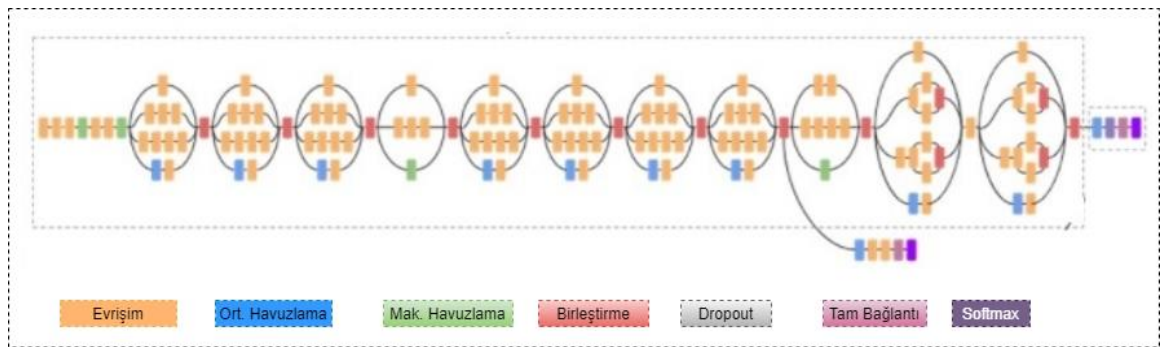
olduğu belirtilmiştir. Bu sayede daha küçük filtreler kullanılmıştır. Densenet modelinin en büyük özelliklerinden biride tüm katmanlar doğrudan çıktı katmanına bağlı olduğu için yok olan gradyan sorunu en aza indirgenmiş olur. Şekil 3.17’de modelin mimarisi verilmiştir.



Şekil 3.17. Densenet201 mimarisi [83]

InceptionV3

Szegedy ve arkadaşları [84] tarafından inceptionv1 ve inceptionv2 modelleri geliştirilerek elde edilmiştir. Inceptionv3 modelini evrişim bloğu, başlangıç bloğu ve sınıflandırıcı bloğu olmak üzere üç bölümden oluşan bir model olarak tanımlamışlardır [85]. Bu model girdi verilerini 299x299 boyutunda alır. Inceptionv3 modeli toplam 315 katmandan oluşmaktadır. Inceptionv3 modelinde, aktivasyon fonksiyonu olarak Relu kullanılır, normalleştirme için toplu normalleştirme ve ortaklama için maksimum ortaklama ve ortalama ortaklama birlikte kullanılır. Modelin mimarisi Şekil 3.18’de verilmiştir.



Şekil 3.18. InceptionV3 mimarisi [86].

Efficientnetb0

GoogleBrain ekibi ESA’ların performansını iyileştirmenin geleneksel yolu, derin öğrenme modelinin derinliğini artırmaktan geçmektedir düşüncesinin aksine yalnızca derinlik değil, aynı zamanda genişlik ve çözünürlük faktörlerinin de doğruluğu ve hesaplama maliyetlerini

etkilediklerini belirtmişlerdir. Derinlik ifadesinin, hâlihazırda mevcut olan derin evrişimli modelin arasına veya üstüne ek katmanlar eklemek anlamına geldiğini, bu yüzden derinlikteki artış, daha fazla hesaplama gücü ve kaynak gerektirdiği için geri tepebileceğini ifade etmişlerdir. Efficientnet modeli tasarlandığı zaman derinlik, genişlik ve çözünürlük parametreleri birlikte göz önünde bulundurulmuştur. Efficientnet modelinde bileşik bir katsayı kullanılarak derinlik, genişlik ve çözünürlük boyutlarını eşit şekilde ölçeklediklerini ifade etmişlerdir [87]. Efficientnet modeline ait temel ağ yapısı Tablo 3.1’de verilmiştir.

Tablo 3.1. EfficienNetb0 temel ağ yapısı

Stage i	Operator Fi	Çözünürlük H _i x W _i	Kanallar C _i	Katmanlar L _i
1	Conv3x3	224x224	32	1
2	MBCConv1, k3x3	112x112	16	1
3	MBCConv6, k3x3	112x112	24	2
4	MBCConv6, k5x5	56x56	40	2
5	MBCConv6, k3x3	28x28	80	3
6	MBCConv6, k5x5	14x14	112	3
7	MBCConv6, k5x5	14x14	192	4
8	MBCConv6, k3x3	7x7	320	1
9	Conv1x1	7x7	1280	1
&ortaklama & FC				

Ağların derinliğini artırma üzerine gerçekleştirilen modeller mevcuttur. Modellerin performansını artırmak için ağların derinliği artırılmıştır. Ağların derinliği arttığı zaman her zaman performansın yükselmeyeceği üzerine yapılmış çalışmalar mevcuttur. Çünkü ağların derinliği arttığı zaman gradyan sorunu ortaya çıktığından modellerin eğitilmesi daha zor olmaktadır. Efficientnet modelinde ağların derinliğini artırmaktan ziyade genişliğinin ve çözünürlüğünün dengeli bir şekilde artırılması gerektiği belirlenmiştir.

Ağ genişliğini ölçeklendirme, yaygın olarak küçük boyutlu modellerde kullanılır. Çünkü daha geniş ağlar, daha ayrıntılı özellikleri yakalayabilir ve eğitilmesi daha kolaydır. Bununla birlikte, son derece geniş ancak sığ ağlar, daha yüksek seviyeli özellikleri yakalamada zorluk yaşama eğiliminde olduğu belirtilmiştir.

Çözünürlük ölçeklendirme de ise çözünürlüğü artırmak belirli bir noktadan sonra modelin performansı üzerinde önemli bir etki sağlamaz. Bir görüntünün çözünürlüğü görüntünün yüksekliği x genişliği demektir. 512 x 512 boyutundaki bir görüntü, 256 x 256 boyutundaki bir görüntüye kıyasla daha fazla bilgiye sahiptir. Bununla birlikte, yüksek çözünürlüklü girdiler almak her zaman hesaplama ihtiyacına yük getirme eğilimindedir. Bu sebeple çözünürlüğün yüksek olmasının da avantajları yanında dezavantajları vardır.

Darknet53

Darknet53 Yolov2'deki Darknet19 ile Resnet' in birleşiminden oluşmaktadır. Resnet ağının tecrübesinden faydalanılarak geçmiş katmanlardaki değerler kendisinden sonra gelecek olan katmanlara daha güçlü bir şekilde iletilmiş olacaktır. 75 katmandan oluşan bu modelde 53 tane evrişim katmanı kullanılmıştır. Burada 1x1 ve 3x3 filtreler tercih edilmiştir. Darknet53 mimarisinde neredeyse her evrişim katmanından sonra yığın normalleştirme tercih edilmiştir. Yığın normalleştirme işleminden sonra ise Leakly Relu tercih edilmiştir [88].

MobileNetv2

Derin öğrenme modelleri her geçen gün daha çok kullanılmaya başlanmıştır. Bu kullanım beraberinde büyük veri setlerini getirmektedir. Bu yüksek miktardaki büyük veri setlerini işlemek için güçlü işlemci birimlerine ihtiyaç duyulmaktadır. Veri sayıları arttıkça derin öğrenme modelleri de o denli karmaşıklaşmaktadır. Modellerin başarımları artsa da hız konusunda tatmin edici sonuçlar alınmamaktadır. Bu nedenle araştırmacılar daha az parametreye sahip, başarımları performansı ve çalışma hızı yüksek modeller geliştirmeye yönelmişlerdir. MobileNet mimarisi de Howard ve arkadaşları [89] tarafından 2017 yılında geliştirilmiştir. Bu mimaride daha düşük veri işleme yeteneğine sahip mobil ve derin öğrenme uygulamalarını gerçekleştirmeyi amaçlamışlardır. Bu mimari özellik çıkarma aşamasında, klasik evrişim işlemi yerine derinlemesine ayrılabilir evrişim (Depthwise Seperable Convolutions) tekniğini kullanmıştır. Bu teknik sayesinde standart evrişim işlemine göre 8 veya 9 kat daha az parametreye özellik çıkarımı yapılabilmektedir. Daha sonra 2019 yılında çeşitli güncellemeler yapılarak modelin daha hızlı ve daha verimli bir hale getirilmesi amaçlanmıştır [90]. Bu mimaride 1x1 evrişimler kullanılarak özellik haritalarının boyutu daraltılmıştır. Ayrıca kullanılan bağlantı atlama tekniği sayesinde daha hızlı bir hesaplama süreci gerçekleştirilmiştir [91].

3.2.2. ESA katmanları

ESA mimarilerinde klasik görüntü işlemedeki gibi görüntünün özellikleri kullanıcı tarafından seçilmemektedir. ESA mimarilerinde görüntülerin özellikleri oluşturulan model tarafından seçilerek elde edilir. ESA modelleri bu özellikleri öğrenerek içlerinden en uygun olan özellikleri seçer. ESA mimarileri oluşturulurken literatürde en yaygın kullanılan katmanlardan biri evrişim ve ortaklama katmanlarıdır. Özellik haritaları evrişim katmanları ile elde edildikten sonra veri boyutunu azaltmak için ortaklama katmanı tercih edilebilir. Bununla birlikte mimarileri doğrusal olmayan bir yapıya dönüştürmek için aktivasyon fonksiyonları kullanılmaktadır. Literatürde birden fazla aktivasyon fonksiyonu mevcuttur. Ayrıca ağların aşırı öğrenmesini engellemek için seyreltme katmanı ve kendisinden önceki katmanlardan gelen verileri

sınıflandırma katmanına iletmek için tek boyutlu bir matrise dönüştüren tam bağlantı katmanı, ESA mimarilerinde en sık kullanılan katmanlardır.

Giriş Katmanı


ESA mimarilerinin ilk katmanı olan giriş katmanı, aldığı verileri evrişim katmanına iletmektedir. Giriş katmanına girdi olarak verilen verilerin boyutu ESA mimarilerinin performansı üzerinde büyük bir etkiye sahiptir. ESA mimarileri pikseller üzerinde işlem yaptığından dolayı, verilerin boyutunun yüksek olması modelin başarımını artırabilmektedir. Buna paralel olarak beraberinde modelin eğitim ve test süreside artmaktadır. Bu da zaman ve bellek açısından istenen bir durum değildir. Giriş katmanına verilecek olan verilerin boyutunun küçük olması modelin başarımını azaltabilmektedir. Fakat bu da beraberinde modelin daha az bellek alanına ihtiyaç duymasına sebep olacaktır. Bundan dolayı giriş verilerinin boyutunun ideal boyutta seçilmesi büyük bir önem arz etmektedir. ESA mimarilerinde giriş katmanında ki en büyük özelliklerden biri de veriyi önceden boyutlandırmak zorunda olmamaktır. Giriş katmanı verilerin boyutunu belirtilen ebatta alabilmektedir. Bu da model tarafında büyük bir esneklik sağlayıp, ön işleme adımına olan gereksinimi ortadan kaldırmaktadır [92, 93]. Literatürde kullanılan modellerden bazılarının giriş verisi boyutu Tablo 3.2’de verilmiştir.

Tablo 3.2. Modellerin giriş boyutu

Alexnet	Resnet50	Googlenet	VGG16	Densenet201	InceptionV3	Darknet53	MobileV2
227 227	224 224	224 224	224 224	224 224	299 299	256 256	224 224

Evrişim Katmanı

Evrişim katmanı ESA mimarilerinin en temel katmanlarından biridir. ESA mimarilerinin ana katmanı sayılan bu katmana girdi olarak gelen imgelere 2x2, 3x3, 5x5 vb. filtrelerin uygulanması sürecidir. Filtre operatörü tüm görüntü üzerinde kaydırma yapılarak gezdirilir. Burada yapılmak istenen aslında görüntünün öznitelik haritalarının elde edilmesi sürecidir. Bundan dolayı bu katmanda kullanılan filtreler aslında ESA mimarilerinin vazgeçilmezleridir. Bu filtreler giriş görüntüsüne girdinin başından sonuna kadar uygulandığından dolayı, belirli bir özniteliğin girdide olup olmadığını belirlemeye yaramaktadır. Bu işlemlerin sonunda girdinin belirli filtrelerden geçirilerek yeni bir görünümü yani özellikleri ortaya çıkmaktadır. Elde edilen bu özelliklere öznitelik haritası (feature map) denilmektedir. ESA modellerinde farklı evrişim katmanında farklı filtreler kullanılabilir [94, 95]. Örneğin ilk evrişim katmanında 11x11’lik bir filtre kullanılırken, başka bir evrişim katmanında 5x5’lik bir filtre kullanılabilir. Bundan dolayı modeller tasarlanırken filtre seçimi konusunda belirli bir ölçüt yoktur. 8 x 8’lik bir görüntüye 3x3 boyutundaki bir filtrenin uygulanması sonucunda elde edilen çıkış matrisi Şekil 3.19’da verilmiştir.



Şekil 3.19. 8x8 boyutundaki giriş görüntüsüne 3x3'lük bir filtre uygulanması

Giriş görüntüsüne uygulanan filtrelerle ağın derinliği artırılmış olunur ve bu sayede ağın daha doğru sonuçlar vermesi amaçlanır. Evrişim katmanlarında ki her filtre kendisinden önceki evrişim katmanından elde edilen görüntüye uygulanarak giriş görüntüsünün en boy oranı düşürülüp, derinliği artırılmış olunur. Tüm bu evrişim işlemlerinin sonunda görüntünün özellik haritası elde edilmiş olunur. Giriş görüntüsüne uygulanan filtre işleminden sonra görüntünün çıkış boyutu Denklem 3.1 ile hesaplanır.

$$o = \frac{(i-k)+2p}{s} + 1 \quad (3.1)$$

o = çıktı boyutu,

i = girdi boyutu,

k = filtre boyutu,

s = adım sayısı,

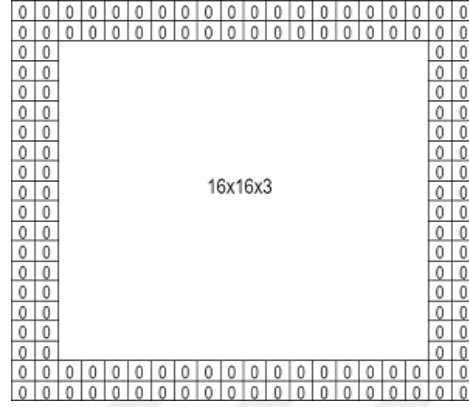
p = dolgu işlemi,

Şekil 3.19'da, $i=8$, $k=3$, $s=1$ ve $p=0$ alındığında çıktı boyutu $o = 6$ olarak hesaplanmıştır.

Denklem 3.1'de de görüleceği üzere evrişim katmanlarında uygulanan filtrelerden sonra görüntünün boyutunun azalmaktadır. Kullanılan evrişim katmanlarından dolayı görüntünün boyutu hızlı bir şekilde azalacaktır. Bu azalma orijinal görüntülerden elde edilecek olan özneliklerin hızlı bir şekilde kaybolacağını göstergesidir. Görüntülerden elde edilecek bu özneliklerin kaybolmaması için görüntüye dolgu işlemi yapılmaktadır. Şekil 3.20'de sıfır dolgu işlemine örnek verilmiştir.

16x16x3 boyutundaki giriş görüntüsüne 5x5x3 filtre uygulandığında ilk evrişim katmanından sonra yine 16x16x3 boyutunda kalmasını istiyorsak o katmana 2'li 0 (sıfır) dolgu

işlemi yapmalıyız. Dolgu işleminden sonra giriş boyutu 20x20x3'e yükselecektir. Giriş boyutu evrişim katmanında tekrar 16x16x3 boyutuna inecektir. Sıfır dolgu işlemi Şekil 3.20'de gösterilmiştir.

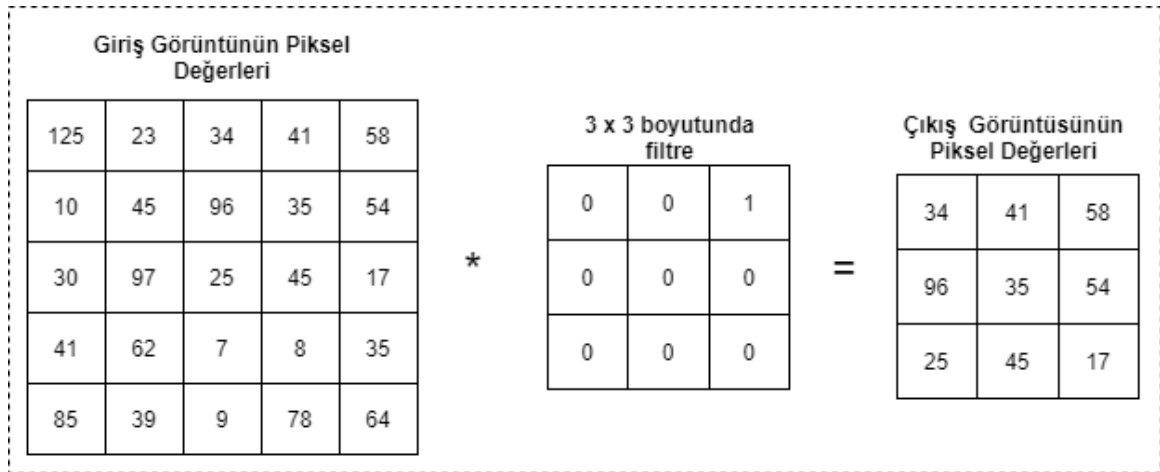


Şekil 3.20. Sıfır dolgu uygulama

Evrişim işlemi Denklem 3.2 kullanılarak gerçekleştirilir.

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m, j - n) \quad (3.2)$$

Denklem 3.2'de S evrişim işleminden sonraki çıktıyı, K çekirdeği (kernel) ve I ise giriş görüntüsünü ifade etmektedir. Evrişim işlemi “*” sembolü ile ifade edilmektedir. Evrişim işlemine örnek Şekil 3.21’de verilmiştir.



Şekil 3.21. Evrişim İşlemi

Şekil 3.21’de 5x5 boyutundaki bir giriş görüntüsü matrisine 3x3 boyutunda bir filtre uygulanmıştır. Sonuç olarak 3x3 boyutunda bir çıkış matrisi elde edilmiştir.

Ortaklama (Pooling) Katmanı

Evrişim katmanlarında elde edilen özellik haritaları daha sonra ortaklama adı verilen işleme tabi tutulabilir. Ortaklama işleminde ki amaçlardan biri öznitelik haritalarının boyutunu düşürüp, çeşitliliği azaltmaktır. Bu sayede önemli özellikler korunmakla beraber, hesaplama maliyetleri ve bir sonraki katmanın girdi boyutları düşürülmüş olunur. Ayrıca ortaklama işleminin ağ ezberlemesini de engellediği söylenebilir. Burada evrişim katmanına göre daha düşük boyutta iyi öznitelikler elde etmek ana hedeflerdendir. Ortaklama işleminde ağırlık matrisi olmadığından dolayı ağ bu aşamada öğrenme işlemini gerçekleştirememektedir. Ortaklama işleminde verinin genişlik ve yüksekliği küçülür fakat derinliğinde herhangi bir değişiklik meydana gelmez [96, 97]. Ortaklama işleminden sonra elde edilen yeni verinin boyutları Denklem 3.3-3.5 ile hesaplanır.

$$G_2 = \frac{G_1 - F}{S} + 1 \quad (3.3)$$

$$Y_2 = \frac{Y_1 - F}{S} + 1 \quad (3.4)$$

$$D_2 = D_1 \quad (3.5)$$

G_2 : Yeni veri boyutunun genişlik değeri,

G_1 : Giriş görüntüsünün genişlik değeri,

Y_2 : Yeni veri boyutunun yükseklik değeri,

Y_1 : Giriş görüntüsünün yükseklik değeri,

D_2 : Yeni görüntünün derinlik boyutu,

D_1 : Giriş görüntüsünün derinlik boyutu,

F: Filtre boyutu,

S: Adım sayısı,

Literatürde en yaygın kullanılan ortaklama işlemleri maksimum ortaklama ve ortalama ortaklamadır. Maksimum ortaklama da filtre içerisinde kalan piksel değerlerinden en büyüğü alınırken, ortalama ortaklama işleminde filtre içerisinde kalan piksel değerlerin ortalaması alınır. 9x9 boyutunda ki görüntü matrisine 3x3 boyutunda maksimum ortaklama işlemi uygulandığında elde edilen yeni matris Şekil 3.22’de gösterilmiştir.

3	5	2	2	9	7	3	4	8
5	4	1	8	5	2	2	4	7
2	4	1	8	4	9	7	5	6
4	3	5	6	1	7	7	4	5
7	8	4	5	2	8	6	9	8
8	9	6	4	3	9	3	1	2
9	6	6	7	6	3	4	2	5
4	8	8	5	5	1	5	6	7
6	9	7	2	4	3	1	7	8

5	9	8
9	9	9
9	7	8

Şekil 3.22. Maksimum ortaklama işlemi

9x9 boyutunda ki görüntü matrisine 3x3 boyutunda ortalama ortaklama işlemi uygulandığında elde edilen yeni matris Şekil 3.23'te verilmiştir.

3	5	2	2	9	7	3	4	8
5	4	1	8	5	2	2	4	7
2	4	1	8	4	9	7	5	6
4	3	5	6	1	7	7	4	5
7	8	4	5	2	8	6	9	8
8	9	6	4	3	9	3	1	2
9	6	6	7	6	3	4	2	5
4	8	8	5	5	1	5	6	7
6	9	7	2	4	3	1	7	8

3	6	5
6	5	5
7	4	5


Şekil 3.23. Ortalama ortaklama işlemi

Ağlarda evrişim ve ortaklama kullanımında her hangi bir katman kısıtlaması söz konusu değildir. İstenen sayıda evrişim katmanı olabilmektedir. Ortaklama katmanı ise her evrişim katmanından sonra olmak zorunda değildir. Bu sayılar modelin tasarımcısı tarafından ayarlanabilmektedir. Özetle ortaklama katmanını mimarilerde kullanıp kullanmama modelin tasarımcısı ile alakalıdır.

Seyreltme (Dropout)

Derin öğrenme ağlarında eğitim sırasında ezberleme olayı meydana gelebilmektedir. Bu ezberleme olayına aşırı öğrenmede denilebilmektedir. Bu durumda eğitim verilerinde modellerin başarıyı yüksek gibi gözükse de test aşamasında aynı başarı oranı elde edilememektedir. Seyreltme katmanı ağın aşırı ezberlemesini engellemek için tercih edilir. Bu katman daha çok parametre sayısının yüksek olduğu tamamen bağlantılı katmanlardan sonra tercih edilmektedir. Tamamen bağlantılı katmanlardaki bazı bağlantıların koparılması nöronların birbirleri hakkında daha az


bilgiye sahip olmalarına yol açacaktır ve bundan dolayı nöronlar birbirlerinin ağırlık değişimlerinden daha az etkilenmiş olacaklardır. Bu sayede ağın aşırı ezberlemesi de engellenmiş olacaktır [98, 99]. Şekil 3.24'te ağın orijinal yapısı ve düğüm seyreltme işleminden sonraki şekli verilmiştir.



Şekil 3.24. Seyreltme işlemi

Tam Bağlı Katman

Bu katman kendisinden önceki katmanın tüm alanlarına bağlıdır. Sınıflandırma aşaması ESA ağlarında özellik çıkarımı aşamasından sonra gelmektedir. Tam bağlantılı katman (FC) özellik haritalarını girdi olarak alır ve bu özellik haritalarını sınıflandırma işlemine hazırlar. Çok boyutlu olan özellik haritaları bu katmanda tek boyutlu hale dönüştürülür ve sınıflandırıcıya girdi olarak verilir [100, 101]. Şekil 3.25'te bu katmanın çalışma mantığı kabaca verilmiştir.



Şekil 3.25. Tam bağlantılı katmanı

FC katmanın sayıları mimariden mimariye farklılık göstermektedir.


3.2.3. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları YSA'da sıklıkla kullanılan yapılardır. Aktivasyon fonksiyonları hangi nöronların aktif olup olmayacağına karar vermek için tercih edilmektedir. Bu fonksiyonlar bir katmanın nöronlarının çıkışlarını başka bir katmana iletmek için kullanılmaktadırlar [102].

Aktivasyon fonksiyonları diğer katmanlarda üretilen değerleri belirli bir aralığa çekmek için kullanılmaktadırlar. Aktivasyon fonksiyonları YSA'da kullanılmazsa çıktı sinyali doğrusal bir fonksiyon şeklinde olacaktır. Bu durum ağın lineer regresyon gibi davranmasına yol açacaktır. Aktivasyon fonksiyonları ağırları doğrusal olmayan bir hale dönüştürdüğünden dolayı ağların daha iyi öğrenmesi sağlanmış olur. Literatürde kullanılan birden fazla aktivasyon fonksiyonu mevcuttur[103]. Çalışmalarda yaygın bir şekilde kullanılan aktivasyon fonksiyonları sırayla verilmiştir.

Relu

Relu fonksiyonu özellikle ESA mimarilerinde sıklıkla kullanılan bir aktivasyon fonksiyonudur. Relu fonksiyonu sayesinde negatif ekseninde fonksiyonun 0 değerini alması sağlanmış olur. Buradaki amaç ağın daha hızlı bir şekilde çalışmasını sağlamaktır. Bunun dezavantajı ise bu bölgede türevin sıfır olmasından dolayı, öğrenmenin de engellenmesi anlamına gelmektedir. Relu fonksiyonun özellikle ESA mimarilerinde sıklıkla tercih edilmesinin en büyük sebeplerinden biri, Relu fonksiyonun hesaplama yükünün daha az olmasından kaynaklanmaktadır [104, 105]. Şekil 3.26'da Relu fonksiyonun grafiği verilmiştir.



Şekil 3.26. Relu aktivasyon fonksiyonu


Şekil 3.26'da görülen Relu aktivasyon fonksiyonunun grafiği Denklem 3.6 ve bu fonksiyonun türevi Denklem 3.7 kullanılarak çizilmektedir.

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.6)$$

$$f(x)' = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (3.7)$$

Sigmoid

Literatürde yaygın bir şekilde kullanılan başka bir aktivasyon fonksiyonu Sigmoid'tir. Bu aktivasyon fonksiyonun [0-1] aralığında değerler ürettiğinden özellikle sınıflandırma çalışmalarında sıklıkla kullanılmaktadır. Fonksiyonun eksen uçlarında y değerleri x'teki değişimlere önemsenmeyecek oranda tepki verdiği için dolayı, bu bölgelerde türev değerleri çok küçük olmaktadır. Bu değerler neredeyse sıfıra yaklaştığından dolayı ağız öğrenmesi de neredeyse sıfır olmaktadır. Ortaya çıkan bu problem gradyanların kaybolması (vanishing gradient) olarak karşımıza çıkmaktadır [106, 107]. Sigmoid fonksiyonunun grafiği Şekil 3.27'de verilmiştir.



Şekil 3.27. Sigmoid aktivasyon fonksiyonu


Şekil 3.27'de görülen Sigmoid aktivasyon fonksiyonunun grafiği Denklem 3.8 ve bu fonksiyonun türevi olan Denklem 3.9'a göre çizilmektedir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.8)$$

$$f'(x) = f(x)(1 - f(x)) \quad (3.9)$$

Hiperbolik Tanjant

Hiperbolik Tanjant (TanH) aktivasyon fonksiyonu (-1 1) aralığında değer alan ve literatürde sıklıkla kullanılan bir başka aktivasyon fonksiyonudur. Şekil 3.28’de de görüleceği gibi TanH fonksiyonun türevi sigmoid fonksiyonuna oranla daha diktir. TanH aktivasyon fonksiyonunun türevinin daha geniş aralıklarda değerler alması ağların daha hızlı öğrenmesini sağlamaktadır. Bu aktivasyon fonksiyonunda da gradyanların kaybolması problemi mevcuttur [108, 109]. Şekil 3.28’de TanH aktivasyon fonksiyonun grafiği verilmiştir.



Şekil 3.28. TanH aktivasyon fonksiyonu

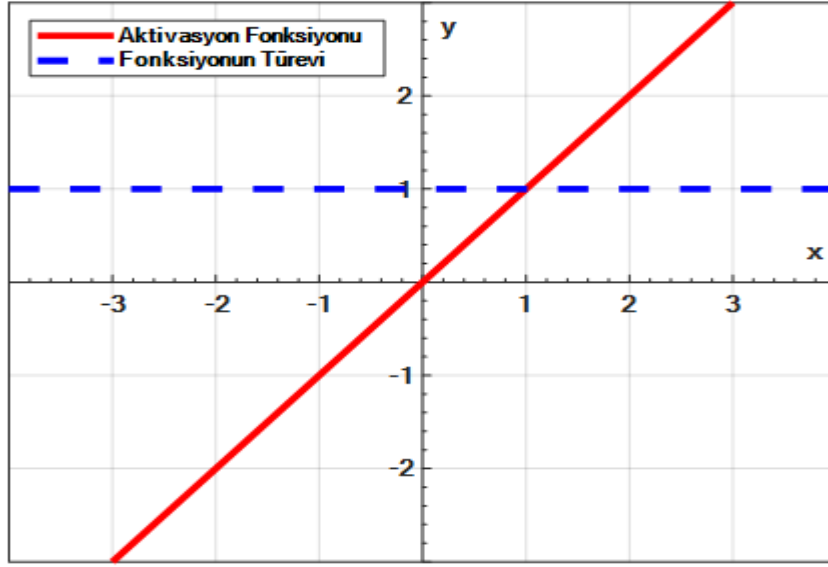
Şekil 3.28’de görülen TanH aktivasyon fonksiyonunun grafiği Denklem 3.10 ve bu fonksiyonun türevi olan Denklem 3.11’e göre çizilmektedir.

$$f(x) = \tanh(x) = \frac{2}{1+e^{-2x}} - 1 \quad (3.10)$$

$$f'(x) = 1 - f(x)^2 \quad (3.11)$$

Doğrusal (Lineer) Aktivasyon Fonksiyonu

Doğrusal aktivasyon fonksiyonları c gibi bir sabit ile ölçeklendirilip aktivasyon değerleri üretirler, c’nin 1 olması durumunda çıkış değeri daima giriş değerine eşit olur. Bu fonksiyonun türevinin daima 1 olması istenmeyen bir durumdur. Çünkü geriye yayılım algoritmaları temelinde türev bazlı çalıştığından, ağıın öğrenememesi sorunu ortaya çıkmaktadır. Fonksiyonun türevi sabit olduğundan dolayı sinir ağları sürekli sabit miktarda düzeltilir. Buda doğrusal aktivasyon fonksiyonları için bir dezavantajdır [110, 111]. Şekil 3.29’da doğrusal aktivasyon fonksiyonun grafiği verilmiştir.



Şekil 3.29. Doğrusal aktivasyon fonksiyonu

Şekil 3.29’da görülen doğrusal aktivasyon fonksiyonunun grafiği Denklem 3.12 ve bu fonksiyonun türevi olan Denklem 3.13’e göre çizilmektedir.

$$f(x) = cx \quad (3.12)$$


$$f'(x) = c \quad (3.13)$$

Basamak (Step)

Bu aktivasyon fonksiyonu daha çok ikili sınıflandırıcı olarak kullanılmaktadır. Bundan dolayı bu aktivasyon fonksiyonuna ikili basamak aktivasyon fonksiyonu da denilmektedir. Bu aktivasyon fonksiyonu daha çok sınıflandırıcı olarak kullanıldığından, bu aktivasyon fonksiyonunun çıkış katmanında kullanılması daha doğru olacaktır. Gizli katmanlarda fonksiyonun türevi herhangi bir değeri temsil etmediğinden dolayı kullanılması çok fazla tercih edilmemektedir[112, 113]. Şekil 3.30’da ikili basamak aktivasyon fonksiyonunun grafiği verilmiştir. Şekil 3.30’da görülen basamak aktivasyon fonksiyonunun grafiği Denklem 3.14 ve bu fonksiyonun türevi olan Denklem 3.15’e göre çizilmektedir.

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (3.14)$$


$$f'(x) = \begin{cases} 0, & x \neq 0 \\ ?, & x = 0 \end{cases} \quad (3.15)$$



Şekil 3.30. Basamak aktivasyon fonksiyonu

Sızıntı Relu

Bu fonksiyonda küçük bir alfa değeri kullanılarak fonksiyonun eksi değerlerde alması sağlanmıştır. Relu fonksiyonunda 0 değeri dönen yerlerde türevde sıfır olduğundan dolayı öğrenme işlemi gerçekleştirilemiyordu. Sızıntı (Leaky) Relu'da, Relu'dan farklı olarak sıfır değeri dönmediğinden dolayı o bölgede de öğrenme sağlanmış olunur. Burada alfa değerinden dolayı sızıntı denen küçük bir eğim oluşmaktadır. Bu eğim $-\infty$ 'a kadar gitmektedir. Bu sayede Relu'daki eksi bölgede oluşan ölü gradyan sorunu çözülmüştür ve o bölgede de ağıın öğrenmesi gerçekleştirilmiştir[114, 115]. Şekil 3.31'de sızıntı Relu fonksiyonunun grafiği verilmiştir.



Şekil 3.31. Leaky Relu aktivasyon fonksiyonu

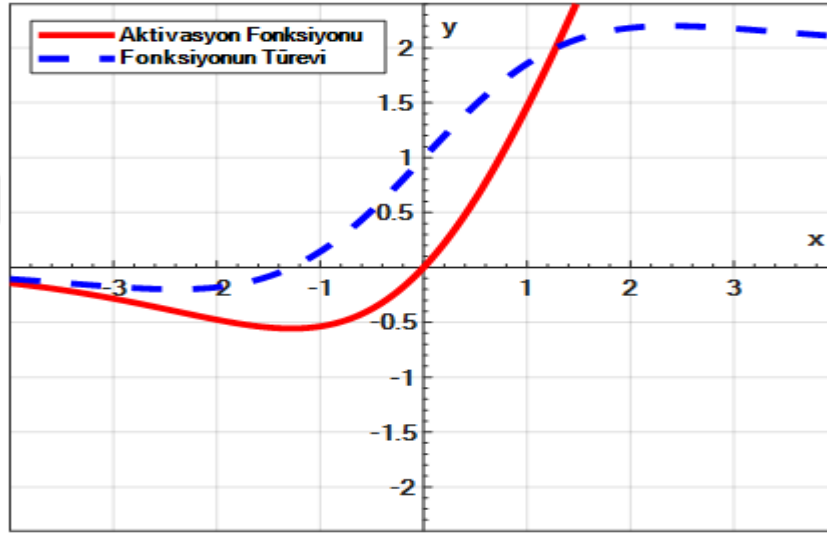
Şekil 3.31’de görülen Leaky Relu aktivasyon fonksiyonunun grafiği Denklem 3.16 ve bu fonksiyonun türevi olan Denklem 3.17’ye göre çizilmektedir.

$$f(x) = \begin{cases} \alpha x, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.16)$$

$$f'(x) = \begin{cases} \alpha, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (3.17)$$

Swish Aktivasyon Fonksiyonu

Swish aktivasyon fonksiyonu Relu ve Sızıntı Relu’ya çok benzeyen bir aktivasyon fonksiyonudur. Relu’dan farkı negatif bölgelerde de değerler alarak, bu bölgede de öğrenmenin devam etmesini sağlamaktadır. Sızıntı Relu’dan farkı ise negatif bölgelerde aldığı değerın doğrusal olmamasıdır. Bu aktivasyon fonksiyonunda Gradyanların ölmesi problemi engellenmiştir. Swish fonksiyonu Relu’ya göre daha fazla işlem gücü gerektirmektedir [116]. Şekil 3.32’de Swish fonksiyonunun grafiği verilmiştir.



Şekil 3.32. Swish aktivasyon fonksiyonu

Şekil 3.32’de verilen Swish aktivasyon fonksiyonunun grafiği Denklem 3.18 ve bu fonksiyonun türevi olan Denklem 3.19’a göre çizilmektedir.

$$f(x) = \frac{x}{1+e^{-x}} \quad (3.18)$$

$$f'(x) = \frac{1}{1+e^{-x}} + \frac{e^{-x}x}{(1+e^{-x})^2} \quad (3.19)$$

Softmax


Özellikle ESA mimarilerinde ve sınıflandırma problemlerinde sıklıkla kullanılmaktadır. Yapı olarak Sigmoid fonksiyonunda benzerdir. Fakat Sigmoid fonksiyonu daha çok ikili

sınıflandırma problemlerinde kullanılırken, Softmax çoklu sınıflandırma problemlerinde de kullanılabilir. Softmax daha çok çıktı katmanında kullanılmakta olup, 0-1 aralığında bir çıktı değeri üretip sınıf tahmin etmeyi amaçlar [117, 118]. Bu fonksiyon Denklem 3.20’de verildiği gibi her bir sınıf için olası değerleri hesaplar.

$$P(y = j|x; W, b) = \frac{\exp^{x^T w_j}}{\sum_{j=1}^n \exp^{x^T w_j}} \quad (3.20)$$

Denklem 3.20’de kullanılan x değişkeni ana sınıfları, W ve b değişkenleri ise ağırlık vektörlerini temsil etmektedir.

Softmax aktivasyon fonksiyonunun grafiği Şekil 3.33’te verilmiştir.



Şekil 3.33. Softmax aktivasyon fonksiyonu

3.3. Derin Öğrenme Mimarilerinde Kullanılan Performans Ölçütleri

Bu çalışmada 3 farklı uygulama gerçekleştirilmiştir. Yapılan çalışmalar hem literatürde yapılan çalışmalarla hem de diğer ESA mimarileriyle karşılaştırılmıştır. Önerilen yöntemlerin kullanılan veri setlerinde başarılı oldukları görülmüştür. Kullanılan modellerin performansını ölçen çok sayıda metrik mevcuttur. Bu metrikler daha çok karışıklık matrisi kullanılarak hesaplanmaktadır [119]. Tablo 3.3’de genel bir karışıklık matrisi yapısı verilmiştir.

Tablo 3.3. Karışıklık matrisi

	A	B
A	TP	FP
B	FN	TN

Gerçek Pozitif (TP): A sınıfına ait bir verinin A diye doğru tahmin edilmesi,

Yanlış Pozitif (FP): A sınıfına ait bir verinin B diye yanlış tahmin edilmesi,

Yanlış Negatif (FN): B sınıfına ait bir verinin A diye yanlış tahmin edilmesi,

Doğru Negatif (TN): B sınıfına ait bir verinin B diye doğru tahmin edilmesini ifade etmektedir.

Modellerin performansını ölçmek için literatürde kabul görmüş metrikler mevcuttur. Bunlardan Doğruluk (Acc) Denklem 3.21’de, Duyarlılık (Sen) Denklem 3.22’de, Özgünlük (Spe) Denklem 3.23’te, Kesinlik (Pre) Denklem 3.24’te, F-Ölçümü (F1) Denklem 3.25’te, Yanlış Pozitif Oranı (FPR) Denklem 3.26’da, Yanlış Negatif Oranı (FNR) Denklem 3.27’de ve Yanlış Bulgu Oranı (FDR) Denklem 3.28’de verilmiştir.

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.21)$$

$$Sen = \frac{TP}{TP + FN} \quad (3.22)$$

$$Spe = \frac{TN}{TN + FP} \quad (3.23)$$

$$Pre = \frac{TP}{TP + FP} \quad (3.24)$$

$$F1 = \frac{2*TP}{2*TP + FP + FN} \quad (3.25)$$

$$FPR = \frac{FP}{FP + TN} \quad (3.26)$$

$$FNR = \frac{FN}{FN + TP} \quad (3.27)$$

$$FDR = \frac{FP}{FP + TP} \quad (3.28)$$

4. İNSAN HAREKETLERİN DERİN ÖĞRENME MİMARİLERİ İLE SINIFLANDIRILMASI

Gelişen teknolojiyle birlikte veri tabanlarında tutulan bilgilerin boyutu gün geçtikçe artmaktadır. Özellikle insanların hayatına çok yakından giren kameralar ile kayıt altına alınan video görüntüleri dâhil olmak üzere, veri tabanlarında oldukça fazla veri tutulmaktadır. Bu verilerin işlenip, gerekli analizlerin yapılması oldukça önemlidir [120]. Ayrıca insan hareketlerinin tanınması ve bu hareketlerin sınıflandırılması, insan makine etkileşimi için son yıllarda en önemli konulardan biri haline gelmiştir [121]. İnsan hareketi tanım olarak çok geniş bir çerçeveye sahiptir. İnsanın en küçük bir hücresini kıpırdatması bir hareketken, koşması da bir harekettir. Bundan dolayı insan hareketlerini çeşitli konular ve amaçlar için sınıflandırmak mümkündür. İnsan hareketleri sağlık başta olmak üzere insan aktivitesi tanıma sistemleri, akıllı ev sistemleri, güvenlik sistemleri, oyun sektörü, yaşlı bakım evleri, görsel izleme, nesne takibi, insan psikolojisi ve mimik analizi gibi birçok alanda kullanılmaktadır. İnsan hareketlerinin tespiti ile mevcut durumu yorumlamanın yanı sıra gelecekteki davranışlar hakkında da tahminlerde bulunulabilir [122, 123]. İnsan için en önemli etkenlerden biri sağlık olduğundan dolayı bu çalışmada insan hareketleri ve hastalıkları incelenmiştir.

Bu çalışmada insan hareketlerini sınıflandırmak için video görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri setindeki videolardan belirli kesitlerde görüntüler alınarak 10 sınıflı bir veri seti oluşturulmuştur. Bu veri setindeki görüntüleri sınıflandırmak için ESA tabanlı bir model önerilmiştir. Önerilen model 43 katmandan oluşmaktadır. Önerilen modeli karşılaştırmak için ESA mimarilerinden olan Alexnet, Densenet201, InceptionV3, Resnet50, Googlenet, MobilenetV2 ve Efficientnetb0 mimarilerinden de aynı veri setinden sonuçlar alınmıştır. Ayrıca modellerin eğitiminde aynı parametre değerleri kullanılmıştır. Önerilen model çalışmada kullanılan önceden eğitilmiş ESA modellerinden daha iyi sonuçlar elde etmiştir.

4.1. Literatür Taraması

Literatürde insan hareketlerinin sınıflandırılması ile ilgili çalışmalar yapılmıştır. Oliveira Silva ve arkadaşları [124] yaptıkları çalışmalarında Ucf_sports veri setini kullanarak insan hareketlerini sınıflandırmışlardır. Çalışmalarında iki farklı yöntem önerdikleri görülmüştür. Bu yöntemlerden ilki uzaysal akış yöntemi, ikincisi ise yoğun optik akış yöntemidir. Her iki yöntemde de ağı ayrı ayrı eğittiklerini ve bir sınıflandırma histogramı oluşturduklarını belirtmişlerdir. Çalışmalarında %78.46 doğruluk elde ettiklerini ifade etmişlerdir. Ayrıca önermiş oldukları yöntemi diğer veri setlerinde de test ettiklerini belirtmişlerdir.

Jaouedi ve arkadaşları [125] insan hareketlerini tanımak için yapmış oldukları çalışmada hibrit bir derin öğrenme modeli önerdiklerini belirtmişlerdir. Bu çalışmada Gauss ve Kalman filtreleri kullanılmıştır. Daha sonra elde edilen veriler tekrarlayan sinir ağları mimarileriyle tahmin edilmeye çalışılmıştır. Bu çalışmada önerilen yöntem farklı veri setlerinde test edilmiştir. Ucf_sports veri setinde önerdikleri hibrit yöntem ile %89.01 doğruluk oranına ulaştıkları görülmüştür.

Charalampous ve arkadaşları [126] insan hareketlerinin sınıflandırılması için derin öğrenme yöntemlerini kullanarak sınıflandırma işlemini yaptıklarını belirtmişlerdir. Yaptıkları çalışmada sınıflandırıcı olarak klasik makine öğrenme sınıflandırıcılarından olan Doğrusal SVM'yi tercih etmişlerdir. Burada Viterbi algoritmasını derin öğrenme modellerinde ilk kez kullandıklarını ve bununla farklı bir yaklaşıma yol açtığını belirtmişlerdir. Bu sınıflandırma işleminin sonucunda Ucf_sports veri setinde %88.55 doğruluk oranı elde etmişlerdir.

Wang ve arkadaşları [127] yapmış oldukları çalışmalarında insan hareketlerini sınıflandırmak için birden fazla veri seti kullanmışlardır. Bu veri setlerinde ayrı ayrı sonuçlar elde etmişlerdir. Çalışmalarında yöntem olarak yoğun yörüngeler ve hareket sınırı tanımlayıcı yöntemini tercih etmişlerdir. Kullandıkları yöntem daha çok histogram tabanlı bir yöntemdir. Bu yöntem ile Ucf_sports veri setinde %88 doğruluk oranı elde ettikleri gözlemlenmiştir.

Ma ve arkadaşları [128] Ucf_sports veri kümesini kullanarak çalışmalarında hiyerarşik uzamsal-zamansal ağaç topluluklarını araştırdıklarını belirtmişlerdir. Hiyerarşik uzamsal-zamansal ağaçların, eylemler için sağlam bir orta düzey temsil sağladığını ifade etmişlerdir. Bununla birlikte, özellikle kısmi eşleşmeye izin veriliyorsa, üstel arama alanı nedeniyle sık ve ayırt edici ağaç yapılarının keşfinin zor olduğunu ve bunu, önce ayırıcı kümeleme yoluyla kısa bir eylem sözlüğü oluşturarak ele aldıklarını belirtmişlerdir. Yapmış oldukları çalışmada %89.4 doğruluk değeri elde ettikleri görülmüştür. Ayrıca modellerini diğer veri setleri ile de test ettikleri görülmüştür.

Wang ve arkadaşları [129] yaptıkları çalışmada video görüntülerini sınıflandırmak için özellik eğrilerinin etkili olduğunu belirtmişlerdir. Yaptıkları çalışmada özellikleri çıkarmak için KLT izleyicileri ve SIFT tanımlayıcılarını kullanmışlar. Yapılan çalışmada videoları yoğun yörüngelerle açıklamak için bir yaklaşım önermişler. Her çerçeveden yoğun noktaları örnekleyip, bunları yoğun bir optik akış alanındaki yer değiştirme bilgilerine göre izlemişler. Yaptıkları bu çalışmada doğruluk oranı %88 olmuştur.

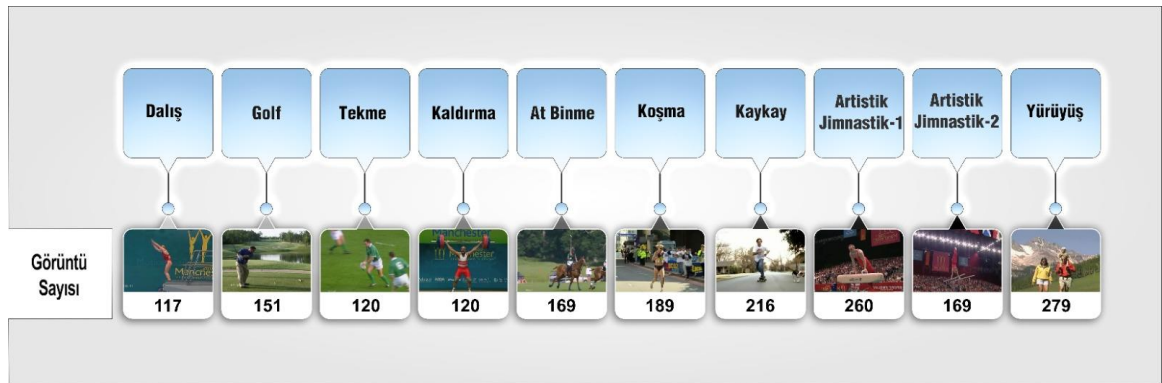
Le ve arkadaşları [130] yaptıkları çalışmada, özellikleri doğrudan video verilerinden öğrenmenin bir yolu olarak denetimsiz özellik öğrenmeyi kullanmışlardır. Etiketlenmemiş video verilerinden değişmeyen uzay-zamansal özellikleri öğrenmek için Bağımsız Alt Uzay Analizi algoritmasının bir uzantısını sunduklarını belirtmişlerdir. Önerdikleri yöntemin basit olmasına rağmen, bu yöntemin derin öğrenme teknikleri ile birleştirildiğinde iyi bir performans elde ettiklerini ifade etmişlerdir. Önerdikleri bu yöntemi birden fazla sınıf üzerinde test ettiklerini ve

başarılı sonuçlar aldıklarını, Ucf_sports veri setinde doğruluk oranının %86.5 olduğunu göstermişlerdir.

Kovashka ve arkadaşları [131] yaptıkları belirli bir eylem kategorisi için en ayırıcı olan uzay-zaman komşuluklarının şekillerini öğrenmeyi amaçladıklarını belirtmişlerdir. Önerdikleri yönteme eğitim videoları verildiğinde, yöntemlerinin öncelikle yerel hareket ve görünüm özelliklerini çıkarttığını ve bunları bir kelime dağarcığına dönüştürdüğünü belirtmişlerdir. Daha sonra elde ettikleri bu kelime dağarcıklarından ve birbirine yakın noktalarla ilişkili sözcüklerden aday komşuluklarını elde etmişlerdir. Hangi noktaların yakın olduğunu belirlemek için uzamsal ve zamansal boyutların belirli bir ölçeğini dikte etmek yerine, en bilgilendirici konfigürasyonları oluşturan sınıfa özgü mesafe fonksiyonlarının nasıl öğrenileceğini gösterdiklerini ifade etmişlerdir. Yapılan bu çalışmada %87.27 oranında bir doğruluk değeri elde ettiklerini göstermişlerdir.

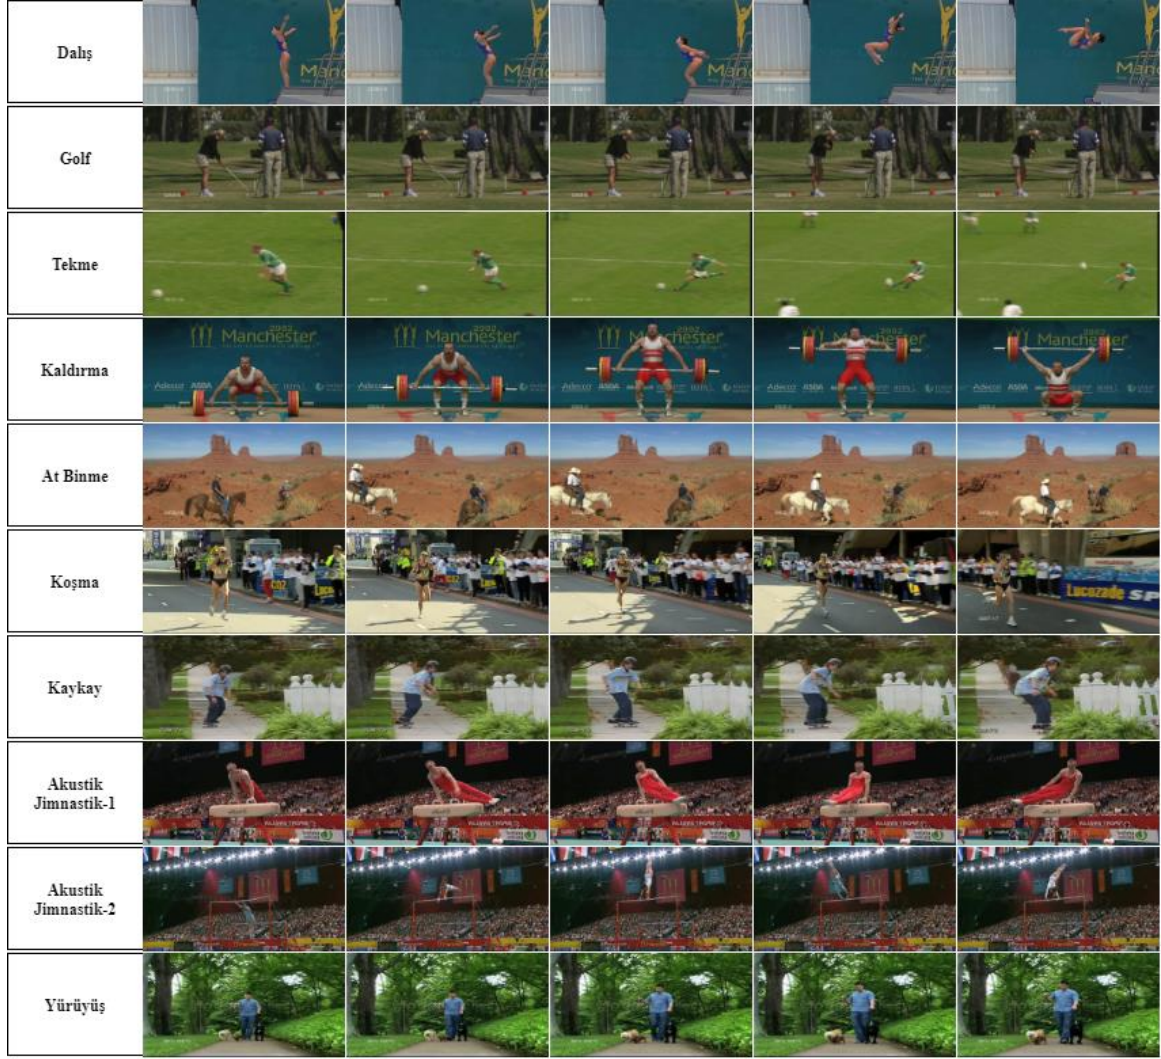
4.2. Veri Seti

İnsan hareketlerinin sınıflandırılması için Ucf_sports_actions video veri seti [132] kullanılmıştır. Bu veri seti 720x480 çözünürlüğünde 10 farklı video sınıftan oluşmaktadır. Veri setindeki videolardan belirli sayıda kesitlerde görüntüler alınarak veri seti oluşturulmuştur. Oluşturulan bu veri seti önerilen yöntem ve diğer önceden eğitilmiş ESA mimarileri ile sınıflandırılmıştır. Veri seti oluşturulduktan sonra her bir sınıftaki görüntü sayısı Şekil 4.1’de verilmiştir.



Şekil 4.1. Çalışmada kullanılan sınıflar ve görüntü sayıları

Belirli kesitlerdeki görüntüler videolardan alınarak o hareket sınıfı oluşturulmuştur. Her bir videodan alınan kesitlere örnek Şekil 4.2’de sunulmuştur. Bu şekilde sadece birer videodan alınan karelerden bazıları verilmiştir.

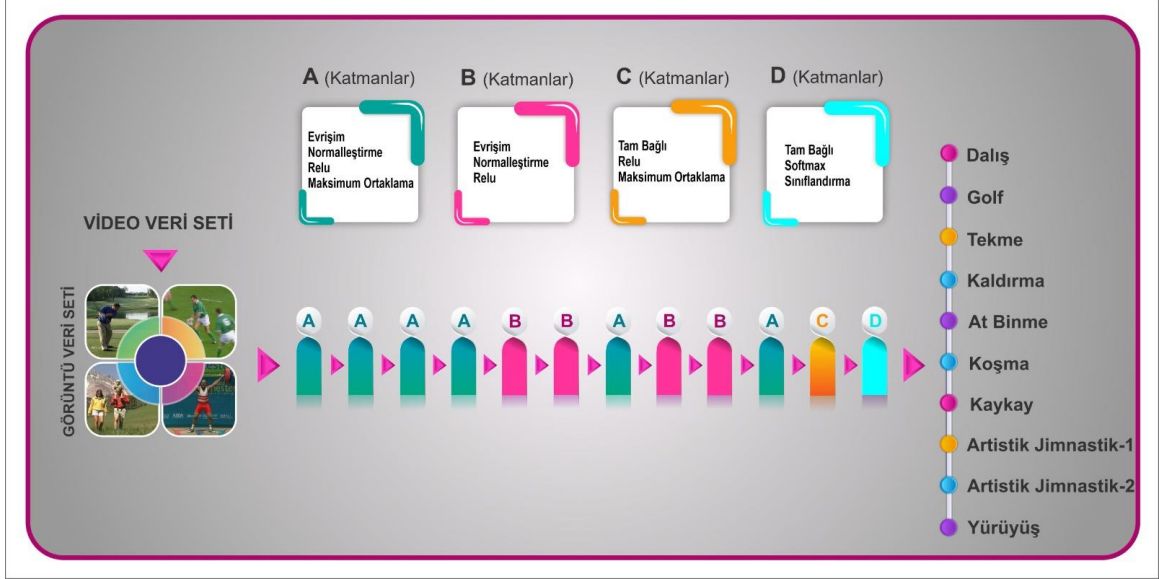


Şekil 4.2. Kesit örnekleri

4.3. Materyal ve Yöntem

İnsan hareketlerinin sınıflandırılması için veri setindeki videolar kullanılarak bir görüntü veri seti oluşturulmuştur. Oluşturulan bu veri seti 10 farklı hareket grubundan oluşmaktadır. Bu veri setindeki insan hareketlerinin sınıflandırılması için yeni bir ESA tabanlı model önerilmiştir. Önerilen model toplam 43 katmandan oluşmaktadır. Önerilen modelde öznetelik haritalarını elde etmek için 10 evrişim katmanı kullanılmıştır. Aktivasyon işlemi için 11 tane Relu aktivasyon fonksiyonu kullanılmıştır. Veri boyutunu küçültüp, hesaplama maliyetini azaltmak için 7 tane maksimum ortaklama katmanı kullanılmıştır. Normalleştirme işlemi için 10 yığın normalleştirme katmanı kullanılmıştır. Özellik haritalarını girdi olarak alıp, çok boyutlu matris formatından tek boyutlu matris formatına dönüştürmek ve bu verileri sınıflandırma sürecine hazırlamak için 2 FC katmanı ayrıca 1 Softmax katmanı ve 1 sınıflandırma katmanı kullanılmıştır. Giriş katmanından

görüntüler 227x227x3 boyutlarında alınmıştır. Önerilen modelin blok diyagramı Şekil 4.3'te verilmiştir.



Şekil 4.3. Önerilen model

Önerilen model eğitilirken kullanılan eğitim değerleri Tablo 4.1'de verilmiştir.

Tablo 4.1. Önerilen modelin eğitiminde kullanılan parametre değerleri

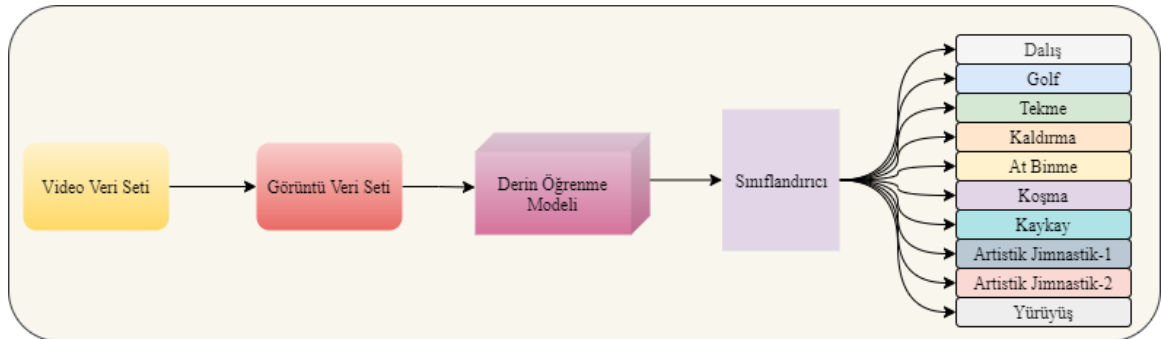
Yazılım Ortamı	Model	Epochs	Optimizasyon	Batch Size	Learning Rate	Validation Frequency
Matlab 2019b	Önerilen model	5	Stochastic Gradient Descent (SGD)	8	10^{-4}	4

Modeller eğitim sürecini 5 Epochs değerinden önce tamamladığı için Epochs değeri 5 olarak seçilmiştir. Optimizasyon yöntemi olarak SGDM (Stokastik Gradient Descent) seçilmiştir. Bu yöntemin sınıflandırma süreçlerinde daha yüksek doğruluk sağladığı görülmüştür. Kullanılan bilgisayarın özelliklerinden dolayı Batch Size değeri 8 olarak seçilmiştir, daha yüksek özellikli bilgisayarlarda bu özelliğin daha yüksek seçilmesi mümkündür. Batch Size değeri modelin eğitim süresini azalmaktadır. Son olarak, eğitim ve kayıp fonksiyonu eğrisinin çiziminde görünürlüğü artırmak için Validation Frequency (doğrulama sıklığı) değeri dört olarak verilmiştir. Önerilen bu modelin, insan hareketlerini tanıma ve sınıflandırma işleminde kullanılabileceği düşünülmektedir. Önerilen modelin genel yapısı ve parametre sayısı Tablo 4.2'de verilmiştir.

Tablo 4.2. Önerilen modelin genel yapısı

Tip	Stride (Adım)	Filtre Boyutu	Aktivasyonlar	Ortaklama	Aktivasyon Fonksiyonu
Evrişim	4,4	11,11	55x55x96	Maksimum Ortaklama	Relu
Evrişim	1,1	3,3	27x27x256	Maksimum Ortaklama	Relu
Evrişim	1,1	3,3	14x14x256	Maksimum Ortaklama	Relu
Evrişim	1,1	3,3	14x14x256	Maksimum Ortaklama	Relu
Evrişim	1,1	3,3	7x7x384	-	Relu
Evrişim	1,1	3,3	7x7x384	-	Relu
Evrişim	1,1	3,3	7x7x512	Maksimum Ortaklama	Relu
Evrişim	1,1	3,3	4x4x512	-	Relu
Evrişim	1,1	3,3	4x4x512	-	Relu
Evrişim	1,1	3,3	4x4x512	Maksimum Ortaklama	Relu

Önerilen modelde, evrişim katmanları, giriş görüntülerine uyguladıkları filtrelerle özellik haritalarının elde edilmesini sağlarlar. Kullanılan evrişim katmanları ağı derinliğini artırdığından, evrişim katmanlarının seçimi büyük önem taşımaktadır [23]. Bu katmanda kullanılan filtreler küçük seçilmesi ağı başarımını artırmakla birlikte işlem karmaşıklığını da artırır, filtrelerin büyük seçilmesi ise işlem karmaşıklığı azaltır ama ağı başarımını da azaltabilir. Filtrelerin seçim süreci modelin performansını doğrudan etkiler. Relu katmanı, önceki katmandan gelen doğrusal olmayan verileri doğrusallaştırır ve bir sonraki katmana iletir. Ek olarak, ortaklama, derin ağlarda kullanılan ana işlemlerden biridir. Bu çalışmada, veri boyutunu ve hesaplama maliyetini azaltmak için maksimum ortaklama kullanılmıştır. Maksimum ortaklama işlemi ile daha başarılı özellik haritalarının elde edilmesi amaçlanmıştır. Önerilen modelin blok diyagramı kabaca Şekil 4.4'te verilmiştir.



Şekil 4.4. Önerilen modelin blok diyagramı

Şekil 4.4'te de görüldüğü gibi video veri setinden görüntü veri seti oluşturulmuştur. Daha sonra oluşturulan veri seti önerilen model kullanılarak eğitilmiştir. Sonuç olarak elde edilen görüntüler 10 farklı kategoride sınıflandırılmıştır.

4.4. Uygulama


Gerçekleştirilen uygulamada modeller eğilirken hepsinde eğitim parametreleri aynı alınmıştır. Modellerde kullanılan eğitim parametreleri Tablo 4.3'te verilmiştir.

Tablo 4.3. Uygulamada kullanılan modellerin parametre değerleri

Yazılım Ortamı	Model	Epochs	Optimizasyon	Batch Size	Learning Rate	Validation Frequency
Matlab 2019b	Çalışmada kullanılan tüm modeller	5	Stochastic Gradient Descent (SGD)	8	10^{-4}	4

Alexnet

İnsan hareketleri videolarından oluşan veri seti kullanılarak belli kesitler de görüntüler alınarak oluşturulan veri seti 2012 yılında yapılan ILSVRC ImageNet yarışmasını kazanan Alexnet modeli kullanılarak sınıflandırılmıştır. Model toplamda 890 adım çalışmıştır. Alexnet modeli giriş görüntülerini $227 \times 227 \times 3$ boyutunda almaktadır. Alexnet modeli ile elde edilen doğruluk ve kayıp eğrisi Şekil 4.5'te verilmiştir.



Şekil 4.5. Alexnet modelinin doğruluk ve kayıp eğrisi

Alexnet modeli ile %84.36 ortalama doğruluk değeri elde edilmiştir. Alexnet modelinin karışıklık matrisi Tablo 4.4'te verilmiştir.

Tablo 4.4. Alexnet modelinin karışıklık matrisi

Doğru Sınıf	Dalış	23									
	Golf		30								
	Tekme			12			3	9			
	Kaldırma				24						
	At Binme					34					
	Koşma						38				
	Kaykay							25			18
	ArtistikJimmastik1								52		
	ArtistikJimmastik2									34	
	Yürüyüş					18		8			30
	Dalış	Golf	Tekme	Kaldırma	At Binme	Koşma	Kaykay	Artistik Jimmastik1	Artistik Jimmastik2	Yürüyüş	
Tahmin Edilen Sınıf											

Tablo 4.4'te verilen karışıklık matrisinde de görüldüğü gibi Dalış, Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında test için kullanılan görüntülerin hepsi doğru tahmin edilmiştir. Alexnet modelinin en başarısız olduğu sınıf Tekme sınıfıdır. Model Tekme sınıfında bulunan 24 görüntünün 12 tanesini doğru tahmin ederken, 12 tanesini yanlış tahmin etmiştir. Tekme sınıfına ait olan 3 görüntü yanlış tahmin edilip, Koşma sınıfına yerleştirilmiştir. Ayrıca yine Tekme sınıfına ait olan 9 görüntü yanlış tahmin edilip, Kaykay sınıfına yerleştirilmiştir. Modelin tekme sınıfında ki doğruluk oranı %50 olmuştur. Alexnet modeli Kaykay sınıfında ise, 43 tane Kaykay sınıfına ait olan görüntünün 25 tanesini doğru tahmin ederken, 18 tanesini Yürüyüş diye yanlış tahmin etmiştir. Modelin bu sınıftaki doğruluk oranı %58.13 olmuştur. Son olarak Alexnet modeli 56 tane yürüyüş görüntüsünden 30 tanesini doğru tahmin ederken, 18 tanesini At Binme ve 8 tanesini Kaykay diye yanlış tahmin etmiştir. Modelin bu sınıftaki doğruluk oranı %53.57'dir. Karışıklık matrisi genel olarak incelendiğinde ise test için kullanılan 358 adet görüntünün 302 tanesi Alexnet modeli tarafından doğru sınıflandırılırken, 56 tanesi ise yanlış sınıflandırılmıştır.

Alexnet modelinin performans ölçütleri Tablo 4.5'te sunulmuştur.


Tablo 4.5. Alexnet modelinde elde edilen performans deęerleri

	FPR	FDR	FNR	F1	Duyarluluk	Özgünlük	Doęruluk
Dalıř	0	0	0	%100	%100	%100	%100
Golf	0	0	0	%100	%100	%100	%100
Tekme	0.0346	0.0050	0	%66.6	%100	%96.53	%50
Kaldırma	0	0	0	%100	%100	%100	%100
At Binme	0	0	0.3461	%79.06	65.38	%100	%100
Kořma	0	0	0	%100	%100	%100	%100
Kaykay	0.0569	0.4186	0.4047	58.81	59.20	94.30	%58.13
ArtistikJimmastik1	0	0	0	%100	%100	%100	%100
ArtistikJimmastik2	0	0	0	%100	%100	%100	%100
Yürüyüş	0.0838	0.4642	0.375	%57.69	%62.5	%91.61	%53.57

Tablo 4.5'te de görüldüęü gibi Alexnet modeli Dalıř, Golf, Kaldırma, At Binme, Kořma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında %100'lük bir doęruluk deęeri elde ederken, Tekme sınıfında %50, Kaykay sınıfında %58.13 ve Yürüyüş sınıfında %53.57 doęruluk deęeri elde etmiştir.

Densenet201

Bu çalışmada insan hareketleri veri setindeki görüntüleri sınıflandırmak için kullanılan bir başka model Densenet201 modelidir. Densenet201 modeli toplamda 890 adım çalışmıştır. Densenet201 modelinin giriş katmanı görüntüleri 224x224x3 boyutunda almaktadır. Densenet201 modeli ile elde edilen doęruluk ve kayıp eğrisi Şekil 4.6'da verilmiştir.



Şekil 4.6. Densenet201 modelin doğruluk ve kayıp eğrisi

Densenet201 modeli ile %84.36 oranında doğruluk değeri elde edilmiştir. Densenet201 modelinin karışıklık matrisi Tablo 4.6'da verilmiştir.

Tablo 4.6. Densenet201 modelinin karışıklık matrisi

Doğru Sınıf	Dalış	23									
	Golf		30								
	Tekme			10		1	1	12			
	Kaldırma				24						
	At Binme					34					
	Koşma						38				
	Kaykay							25			18
	ArtistikJimmastik1								52		
	ArtistikJimmastik2									34	
	Yürüyüş					24					32
	Dalış	Golf	Tekme	Kaldırma	At Binme	Koşma	Kaykay	ArtistikJimmastik1	ArtistikJimmastik2	Yürüyüş	

Tahmin Edilen Sınıf

Tablo 4.6'da verilen karışıklık matrisinde de görüldüğü gibi Dalış, Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında test için kullanılan görüntülerin hepsi doğru tahmin edilmiştir. Modelin bu sınıflardaki doğruluk değeri %100'dür.

Densenet201 modelinin en başarısız olduğu sınıf Tekme sınıfıdır. Densenet201 modeli Tekme sınıfında ki 24 görüntünün 10 tanesi doğru sınıflandırılırken 14 tanesi yanlış sınıflandırılmıştır. Modelin bu sınıftaki doğruluk oranı %41.66'dır. Kaykay sınıfında ise toplamda 43 tane test görüntüsü mevcuttur. Densenet201 modeli bu görüntülerin 25 tanesini doğru sınıflandırırken, 18 tanesini yanlış sınıflandırılmıştır. Modelin bu sınıftaki doğruluk oranı ise %58.13'tür. Son olarak yanlış tahmin ettiği bir başka sınıf Yürüyüş sınıfıdır. Yürüyüş sınıfında toplamda 48 tane test görüntüsü mevcuttur. Densenet201 modeli bu görüntülerden 32 tanesini doğru sınıflandırırken, 24 tanesini ise yanlış sınıflandırmıştır. Modelin bu sınıftaki doğruluk oranı ise %57.14'tür. Karışıklık matrisi genel olarak incelendiğinde ise test için kullanılan 358 adet görüntünün 302 tanesi doğru sınıflandırılırken, 56 tanesi yanlış sınıflandırılmıştır. Densenet201 modelinin performans ölçütleri Tablo 4.7'de sunulmuştur.

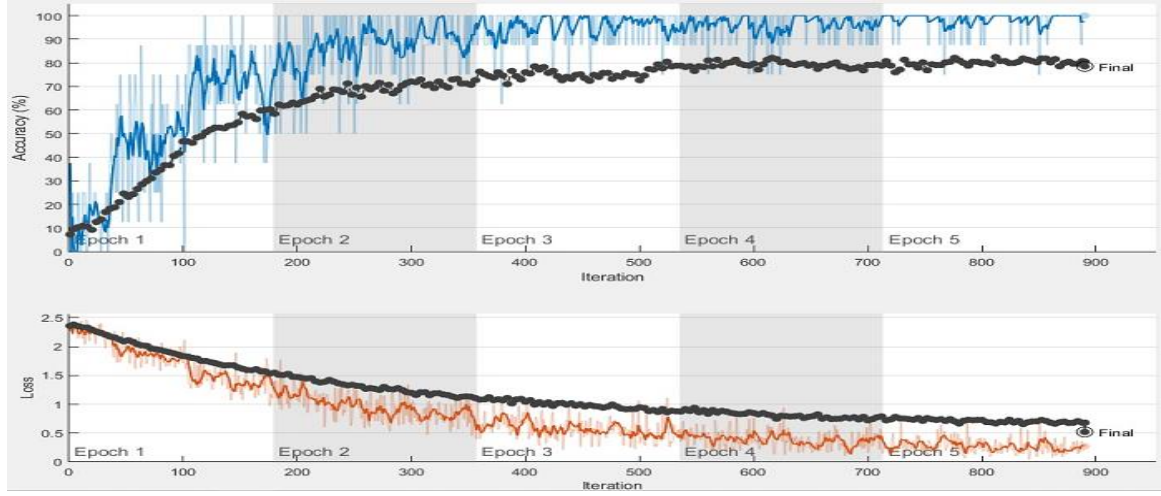
Tablo 4.7. Densenet201 modelinde elde edilen performans değerleri

	FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
Dalış	0	0	0	%100	%100	%100	%100
Golf	0	0	0	%100	%100	%100	%100
Tekme	0.0402	0.5833	0	%58.81	%100	%95.97	%41.66
Kaldırma	0	0	0	%100	%100	%100	%100
At Binme	0	0	0.4237	%73.11	%57.12	%100	%100
Koşma	0	0	0.0256	%98.69	%97.43	%100	%100
Kaykay	0.0560	0.4186	0.3243	%62.49	%67.56	%94.39	%58.13
ArtistikJimmastik1	0	0	0	%100	%100	%100	%100
ArtistikJimmastik2	0	0	0	%100	%100	%100	%100
Yürüyüş	0.0779	0.4285	0.0036	%60.37	%64	%92.2	%57.14

Tablo 4.7'de de görüldüğü gibi Densenet201 modeli Dalış, Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında %100 'lük bir doğruluk değeri elde ederken, Tekme sınıfında %41.66, Kaykay sınıfında %58.13 ve Yürüyüş sınıfında %57.14 doğruluk değeri elde etmiştir. Densenet201 mimarisinin en başarısız olduğu sınıf %41.66 ile Tekme sınıfı olmuştur.

InceptionV3

Bu çalışmada insan hareketleri veri setindeki görüntüleri sınıflandırmak için kullanılan bir başka model InceptionV3 modelidir. Toplamda 890 adım çalışan InceptionV3 modelinin giriş katmanı görüntüleri 299x299x3 boyutunda almaktadır. InceptionV3 modeli ile elde edilen doğruluk ve kayıp eğrisi Şekil 4.7'de verilmiştir.



Şekil 4.7. InceptionV3 modelin doğruluk ve kayıp eğrisi

InceptionV3 modeli ile %78.49 oranında doğruluk değeri elde edilmiştir. InceptionV3 modelinin karışıklık matrisi Tablo 4.8’de verilmiştir.

Tablo 4.8. InceptionV3 modelinin karışıklık matrisi

Doğru Sınıf	Dalış	22									1
	Golf		30								
	Tekme		1	5			6				12
	Kaldırma				24						
	At Binme					34					
	Koşma						38				
	Kaykay						13	12			18
	ArtistikJimmastik1								52		
	ArtistikJimmastik2									34	
	Yürüyüş					26					30
		Dalış	Golf	Tekme	Kaldırma	At Binme	Koşma	Kaykay	Artistik Jimmastik1	Artistik Jimmastik2	Yürüyüş
		Tahmin Edilen Sınıf									

Tablo 4.8’de verilen karışıklık matrisinde de görüldüğü gibi InceptionV3 modeli Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında test için kullanılan görüntülerin hepsini doğru tahmin etmiştir. Bu sınıflarda doğru tahmin edilen görüntü

sayısı 212'dir. InceptionV3 modeli Dalış sınıfında bulunan 23 görüntüden 22 tanesini doğru tahmin ederken 1 tanesini Yürüyüş diye yanlış tahmin etmiştir. Modelin bu sınıftaki doğruluk oranı %95.65'tir. InceptionV3 modeli Tekme sınıfında bulunan 24 görüntüden 5 tanesini doğru tahmin ederken, 1 tanesini Golf, 6 tanesini Koşma, 12 tanesini ise Yürüyüş diye yanlış tahmin etmiştir. Modelin bu sınıftaki doğruluk oranı %20.83'tür. Modelin en başarısız olduğu sınıf bu sınıftır. Aynı model Kaykay sınıfında bulunan 43 görüntüden 12 tanesini doğru tahmin ederken, 13 tanesini Koşma diye ve 18 tanesini Yürüyüş diye yanlış tahmin etmiştir. Modelin bu sınıftaki doğruluk oranı %27.90 olmuştur. Son olarak InceptionV3 modeli Yürüyüş sınıfında bulunan 56 görüntüden 30 tanesini doğru tahmin ederken, 26 tanesini At Binme diye yanlış tahmin etmiştir. Modelin bu sınıftaki doğruluk oranı %53.57 olmuştur. Karışıklık matrisi incelendiğinde InceptionV3 modeli toplam 358 görüntünün 281 tanesini doğru tahmin ederken 77 tanesini yanlış tahmin etmiştir. Özellikle Tekme ve Kaykay sınıflarında InceptionV3 modelinin yanlış tahmin ettiği görüntü sayısı doğru tahmin ettiği görüntü sayısından fazladır.

InceptionV3 modelinin performans ölçütleri Tablo 4.9'da sunulmuştur.

Tablo 4.9. InceptionV3 modelinde elde edilen performans değerleri

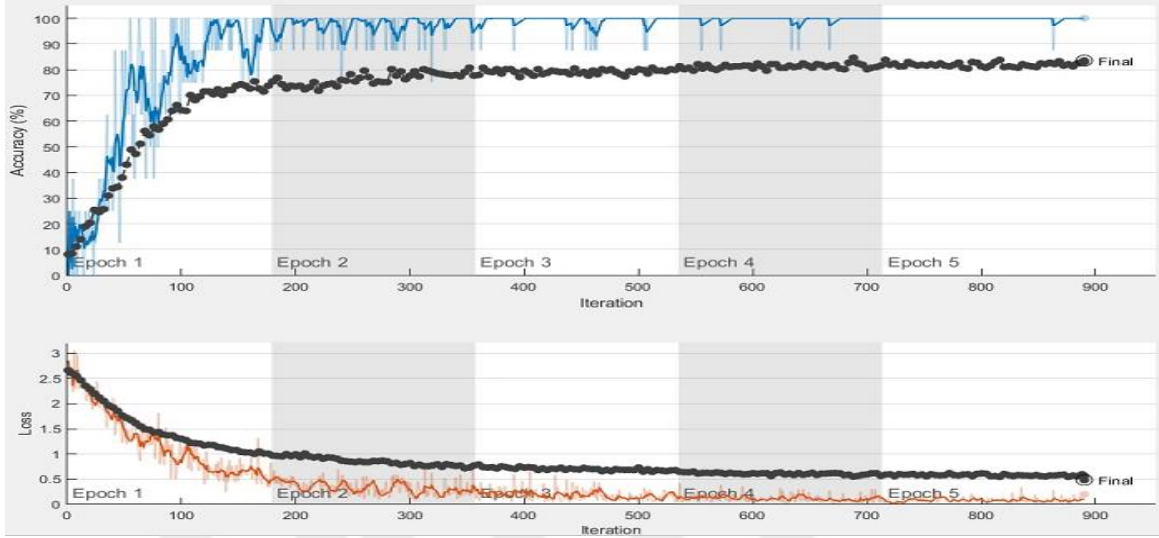
	FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
Dalış	0.0029	0.0434	0	%97.77	%100	%99.70	%95.65
Golf	0	0	0.0322	%98.35	%96.77	%100	%100
Tekme	0.0538	0.7916	0	%34.48	%100	%94.61	%20.83
Kaldırma	0	0	0	%100	%100	%100	%100
At Binme	0	0	0.4333	%72.33	%56.66	%100	%100
Koşma	0	0	0.3333	%79.95	%66.66	%100	%100
Kaykay	0.0895	0.7209	0	%43.62	%100	%91.04	%27.90
ArtistikJimmastik1	0	0	0	%100	%100	%100	%100
ArtistikJimmastik2	0	0	0	%100	%100	%100	%100
Yürüyüş	0.0875	0.4642	0.5081	%51.28	%49.18	%91.24	%53.57

Tablo 4.9'da da görüldüğü gibi InceptionV3 modeli Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında %100 'lük bir doğruluk değeri elde ederken, Dalış sınıfında %95.65, Tekme sınıfında %20.83, Kaykay sınıfında %27.90 ve Yürüyüş sınıfında %53.57 doğruluk değeri elde etmiştir. InceptionV3 mimarisinin en başarısız olduğu sınıf %20.83 ile Tekme sınıfı olmuştur.

Resnet50

İnsan hareketleri görüntülerini sınıflandırmak için kullanılan bir başka model 2015 yılında yapılan ILSVRC ImageNet yarışmasının kazananı olan Resnet50 modelidir. Toplamda 890 adım

çalıřan Resnet50 modeli, giriř katmanı görüntülerini 224x224x3 boyutunda almaktadır. Resnet50 modeli ile elde edilen dođruluk ve kayıp eđrisi Őekil 4.8'de verilmiřtir.



Őekil 4.8. Resnet50 modelin dođruluk ve kayıp eđrisi

Resnet50 modeli ile %83.52 oranında dođruluk deđeri elde edilmiřtir. Resnet50 modelinin karıřıklık matrisi Tablo 4.10'da verilmiřtir.

Tablo 4.10. Resnet50 modelinin karıřıklık matrisi

Dođru Sınıf	Dalıř	23								
	Golf		30							
	Tekme			9			11			4
	Kaldırma				24					
	At Binme					34				
	Kořma						38			
	Kaykay							25		18
	ArtistikJimmastik1								52	
	ArtistikJimmastik2									34
	Yürüyüř						26			
	Dalıř	Golf	Tekme	Kaldırma	At Binme	Kořma	Kaykay	Artistik Jimmastik1	Artistik Jimmastik2	Yürüyüř
Tahmin Edilen Sınıf										

Tablo 4.10'da verilen karışıklık matrisinde de görüldüğü gibi Dalış, Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında test için kullanılan görüntülerin hepsi doğru tahmin edilmiştir. Bu sınıflarda doğru tahmin edilen görüntü sayısı 235'dir. Resnet50 modeli Tekme sınıfında bulunan 24 görüntüden 9 tanesini doğru tahmin ederken 15 tanesini yanlış tahmin etmiştir. Kaykay sınıfında bulunan 43 görüntüden 25 tanesini doğru tahmin ederken, 18 tanesini Yürüyüş diye yanlış tahmin etmiştir. Son olarak Yürüyüş sınıfında bulunan 56 görüntüden 30 tanesini doğru tahmin ederken, 26 tanesini At Binme diye yanlış tahmin etmiştir. Karışıklık matrisi incelendiğinde Resnet50 modeli toplam 358 görüntünün 299 tanesini doğru tahmin ederken 59 tanesini yanlış tahmin etmiştir. Özellikle Tekme sınıfında Resnet50 modelinin yanlış tahmin ettiği görüntü sayısı doğru tahmin ettiği görüntü sayısından fazladır. Resnet50 modelinin performans ölçütleri Tablo 4.11'de sunulmuştur.


Tablo 4.11. Resnet50 modelinde elde edilen performans değerleri

	FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
Dalış	0	0	0	%100	%100	%100	%100
Golf	0	0	0	%100	%100	%100	%100
Tekme	0.0429	0.625	0	%54.54	%100	%95.70	%37.5
Kaldırma	0	0	0	%100	%100	%100	%100
At Binme	0	0	0	%100	%100	%100	%100
Koşma	0	0	0.2244	%87.37	%77.55	%100	%100
Kaykay	0.0586	0.418	0.5098	%53.18	%49.01	%94.13	%58.13
ArtistikJimmastik1	0	0	0	%100	%100	%100	%100
ArtistikJimmastik2	0	0	0	%100	%100	%100	%100
Yürüyüş	0.0849	0.4642	0.4230	%55.55	%57.69	%91.5	%53.57

Tablo 4.11'de de görüldüğü gibi Resnet50 modeli Dalış, Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında %100'lük bir doğruluk değeri elde ederken, Tekme sınıfında %37.5, Kaykay sınıfında %58.13 ve Yürüyüş sınıfında %53.57 doğruluk değeri elde etmiştir. InceptionV3 mimarisinin en başarısız olduğu sınıf %37.5 ile Tekme sınıfı olmuştur.

Googlenet

Bu çalışmada insan hareketleri veri setindeki görüntüleri sınıflandırmak için kullanılan bir başka model Googlenet modelidir. Googlenet modeli 2014 yılında yapılan ILSVRC ImageNet yarışmasının kazananıdır. Googlenet modeli ardışık bir yapıda katmanları sıralamaktan uzaklaşan ilk modellerdendir. Bu model giriş verilerini 224x224x3 boyutunda almaktadır. Googlenet modeli ile elde edilen doğruluk ve kayıp eğrisi Şekil 4.9'da verilmiştir.



Şekil 4.9. GoogLeNet modelinin doğruluk ve kayıp eğrisi

GoogLeNet modeli ile %88.55 oranında doğruluk değeri elde edilmiştir. GoogLeNet modelinin karışıklık matrisi Tablo 4.12’de verilmiştir.

Tablo 4.12. GoogLeNet modelinin karışıklık matrisi

Doğru Sınıf	Dalış	23									
	Golf		30								
	Tekme			9			15				
	Kaldırma				24						
	At Binme					34					
	Koşma						38				
	Kaykay						1	24			18
	ArtistikJimmastik1								52		
	ArtistikJimmastik2								2	32	
	Yürüyüş					5					51
	Dalış	Golf	Tekme	Kaldırma	At Binme	Koşma	Kaykay	Artistik Jimnastik1	Artistik Jimnastik2	Yürüyüş	
											Tahmin Edilen Sınıf

GoogLeNet mimarisinde Tablo 4.12’de elde edilen karışıklık matrisinde de görüldüğü gibi Dalış, Golf, Kaldırma, At Binme, Koşma ve ArtistikJimmastik1 sınıflarında test için kullanılan görüntülerin hepsi doğru tahmin edilmiştir. Bu sınıflarda doğru tahmin edilen görüntü sayısı

201'dir. Googlenet modeli Tekme sınıfında bulunan 24 görüntüden 9 tanesini doğru tahmin ederken 15 tanesini Koşma diye yanlış tahmin etmiştir. Kaykay sınıfında bulunan 43 görüntüden 24 tanesini doğru tahmin ederken, 1 tanesini Koşma ve 18 tanesini Yürüyüş diye yanlış tahmin etmiştir. ArtistikJimmastik2 sınıfında bulunan 34 görüntüden 32 tanesini doğru tahmin ederken, 2 tanesini ArtistikJimmastik1 diye yanlış tahmin etmiştir. Son olarak Yürüyüş sınıfında bulunan 56 görüntüden 51 tanesini doğru tahmin ederken, 5 tanesini At Binme diye yanlış tahmin etmiştir. Karışıklık matrisi incelendiğinde Googlenet modeli toplam 358 görüntünün 317 tanesini doğru tahmin ederken 41 tanesini yanlış tahmin etmiştir. Özellikle Tekme sınıfında Googlenet modelinin yanlış tahmin ettiği görüntü sayısı doğru tahmin ettiği görüntü sayısından daha fazladır. Diğer modellerde olduğu gibi Googlenet modelinde de tekme sınıfında yüksek başarımlar elde edilememiştir.

Googlenet modelinin performans ölçütleri Tablo 4.13'de sunulmuştur.


Tablo 4.13. Googlenet modelinde elde edilen performans değerleri

	FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
Dalış	0	0	0	%100	%100	%100	%100
Golf	0	0	0	%100	%100	%100	%100
Tekme	0.0429	0.625	0	%54.54	%100	%95.70	%37.5
Kaldırma	0	0	0	%100	%100	%100	%100
At Binme	0	0	0.1282	%93.15	%87.17	%100	%100
Koşma	0	0	0.2962	%82.60	%70.37	%100	%100
Kaykay	0.0568	0.4418	0	%71.64	%100	%94.31	%55.81
ArtistikJimmastik1	0	0	0.0370	%98.11	%96.29	%100	%100
ArtistikJimmastik2	0.0061	0.0588	0	%96.96	%100	%99.38	%94.11
Yürüyüş	0.0173	0.0892	0.2608	%81.60	%73.91	%98.26	%91.07

Tablo 4.13'de de görüldüğü gibi Googlenet modeli Dalış, Golf, Kaldırma, At Binme, Koşma ve ArtistikJimmastik1 sınıflarında %100 'lük bir doğruluk değeri elde ederken, Tekme sınıfında %37.5, Kaykay sınıfında %55.81, Yürüyüş sınıfında %91.07 ve ArtistikJimmastik2 sınıfında %94.11 doğruluk değeri elde etmiştir. Googlenet mimarisinin en başarısız olduğu sınıf %37.5 ile Tekme sınıfı olmuştur.

MobilenetV2

MobilenetV2 modeli daha düşük veri işleme yeteneğine sahip mobil ve derin öğrenme uygulamalarını gerçekleştirmeyi amaçlamıştır. İnsan hareketleri veri setini sınıflandırmak için kullanılan bir başka model MobilenetV2'dir. MobilenetV2 modeli ile elde edilen doğruluk ve kayıp eğrisi Şekil 4.10'da verilmiştir.



Şekil 4.10. MobilenetV2 modelinin doğruluk ve kayıp eğrisi

MobilenetV2 modeli ile %90.5 oranında doğruluk değeri elde edilmiştir. MobilenetV2 modelinin karışıklık matrisi Tablo 4.14'te verilmiştir.

Tablo 4.14. MobilenetV2 modelinin karışıklık matrisi

Doğru Sınıf	Dalış	23								
	Golf		30							
	Tekme	1		8			8	2		5
	Kaldırma				24					
	At Binme					34				
	Koşma						38			
	Kaykay							26		17
	ArtistikJimmastik1								52	
	ArtistikJimmastik2									34
	Yürüyüş			1						
	Dalış	Golf	Tekme	Kaldırma	At Binme	Koşma	Kaykay	ArtistikJimmastik1	ArtistikJimmastik2	Yürüyüş

Tahmin Edilen Sınıf

MobilenetV2 mimarisinde Tablo 4.14'te elde edilen karışıklık matrisinde de görüldüğü gibi Dalış, Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında test için kullanılan görüntülerin hepsi doğru tahmin edilmiştir. Bu sınıflarda doğru tahmin edilen

görüntü sayısı 237'dir. MobilenetV2 modeli Tekme sınıfında bulunan 24 görüntüden 8 tanesini doğru tahmin ederken, 1 tanesini Dalış, 8 tanesini koşma, 2 tanesini Kaykay ve 5 tanesini yürüyüş olarak yanlış tahmin etmiştir. Kaykay sınıfında bulunan 43 görüntüden 26 tanesini doğru tahmin ederken, 17 tanesini Yürüyüş diye yanlış tahmin etmiştir. Son olarak Yürüyüş sınıfında bulunan 56 görüntüden 55 tanesini doğru tahmin ederken, 1 tanesini Tekme diye yanlış tahmin etmiştir. Karışıklık matrisi incelendiğinde MobilenetV2 modeli toplam 358 görüntünün 324 tanesini doğru tahmin ederken 34 tanesini yanlış tahmin etmiştir. Özellikle Tekme sınıfında MobilenetV2 modelinin yanlış tahmin ettiği görüntü sayısı doğru tahmin ettiği görüntü sayısından daha fazladır. MobilenetV2 modelinin performans ölçütleri Tablo 4.15'te sunulmuştur.


Tablo 4.15. MobilenetV2 modelinde elde edilen performans değerleri

	FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
Dalış	0	0	0.0416	%97.87	%95.83	%100	%100
Golf	0	0	0	%100	%100	%100	%100
Tekme	0.0458	0.6666	0.1111	%48.48	%88.88	%95.41	%33.33
Kaldırma	0	0	0	%100	%100	%100	%100
At Binme	0	0	0	%100	%100	%100	%100
Koşma	0	0	0.1739	%90.47	%82.60	%100	%100
Kaykay	0.0515	0.3953	0.0714	%73.23	%92.85	%94.84	%60.46
ArtistikJimmastik1	0	0	0	%100	%100	%100	%100
ArtistikJimmastik2	0	0	0	%100	%100	%100	%100
Yürüyüş	0.0035	0.0178	0.2857	%82.52	%71.42	%99.64	%98.21

Tablo 4.15'te de görüldüğü gibi MobilenetV2 modeli Dalış, Golf, Kaldırma, At Binme, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında %100'lük bir doğruluk değeri elde ederken, Tekme sınıfında %33.33, Kaykay sınıfında %60.46 ve Yürüyüş sınıfında %98.21 doğruluk değeri elde etmiştir. MobilenetV2 mimarisinin en başarısız olduğu sınıf %33.33 ile Tekme sınıfı olmuştur.

Efficientnetb0

İnsan hareketleri videoları kullanılarak elde edilen görüntü veri setini sınıflandırmak için kullanılan bir başka mimari Efficientnetb0 mimarisidir. Bu mimari tasarlandığı zaman derinlik, genişlik ve çözünürlük parametreleri birlikte göz önünde bulundurularak tasarlanmıştır. Efficientnetb0 mimarisi ile elde edilen doğruluk ve kayıp eğrisi Şekil 4.11'de sunulmuştur.



Şekil 4.11. Efficientnetb0 modelinin doğruluk ve kayıp eğrisi

Efficientnetb0 modeli ile %79.89 oranında doğruluk değeri elde edilmiştir. Efficientnetb0 modelinin karışıklık matrisi Tablo 4.16’da verilmiştir.

Tablo 4.16. Efficientnetb0 modelinin karışıklık matrisi

Doğru Sınıf	Dalış	21					1	1		
	Golf		28			1				1
	Tekme		3	2	1	2		2	13	1
	Kaldırma				24					
	At Binme					26	1	7		
	Koşma						35		3	
	Kaykay						1	34		8
	ArtistikJimmastik1								52	
	ArtistikJimmastik2									34
	Yürüyüş		4			1		21		
	Dalış	Golf	Tekme	Kaldırma	At Binme	Koşma	Kaykay	ArtistikJimmastik1	ArtistikJimmastik2	Yürüyüş

Tahmin Edilen Sınıf

Efficientnetb0 mimarisi, Tablo 4.16’da verilen karışıklık matrisinde de görüldüğü gibi Kaldırma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında test için kullanılan görüntülerin hepsini doğru tahmin etmiştir. Bu sınıflarda doğru tahmin edilen görüntü sayısı 110’dur. Efficientnetb0 modeli Dalış sınıfında bulunan 23 test görüntüsünde 21 tanesi doğru

sınıflandırılırken, 2 tanesi yanlış sınıflandırılmıştır. Golf sınıfındaki 30 görüntüden 28 tanesi doğru sınıflandırılırken, 2 tanesi yanlış sınıflandırılmıştır. Tekme sınıfında bulunan 24 görüntüden 2 tanesini doğru tahmin ederken 22 tanesini yanlış tahmin etmiştir. At Binme sınıfında bulunan 34 tane test görüntüsünden 26 tanesi doğru sınıflandırılırken 8 tanesi yanlış sınıflandırılmıştır. Kaykay sınıfında bulunan 43 görüntüden 34 tanesini doğru tahmin ederken, 9 tanesini yanlış tahmin etmiştir. Son olarak Yürüyüş sınıfında bulunan 56 görüntüden 30 tanesini doğru tahmin ederken, 26 tanesini yanlış tahmin etmiştir. Efficientnetb0 modelinin performans ölçütleri Tablo 4.17’de sunulmuştur.

Tablo 4.17. Efficientnetb0 modelinin performans değerleri


	FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
Dalış	0.0059	0.0869	0	%95.49	%100	%99.40	%91.30
Golf	0.0061	0.0666	0.2	%86.15	%80	%99.38	%93.33
Tekme	0.0617	0.9166	0	%15.38	%100	%93.82	%8.33
Kaldırma	0	0	0.04	%97.95	%96	%100	%100
At Binme	0.0243	0.2352	0.1333	%81.25	%86.66	%97.56	%76.47
Koşma	0.0093	0.0789	0.0540	%93.33	%94.59	%99.06	%92.1
Kaykay	0.0307	0.2093	0.4769	%62.96	%52.30	%96.92	%79.06
ArtistikJimmastik1	0	0	0.2463	%85.95	%75.36	%100	%100
ArtistikJimmastik2	0	0	0	%100	%100	%100	%100
Yürüyüş	0.0817	0.4642	0.25	%62.5	%75	%91.82	%53.57

Tablo 4.17 incelendiğinde Efficientnetb0 modelinin en başarılı olduğu sınıfların Kaldırma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıfları olduğu gözükmemektedir. Efficientnetb0 modeli bu sınıflardaki görüntüleri %100 doğrulukla sınıflandırmıştır. Efficientnetb0 modelinin en başarısız olduğu sınıf ise Tekme sınıfıdır. Modelin bu sınıftaki doğruluk oranı %8.33’tür. Efficientnetb0 modeli golf sınıfındaki görüntüleri sınıflandırırken %93.33, At Binme sınıfındaki görüntüleri sınıflandırırken %76.47, Koşma sınıfındaki görüntüleri sınıflandırırken %92.1, Kaykay sınıfındaki görüntüleri sınıflandırırken %79.06 ve Yürüyüş sınıfındaki görüntüleri sınıflandırırken %53.57 oranında doğruluk değeri elde etmiştir.

Önerilen Yöntem

Veri setindeki insan hareketlerinin sınıflandırılması için yeni bir ESA tabanlı model önerilmiştir. Önerilen model giriş katmanı dâhil toplam 43 katmandan oluşmaktadır. Önerilen modelde 10 evrişim katmanı, 11 tane Relu aktivasyon fonksiyonu, 7 tane maksimum ortaklama katmanı, 10 yığın normalleştirme katmanı, 2 FC katmanı, 1 Softmax katmanı ve 1 sınıflandırma katmanı kullanılmıştır. Önerilen bu model giriş görüntülerini 227x227x3 boyutunda almaktadır.

Önerilen model toplam 892 adım çalışmıştır. Önerilen modelin doğruluk ve kayıp eğrisi Şekil 4.12’de verilmiştir.



Şekil 4.12. Önerilen modelin doğruluk ve kayıp eğrisi

Önerilen model ile %91.34 oranında doğruluk değeri elde edilmiştir. Önerilen modelinin karışıklık matrisi Tablo 4.18’de verilmiştir.

Tablo 4.18. Önerilen modelin karışıklık matrisi

Doğru Sınıf	Dalış	23								
	Golf		30							
	Tekme	2	1	15			5			1
	Kaldırma				24					
	At Binme					32				2
	Koşma						38			
	Kaykay							25		18
	ArtistikJimmastik1								52	
	ArtistikJimmastik2									34
	Yürüyüş					2				54
	Dalış	Golf	Tekme	Kaldırma	At Binme	Koşma	Kaykay	ArtistikJimmastik1	ArtistikJimmastik2	Yürüyüş

Tahmin Edilen Sınıf

Tablo 4.18’de elde edilen karışıklık matrisinde de görüldüğü gibi önerilen model Dalış, Golf, Kaldırma, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında test için kullanılan görüntülerin hepsini doğru tahmin etmiştir. Önerilen model, Tekme sınıfında bulunan 24 görüntüden 15 tanesini doğru tahmin ederken 9 tanesini yanlış tahmin etmiştir. Çalışmada kullanılan modeller içerisinde Tekme sınıfına ait görüntüleri tahmin etmede en başarılı model önerilen model olmuştur. Diğer modellerin doğruluk oranları %50 ve %50’nin altında kalırken, önerilen modelde bu sınıfa ait doğruluk oranı %62.5 olmuştur. Önerilen model At Binme sınıfındaki 34 görüntünün 32 tanesini doğru tahmin ederken, 2 tanesini yanlış tahmin etmiştir. Aynı model Kaykay sınıfında bulunan 43 görüntüden 28 tanesini doğru tahmin ederken, 18 tanesini yanlış tahmin etmiştir. Son olarak Yürüyüş sınıfında bulunan 56 görüntüden 54 tanesini doğru tahmin ederken, 2 tanesini yanlış tahmin etmiştir. Karışıklık matrisi incelendiğinde önerilen model toplam 358 görüntünün 327 tanesini doğru tahmin ederken 31 tanesini yanlış tahmin etmiştir. Önerilen modelinin performans ölçütleri Tablo 4.19’da sunulmuştur.

Tablo 4.19. Önerilen modelin performans değerleri

	FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
Dalış	0	0	8	95,8%	92%	100%	100%
Golf	0	0	3,22	98,3%	96,7%	100%	100%
Tekme	2,62	37,5	0	76,92%	100%	97,37%	62,5%
Kaldırma	0	0	0	100%	100%	100%	100%
At Binme	0.61	5.88	5.88	94.11%	94.11%	99.38%	94.11%
Koşma	0	0	11.62	93.82%	88.37%	100%	100%
Kaykay	5.40	41.86	0	73.52%	100%	94.59%	58.13%
ArtistikJimmastik1	0	0	0	100%	100%	100%	100%
ArtistikJimmastik2	0	0	0	100%	100%	100%	100%
Yürüyüş	0.7	3.57	28	82.43%	72%	99.29%	96.42%

Tablo 4.19’da verilen başarımlar ölçütleri incelendiğinde önerilen model Dalış, Golf, Kaldırma, Koşma, ArtistikJimmastik1 ve ArtistikJimmastik2 sınıflarında %100 ‘lük bir doğruluk değeri elde ederken, Tekme sınıfında %62.5, At Binme sınıfında %94.11, Kaykay sınıfında %58.13 ve Yürüyüş sınıfında %96.42 doğruluk değeri elde etmiştir. Çalışmada kullanılan diğer mimarilerde en başarısız sonuçlar Tekme sınıfında alınırken, önerilen modelde en başarısız sınıf %58.13 ile Kaykay sınıfı olmuştur.

4.5. Sonular ve Tartışma

İnsan hareketlerini sınıflandırılması gelişen teknoloji ile birlikte önemli konulardan biri haline gelmiştir. Gelişen teknoloji beraberinde büyük miktardaki veri setlerindeki verilerin işlenmesini daha kolay bir hale getirmektedir. Veri setlerinde ki büyük miktarlarda ki verilerin anlam kazanabilmesi için işlenmesi gerekmektedir. İşlenen bu veriler farklı amaçlar için kullanılabilirse o zaman bir anlam ifade etmektedir. İnsan hareketlerinin sınıflandırılmasıyla ilgili literatürde yapılan birçok çalışma mevcuttur. İnsan hareketlerinin sınıflandırılması sağlıktan güvenliğe, spordan sosyal hayata, nesne takibinden oyun endüstrisine kadar pek çok alanda kullanılmaktadır. Bu çalışmada video görüntülerini sınıflandırmak için ESA mimarilerinden olan Alexnet, Densenet201, InceptionV3, Resnet50, Googlenet, MobilenetV2 ve Efficientnetb0 modelleri kullanılmıştır. Bu modellerde elde edilen en yüksek doğruluk değeri %90.5 olmuştur.

Daha sonra aynı video görüntüleri önerilen model ile sınıflandırılmıştır. Önerilen modelde %91.34 ile en yüksek doğruluk oranı elde edilmiştir. Çalışmada kullanılan modellerin doğruluk oranları Tablo 4.20’de verilmiştir.

Tablo 4.20. Modellerin doğruluk oranları.

Alexnet	Densenet201	InceptionV3	Resnet50	Googlenet	MobilenetV2	Efficientnetb0	Önerilen Yöntem
%84.36	%84.36	%78.49	%83.52	%88.55	%90.5	%79.89	%91.34

Tablo 4.20’de da görüldüğü gibi geliştirilen model Alexnet, Densenet201, InceptionV3, Resnet50, Googlenet, MobilenetV2 ve Efficientnetb0 modellerinden daha yüksek bir doğruluk değeri elde etmiştir. İnsan hareketlerinin sınıflandırılması için önerdiğimiz model kullanılan modeller arasında %91,34 ile en başarılı model olmuştur.

5. BEYİN MR GÖRÜNTÜLERİNİN DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK SINIFLANDIRILMASI

Beyin tümörü beyinde anormal hücrelerin çoğalması sonucunda yetişkinlerde ve çocuklarda gelişen ölümcül bir hastalıktır. Beyin tümörlerinin sıklığı yaşla birlikte artış göstermektedir. Beyin tümörleri iyi huylu ve kötü huylu olmak üzere iki gruba ayrılırlar. Beyin tümörleri beyin içinde oluşan tümörlerin yanı sıra vücudun farklı bir yerindeki tümörün beyine yayılması sonucunda meydana gelebilmektedirler. Beyin tümörü görülen hastalarda özellikle sabahları daha şiddetli olan baş ağrısı, bulantı, kusma, görme bozukluğu ve nöbet gibi şikâyetler görülebilmektedir. Beyin tümörlerinin tanısında bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) başlıca kullanılan radyolojik görüntüleme yöntemleridir. MRG beyin görüntülenmesinde daha çok tercih edilen görüntüleme yöntemidir [133, 134].

Beyin tümörlerinin erken ve doğru bir biçimde teşhisi, hastaların tedavi yöntemi ve takip açısından önemlidir. Uzmanların beyin tümörünü bilgisayar destekli sistemler kullanarak tespit etmesi önemli bir adımdır. Bu sistemler, uzmanların tümör tespitini daha kolay gerçekleştirmesine olanak tanımakla birlikte geleneksel yöntemlerle yapılan hataların da önüne geçebilmektedir. Bu bölümde beyin tümörünün MR görüntüleri kullanılarak teşhis edilmesi amaçlanmıştır. Teşhis sürecinde derin öğrenme ağlarından biri olan ESA modelleri kullanılmaktadır. Önceden eğitilmiş bu ESA modellerinin haricinde ayrıca hibrit bir model önerilmiştir. Önerilen modelde ESA mimarilerinden olan Resnet50 taban olarak kullanılmıştır. Önerilen model ile alınan sonuçlar diğer ESA mimarileriyle elde edilen sonuçlarla karşılaştırıldığında, önerilen modelin daha başarılı olduğu görülmüştür. Önerilen modelde elde edilen doğruluk oranı %97.01'dir. Uygulama bölümünde önerilen modelin ve çalışmada kullanılan diğer ESA modellerinin performans ölçütleri detaylı bir şekilde açıklanmıştır.

5.1. Literatür Taraması

Literatürde tümör tespiti için beyin MR görüntüleri kullanılarak yapılmış benzer çalışmalar mevcuttur. Özyurt ve arkadaşları [135] beyin tümörü görüntülerini sınıflandırmak için 160 görüntüden oluşan bir veri seti kullanmışlardır. Burada 80 tane iyi huylu, 80 tane kötü huylu görüntü mevcuttur. Yazarlar yapılan çalışmada manuel özellik çıkarmamak için ESA mimarilerini kullandıklarını belirtmişlerdir. Yazarlar yapılan bu çalışmada segmentasyon ve sınıflandırma yöntemlerini kullanarak hibrit bir model önermişlerdir. Yapılan çalışmada beyin MR görüntülerini sınıflandırmak için makine öğrenmesi sınıflandırıcılarından olan SVM ve KNN sınıflandırıcıları kullanılmıştır. Önerilen yöntemle SVM sınıflandırıcısında %95.62 doğruluk değeri elde edilmiştir.

Toğaçar ve arkadaşları [136] yaptıkları çalışmada Alexnet ve VGG16 mimarilerini kullanmışlardır. Yapılan çalışmada softmax katmanından önceki tam bağlı (fc8) katmandan özellikler elde edilmiştir. Her bir mimaride elde edilen özellikler birleştirilmiştir. Yapılan çalışmada özyinelemeli özellik seçme (RFE) yöntemi kullanılarak birleştirilen bu özellikler içerisinde özellik seçimi gerçekleştirilmiştir. Ayrıca çalışmada veri çoğullama işlemi için birden fazla yöntem kullanılmıştır. Yazarlar yaptıkları bu çalışmada SVM sınıflandırıcısında %96.77 doğruluk oranı elde etmişlerdir.

Amin ve arkadaşları [137] yaptıkları çalışmada beyin MR görüntülerini kullanmışlardır. Farklı kesitlerdeki MR görüntülerini Ayrık Dalgacık Dönüşümü kullanarak birleştirmişlerdir. Yazarlar bu çalışmada tümör görüntülerini öncelikle global bir eşikleme yöntemi kullanarak segmentlere ayırmışlar. Yapılan çalışmada yazarlar segmentasyon işleminden sonra bu görüntüleri 23 katmanlı bir ESA mimarisine aktardıklarını ve burada ki ortalama doğruluk değerlerinin %96.7 olduğunu belirtmişlerdir. Ayrıca yapılan bu çalışmada 5 farklı veri seti kullanıldığı görülmüştür.

Mohsen ve arkadaşları [138] yaptıkları çalışmalarında makalenin katkısını, beyin MR görüntülerini kullanarak otomatik beyin tümörleri sınıflandırması yapmak ve performansını ölçmek için derin öğrenme mimarilerini uygulamak olarak tanımlamışlardır. Önerilen yöntemde, yazarlar beyin MR görüntülerini kullanarak normal beyin görüntüleri ile beyin tümörleri arasında ayırım yapmayı amaçlamışlardır. Yapılan bu çalışmada derin öğrenme mimarileri kullanılmıştır. Özellik çıkarımı için Ayrık Dalgacık Dönüşümü (DWT) kullanılmıştır. Elde edilen özellikler farklı sınıflandırıcılarda sınıflandırılmıştır. Yapılan çalışmada yazarlar, elde ettikleri en yüksek doğruluk oranının derin öğrenme mimarilerinde %96.97 olduğunu belirtmişlerdir.

Pareek ve arkadaşları [139] yaptıkları çalışmada tümörün var olup olmadığını kontrol eden bir sistem önerdiklerini belirtmişlerdir. Yapılan çalışmada beyin tümörünün tespiti ve sınıflandırılması için 150 T1 ağırlıklı MRI beyin görüntüsü üzerinde çalışıldığı görülmüştür. Yapılan çalışmada özellik çıkarımı için GLCM ve DWT yöntemleri kullanılmıştır. Yazarlar elde ettikleri özellikleri azaltmak için temel bileşenler analizi yöntemini kullanmışlar. Yapılan çalışmada beyin tümörünü sınıflandırmak için %97 doğruluk oranı elde edilmiştir. Ayrıca yazarlar tümörün evrelerini bulmak için tümörün alanını ve hacmini de hesapladıklarını belirtmişlerdir.

Anaraki ve arkadaşları [140] yaptıkları çalışmada MR görüntülerini sınıflandırmak için genetik algoritma ve ESA'dan oluşan bir model önerdiklerini belirtmişlerdir. Yazarlar önerdikleri yöntemi deneme yanılma yoluyla bulmadıklarını, genetik bir algoritma kullanarak geliştirdiklerini belirtmişlerdir. Ayrıca yazarlar çalışmalarında farklı doğruluk değerleri elde ettiklerini ve bu değerler arasında en yüksek doğruluk değerinin %94,2 olduğunu belirtmişlerdir.


Gumaei ve arkadaşları [141] yaptıkları çalışmada beyin MR görüntülerini sınıflandırmak için önerdikleri yöntemde RELM aşırı öğrenme makinesini kullandıklarını belirtmişlerdir. Çalışmalarının ilk adımı, kenarların ve bölgelerin kontrastını artırarak beyin görüntülerini önceden

işlemektir. Bu görüntülerin özellikleri daha sonra hibrit bir yöntem kullanılarak elde edilmiştir. Elde edilen bu özellikler RELM aşırı öğrenme makinası kullanılarak sınıflandırılmıştır. Yazarlar önerdikleri bu yöntemde %94.23 doğruluk değeri elde edildiğini belirtmişlerdir.

Das ve arkadaşları [142] yapmış oldukları çalışmada, T1 ağırlıklı kontrastlı MR görüntülerinde beyin tümörlerini sınıflandırmak için bir ESA modeli önerdiklerini belirtmişlerdir. Yazarlar önerilen modelin iki önemli adımdan oluştuğunu ifade etmişlerdir. Çalışmada ilk olarak, görüntüler farklı görüntü işleme teknikleri kullanılarak önceden işlenmiş ve ardından önceden işlenmiş görüntüyü önerdikleri ESA modelini kullanarak sınıflandırmışlardır. Yapılan çalışma üç tip beyin tümörü içeren 3064 görüntüden oluşan bir veri kümesi üzerinde gerçekleştirilmiştir. Önerilen ESA modeli %94.39 oranında bir doğruluk oranı elde etmiştir.

5.2. Veri Seti

Bu çalışmada kullanılan beyin tümörü MR görüntüleri, Kaggle web sitesinden [143] alınmıştır. Bu veri seti tümörlü ve tümörsüz beyin MR görüntülerinden oluşmaktadır. Veri setinde 98 tane tümörsüz beyin MR görüntüsü mevcut iken, 155 tane tümörlü beyin MR görüntüsü mevcuttur. Tümörsüz MR görüntü sayısı az olduğundan dolayı, bu görüntüler yaklaşık 2 katına çoğullanmıştır. Toplamda 180 tane tümörsüz, 155 tane tümörlü beyin MR görüntüsü ile çalışılmıştır. Şekil 5.1’de veri setinde ki beyin MR görüntülerinden örnekler verilmiştir.

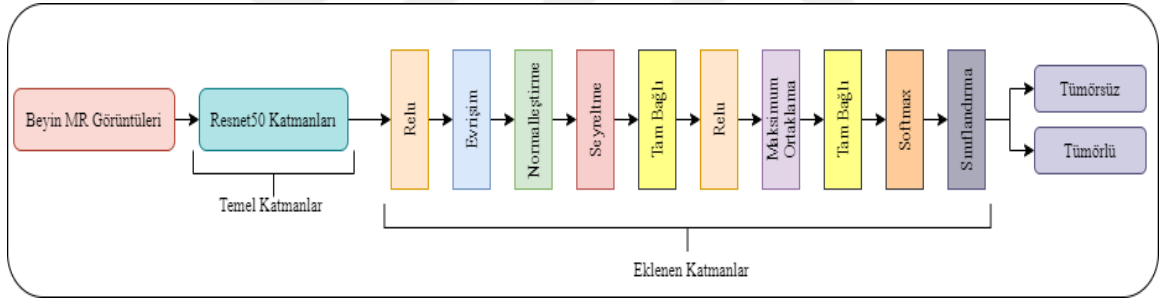


Şekil 5.1. Veri setinden örnek MR görüntüleri.

Şekil 5.1’de 4 tane tümörsüz, 4 tane tümörlü görüntü örneği verilmiştir. Seçilen görüntüler veri setinden rastgele seçilmiştir.

5.3. Materyal ve Yöntem


Önerilen yöntemde, 2015 yılında yapılan ILSVRC ImageNet yarışmasını kazanan Resnet50 modeli temel olarak kullanılmıştır. Sıfırdan bir ağ eğitmek yerine eğitilmiş bir model kullanılması tercih edilmiştir. Resnet50 modelinin temel olarak kullanılmasının nedeni, önceden eğitilmiş bu modelin birikiminden yararlanılmak istenmesidir. Geliştirilen modelde Resnet50’nin son 5 katmanı çıkartılmıştır. Çıkartılan bu 5 katmanın yerine 10 yeni katman eklenmiştir. Eklenen katmanlar sırasıyla Relu, evrişim, normalleştirme, seyreltme, tam bağlı, Relu, maksimum ortaklama, tam bağlı, Softmax ve sınıflandırma şeklindedir. Bahsedilen katmanlara giriş katmanı, aktivasyon fonksiyonları, normalleştirme ve ortaklama katmanları dâhildir. Önerilen modelde ayrıca Resnet50 modelinin giriş katmanı ve onu takip eden evrişim katmanı da güncellenmiştir. Geliştirilen modelin yapısı Şekil 5.2’de verilmiştir.



Şekil 5.2. Geliştirilen Resnet50 modelinin katman yapısı

Ayrıca veri setinde ki giriş görüntülerinin siyah beyaz olmasından dolayı giriş görüntüleri 224x224x1 boyutunda alınmıştır. Resnet50 mimarisinin giriş katmanı ve ilk evrişim katmanı da güncellenmiştir. Evrişim katmanları ile görüntülerin özellik haritaları çıkartılmaktadır. Aktivasyon fonksiyonu olarak Relu kullanılmıştır. Relu fonksiyonu sayesinde negatif eksende fonksiyonun sıfır değerini alması sağlanmış olur. Buradaki amaçlardan biri ağın daha hızlı bir şekilde çalışmasını sağlamaktır. Havuzlama katmanı için ise maksimum ortaklama tercih edilmiştir. Ayrıca ağın aşırı ezberlemesini engellemek seyreltme katmanı tercih edilen bir başka katmandır. Geliştirilen model ayrıca diğer ESA modelleri ile kıyaslanmıştır. Geliştirilen modelin ve karşılaştırma için kullanılan diğer ESA modellerinin doğruluk ve kayıp eğrileri, karışıklık matrisleri ve modellerin başarımları ölçütleri uygulama bölümünde verilmiştir. Önerilen model literatürde yapılmış benzer çalışmalar ve çalışmada kullanılan ESA mimarileriyle karşılaştırıldığında, önerilen modelin performans

ölçütlerinin başarılı olduğu gözlemlenmiştir. Şekil 5.3'te önerilen modelin çalışma prensibi verilmiştir.



Şekil 5.3. Önerilen modelin kaba gösterimi

Uygulama bölümünde ise beyin MR görüntülerinin sınıflandırılması için önceden eğitilmiş mimarilerden olan Googlenet, Inceptionv3, Alexnet, Densenet201, VGG16, Resnet50, Darknet53 ve önerilen hibrit model kullanılmıştır. Ayrıca elde edilen karışıklık matrisleri kullanılarak modellerin başarı oranları hesaplanmıştır.

5.4. Uygulama

Uygulamada literatürde kabul gören 7 tane ESA modeli ve geliştirilen hibrit model kullanılarak beyin tümörü MRI veri setinden sonuçlar alınmıştır. Kullanılan veri seti halka açık bir veri setidir. Uygulamada kullanılan veri setinde ki görüntülerin %80'ni eğitim için kullanılırken, geriye kalan %20'lik görüntüler ise test için kullanılmıştır.


Geliştirilen modelde ve diğer ESA mimarilerinin eğitim sürecinde Tablo 5.1'de verilen parametreler kullanılmıştır.

Tablo 5.1.Çalışmada kullanılan parametre değerleri

Solver Name	MiniBatch Size	MaxEpochs	Learning Rate	Shuffle	Validation Frequency	Total Adım
Sgdm	16	5	1.0000e-04	every-epoch	3	160

Googlenet

Beyin MRI veri setinde bulunan görüntüleri sınıflandırmak için kullanılan ilk model önceden eğitilmiş olan Googlenet'tir. Googlenet modeli 2014 yılında ILSVRC Imagenet yarışmasının kazananıdır. Googlenet modeli ve çalışmada kullanılan diğer modeller toplam 165 adım çalışmıştır. Googlenet mimarisinin doğruluk ve kayıp eğrisi Şekil 5.4'te verilmiştir.



Şekil 5.4. GoogLeNet mimarisinin doğruluk ve kayıp eğrisi

GoogLeNet modeli ile %71.64 ortalama doğruluk değeri elde edilmiştir. GoogLeNet modelinin karışıklık matrisi Tablo 5.2'de verilmiştir.

Tablo 5.2. GoogLeNet modelinin karışıklık matrisi

		Tümörsüz	Tümörlü
Doğru Sınıf	Tümörsüz	35	1
	Tümörlü	18	13
		Tahmin Edilen Sınıf	

GoogLeNet modelinde elde edilen Tablo 5.2'deki karışıklık matrisi incelendiğinde;

GoogLeNet modeli 36 tane tümör görüntüsü olmayan test görüntülerinden 35 tanesini tümörsüz olarak doğru tahmin ederken, 1 tanesini tümörlü olarak yanlış tahmin etmiştir. 31 tane tümörlü test görüntüsünden 13 tanesini tümörlü olarak doğru tahmin ederken, 18 tanesini tümörsüz olarak yanlış tahmin etmiştir. GoogLeNet modelinin performans metrikleri Tablo 5.3'te verilmiştir.


Tablo 5.3. GoogLeNet modelinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.0714	0.0278	0.3396	66.03%	66.03%	92.85%	71.64%

GoogLeNet modeli test için kullanılan 67 görüntünün 48 tanesini doğru tahmin ederken, 19 tanesini yanlış tahmin etmiştir. Modelin doğruluk değeri %71.64 olmuştur.

InceptionV3

Beyin MR görüntülerinin sınıflandırılmasında kullanılan InceptionV3 modeli eğitildikten sonra elde edilen doğruluk ve kayıp eğrisi Şekil 5.5'te verilmiştir.



Şekil 5.5. InceptionV3 modelinin doğruluk ve kayıp eğrisi

InceptionV3 modeli ile %88.06 ortalama doğruluk değeri elde edilmiştir. InceptionV3 modelinin karışıklık matrisi Tablo 5.4'te verilmiştir.

Tablo 5.4. InceptionV3 modelinin karışıklık matrisi

		Tümörsüz	Tümörlü
Doğru Sınıf	Tümörsüz	36	
	Tümörlü	8	23
		Tahmin Edilen Sınıf	

InceptionV3 modeli 36 tane tümörsüz test görüntüsünün hepsini tümörsüz olarak doğru tahmin etmiştir. 31 tane tümörlü test görüntüsünden 23 tanesini tümörlü olarak doğru tahmin ederken, 8 tanesini tümörsüz olarak yanlış tahmin etmiştir. InceptionV3 modelinin performans metrikleri Tablo 5.5'te verilmiştir.


Tablo 5.5. InceptionV3 modelinin performans ölçütleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0	0	0.1818	89.99%	81.81%	100%	88.06%

InceptionV3 modeli test için kullanılan 67 görüntünün 59 tanesini doğru tahmin ederken, 8 tanesini yanlış tahmin etmiştir. Modelin doğruluk değeri %88.06 olmuştur. InceptionV3 modelinde %100'lük bir özgünlük değeri elde edilmiştir.

Alexnet

Beyin MR görüntülerinden oluşan veri seti ESA modellerinden olan Alexnet kullanılarak sınıflandırılmıştır. Alexnet modeli ile elde edilen doğruluk ve kayıp eğrisi Şekil 5.6'da verilmiştir.



Şekil 5.6. Alexnet modelinin doğruluk ve kayıp eğrisi

Alexnet modeli ile %89.55 ortalama doğruluk değeri elde edilmiştir. Alexnet modelinin karışıklık matrisi Tablo 5.6'da verilmiştir.

Tablo 5.6. Alexnet mimarisinin karışıklık matrisi

		Tümörsüz	Tümörlü
Doğru Sınıf	Tümörsüz	34	2
	Tümörlü	5	26
		Tahmin Edilen Sınıf	

Alexnet modelinde elde edilen tablo 5.6'daki karışıklık matrisi incelendiğinde;

Alexnet modeli 36 tane tümörsüz test görüntüsünden 34 tanesini tümörsüz olarak doğru tahmin ederken, 2 tanesini tümörlü olarak yanlış tahmin etmiştir. 31 tane tümörlü test görüntüsünden 26 tanesini tümörlü olarak doğru tahmin ederken, 5 tanesini tümörsüz olarak yanlış tahmin etmiştir. Alexnet modelinin performans metrikleri Tablo 5.7'de verilmiştir.


Tablo 5.7. Alexnet mimarisinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.0714	0.0556	0.1282	90.05%	87.17%	92.85%	89.55%

Alexnet modeli test için kullanılan 67 görüntünün 60 tanesini doğru tahmin ederken, 7 tanesini yanlış tahmin etmiştir. Modelin doğruluk değeri %89.55 olmuştur.

Densenet201

Beyin MRI veri setinde bulunan görüntüleri sınıflandırmak için kullanılan bir başka model Densenet201 modelidir. Densenet201 modelinin doğruluk ve kayıp eğrisi Şekil 5.7'de verilmiştir.



Şekil 5.7. Densenet201 modelinin doğruluk ve kayıp eğrisi

Densenet201 modeli ile %91.04 ortalama doğruluk değeri elde edilmiştir. Densenet201 modelinin karışıklık matrisi Tablo 5.8'de verilmiştir.

Tablo 5.8. Densenet201 modelinin karışıklık matrisi

		Tümörsüz	Tümörlü
Doğru Sınıf	Tümörsüz	36	
	Tümörlü	6	25
		Tahmin Edilen Sınıf	

Densenet201 modelinde elde edilen Tablo 5.8'deki karışıklık matrisi incelendiğinde;

Densenet201 modeli 36 tane tümörsüz test görüntüsünün hepsini tümörsüz görüntü diye doğru tahmin etmiştir. Aynı model 31 tane tümörlü test görüntüsünden 25 tanesini tümörlü görüntü diye doğru tahmin ederken, 6 tanesini tümörsüz diye yanlış tahmin etmiştir. Densenet201 modelinin performans metrikleri Tablo 5.9'da verilmiştir.


Tablo 5.9. Densenet201 modelinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0	0	0.1429	92.30%	85.71%	100%	91.04%

Densenet201 modeli test için kullanılan 67 görüntünün 61 tanesini doğru tahmin ederken, 6 tanesini yanlış tahmin etmiştir. Modelin doğruluk değeri %91.04 olmuştur. Model tümörsüz görüntüleri sınıflandırmada daha başarılı olmuştur. Modelin tümörsüz görüntüleri sınıflandırmadaki doğruluk oranı %100'dür.

VGG16

Beyin MR görüntülerinden oluşan veri seti önceden eğitilmiş ESA modellerinden biri olan Vgg16 modeli kullanılarak da sınıflandırılmıştır. Vgg modeli 2014 yılında ILSVCR Imagenet yarışmasında büyük bir başarı elde etmiştir. Alexnet modelinden sonra önerilen bu model giriş, aktivasyon, sınıflandırma katmanları da dâhil olmak üzere toplamda 41 katmandan oluşmaktadır. Vgg16 modeli ile beyin MR görüntülerinden oluşan veri setinde ki görüntüler tümörlü ve tümörsüz olmak üzere 2 başlık altında sınıflandırılmıştır. Vgg16 modeli ile elde edilen doğruluk ve kayıp eğrisi Şekil 5.8'de verilmiştir.



Şekil 5.8. Vgg16 modelinin doğruluk ve kayıp eğrileri

Vgg16 modeli ile %91.04 ortalama doğruluk değeri elde edilmiştir. Vgg16 modelinin karışıklık matrisi Tablo 5.10'da verilmiştir.

Tablo 5.10. Vgg16 modelinin karışıklık matrisi

		Tümörsüz	Tümörlü
Doğru Sınıf	Tümörsüz	32	4
	Tümörlü	2	29
		Tahmin Edilen Sınıf	

Vgg16 modelinde elde edilen Tablo 5.10'daki karışıklık matrisi incelendiğinde;

Vgg16 modeli 36 tane tümörsüz test görüntüsünün 32 tanesini tümörsüz görüntü olarak doğru tahmin ederken, 4 tanesini tümörlü olarak yanlış tahmin etmiştir. Vgg16 modeli 31 tane tümörlü test görüntüsünden 29 tanesini tümörlü olarak doğru tahmin ederken, 2 tanesini tümörsüz olarak yanlış tahmin etmiştir. Vgg16 modelinin performans metrikleri Tablo 5.11'de verilmiştir.


Tablo 5.11. Vgg16 modelinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.1212	0.1111	0.0588	91.43%	94.12%	87.88%	91.04%

Vgg16 modeli toplamda test için kullanılan 67 tane test görüntüsünden 61 tanesini doğru sınıflandırırken, 6 tanesini ise yanlış sınıflandırmıştır. Modelin doğruluk değeri %91.04 olmuştur.

Resnet50

Beyin MRI veri setinde bulunan görüntüler önerilen modelde taban olarak da kullanılan Resnet50 modeli ile sınıflandırılmıştır. Resnet modeli 2015 yılında yapılan ILSVRC ImageNet yarışmasının kazananıdır. Bu model kendisinden önce önerilen modellerden daha derin bir yapıya sahiptir. Resnet50 modeli kullanılarak Beyin MRI veri setinde elde edilen doğruluk ve kayıp eğrisi Şekil 5.9’da verilmiştir.



Şekil 5.9. Resnet50 modelinin doğruluk ve kayıp eğrisi

Resnet50 modeli ile %92.54 ortalama doğruluk değeri elde edilmiştir. Resnet50 modelinin karışıklık matrisi Tablo 5.12’de verilmiştir.

Tablo 5.12. Resnet50 modelinin karışıklık matrisi

		Tümörsüz	Tümörlü
Doğru Sınıf	Tümörsüz	35	1
	Tümörlü	4	27
		Tahmin Edilen Sınıf	

Resnet50 modelinde elde edilen Tablo 5.12’deki karışıklık matrisi incelendiğinde;

Resnet50 modeli 36 tane tümörsüz test görüntüsünden 35 tanesini tümörsüz olarak doğru sınıflandırırken, 1 görüntüyü ise yanlış tahmin edip tümörlü sınıfına dâhil etmiştir. 31 tane tümörlü test görüntüsünden 27 tanesini tümörlü olarak doğru tahmin ederken, 4 tanesini tümörsüz olarak yanlış tahmin etmiştir. Resnet50 modelinin performans metrikleri Tablo 5.13’te verilmiştir.


Tablo 5.13. Resnet50 modelinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.0357	0.0278	0.1026	93.33%	89.74%	96.4%	92.54%

Resnet50 modeli test için kullanılan 67 görüntünün 62 tanesini doğru tahmin ederken, 5 tanesini yanlış tahmin etmiştir. Modelin doğruluk değeri %92.54 olmuştur.

Darknet53

Beyin MRI veri setinde bulunan Darknet53 modeli ile sınıflandırıldığında elde edilen doğruluk ve kayıp eğrisi Şekil 5.10'da verilmiştir.



Şekil 5.10. Darknet53 modelinin doğruluk ve kayıp eğrisi

Darknet53 modeli ile %94.03 ortalama doğruluk değeri elde edilmiştir. Darknet53 modelinin karışıklık matrisi Tablo 5.14'te verilmiştir.

Tablo 5.14. Darknet53 modelinin karışıklık matrisi

		Tümörsüz	Tümörlü
Doğru Sınıf	Tümörsüz	36	
	Tümörlü	4	27
		Tahmin Edilen Sınıf	

Darknet53 modelinde elde edilen Tablo 5.14'teki karışıklık matrisi incelendiğinde;

Darknet53 modeli 36 tane tümörsüz test görüntüsünün tamamını tümörsüz olarak doğru tahmin etmiştir. Darknet53 modeli 31 tane tümörlü test görüntüsünden 27 tanesini tümörlü olarak doğru tahmin ederken, 4 tanesini tümörsüz olarak yanlış tahmin etmiştir. Darknet53 modelinin performans metrikleri Tablo 5.15'te verilmiştir.


Tablo 5.15. Darknet53 modelinin performans metrikleri

FPR	FDR	FNR	F1 Score	Sensitivity	Specificity	Accuracy
0	0	0.1000	94.74%	90%	100%	94.03%

Darknet53 modeli test için kullanılan 67 görüntünün 63 tanesini doğru tahmin ederken, 4 tanesini yanlış tahmin etmiştir. Modelin doğruluk değeri %94.03 olmuştur. Darknet53 modeli ile çalışmada kullanılan önceden eğitilmiş ESA modelleri içerisinde en yüksek doğruluk değeri elde edilmiştir.

Önerilen Hibrit Yöntem

Önerilen hibrit yöntemde Resnet50 modeli taban olarak kullanılmıştır. Resnet50 modeli 2015 yılında yapılan ILSVRC ImageNet yarışmasının kazananıdır. Bu modelin belirli katmanları kullanılarak, hibrit bir yapı elde edilmiştir. Önerilen modelle elde edilen doğruluk ve kayıp eğrileri Şekil 5.11'de verilmiştir.



Şekil 5.11. Önerilen hibrit modelin doğruluk ve kayıp eğrisi

Önerilen model ile %97.01 ortalama doğruluk değeri elde edilmiştir. Önerilen hibrit modelinin karışıklık matrisi Tablo 5.16'da verilmiştir.

Tablo 5.16. Önerilen modelin karışıklık matrisi

		Tümörsüz	Tümörlü
		Tümörsüz	Tümörlü
Doğru Sınıf	Tümörsüz	36	
	Tümörlü	2	29
		Tahmin Edilen Sınıf	

Önerilen modelde elde edilen Tablo 5.16'daki karışıklık matrisi incelendiğinde;

Önerilen model ile 36 tane tümörsüz test görüntüsünün tamamı tümörsüz olarak doğru tahmin edilmiştir. Önerilen model ile 31 tane tümörlü test görüntüsünden 29 tanesi tümörlü olarak doğru tahmin edilirken, 2 tanesi tümörsüz olarak yanlış tahmin edilmiştir.

Önerilen modelin performans metrikleri Tablo 5.17'de verilmiştir.

Tablo 5.17. Önerilen modelin performans metrikleri

FPR	FDR	FNR	F1 Score	Sensitivity	Specificity	Accuracy
0	0	0.0526	96.90%	94.7%	100%	97.01%

Önerilen model test için kullanılan 67 görüntünün 65 tanesini doğru tahmin ederken, 2 tanesini yanlış tahmin etmiştir. Model tümörsüz görüntülerde %100 doğruluk elde ederken, tümörlü görüntülerde %93.54 doğruluk değeri elde etmiştir. Modelin doğruluk değeri %97.01 olmuştur. Önerilen model çalışmada kullanılan diğer ESA mimarileriyle karşılaştırıldığına en yüksek değer önerilen modelde elde edilmiştir.

5.5. Sonuçlar ve Tartışma

Beyin tümörleri nadir görülmekle birlikte morbidite ve mortalitesi yüksek hastalıklardır [144]. Beyin dokusundaki nöroglial hücrelerden, damarlardan, sinirlerden ve beyni çevreleyen zarlardan kaynaklanabilirler. Bu tümörler iyi huylu veya kötü huylu olabilmektedirler. Direk beyin dokusundan kaynaklandıkları gibi vücudun farklı bir yerindeki tümörden beyine yayılım sonucu da görülebilirler [145]. Tanıda başlıca görüntüleme yöntemleri BT ve MRG'dir. BT'de radyasyon riski olması ve beyin parankimini MRG kadar yüksek çözünürlük ile gösterememesi nedeni ile daha az tercih edilmektedir [146]. MR görüntüleme yumuşak doku çözünürlüğü yüksek olduğu için beyin normal anatomisinin değerlendirilmesini sağlar. Bunun yanında beyin içerisinde yer

kaplayan patolojilerin tanısında da son derece önemlidir. Son yıllarda MR spektroskopisi ve perfüzyon MR gibi ileri MR teknikleri ile beyin tümörlerinin tanı ve sınıflandırılmasında önemli gelişmeler kaydedilmiştir. Son yıllarda beyin tümörlerinin sıklığında özellikle benin olanlarda artış olduğu belirtilmektedir. Bunun tanı tekniklerindeki gelişmelerden kaynaklandığı düşünülmektedir [147, 148]. Bu çalışmada, MR görüntülerinde beyin tümörünün olup olmadığının önerilen yöntemle sınıflandırılması amaçlanmıştır. Kullanılan veri seti 2 sınıftan oluşmaktadır. Önerilen yöntem ile % 97.01 oranında doğruluk değeri elde edilmiştir. Önerilen modelde Resnet50 mimarisi taban olarak kullanılmıştır. Çalışmada literatürde sıklıkla kullanılan ESA mimarileriyle de sonuçlar alınmıştır. Bu sonuçlar Tablo 5.18’de verilmiştir.

Tablo 5.18. Çalışmada kullanılan modellerin doğruluk değerleri

Alexnet	Densenet201	InceptionV3	Resnet50	Googlenet	Vgg16	Darknet53	Önerilen Yöntem
%89.55	%91.04	%88.06	%92.54	%71.64	%91.04	%94.03	%97.01

Tablo 5.18’de de görüldüğü gibi önerilen model çalışmada kullanılan önceden eğitilmiş ESA modellerinden daha iyi sonuç elde etmiştir.

6. GÖĞÜS X-RAY GÖRÜNTÜLERİNİN DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK SINIFLANDIRILMASI

Zatürre, başta bakteriler olmak üzere çeşitli yollarla bulaşan, akciğer dokusunun iltihaplanmasının neden olduğu ölümcül bir hastalık türüdür. Bu hastalık her yıl birçok insanı etkilemektedir. Zatürre olan bu hastaların bir kısmı tedavi edilemez ve hastalık ölümle sonuçlanır. Zatürre, genellikle akciğer röntgeni ile tespit edilen zor bir hastalıktır. Bu nedenle röntgen cihazından elde edilen zatürre görüntülerinin bilgisayar sistemleri tarafından hızlı ve doğru bir şekilde sınıflandırılması büyük önem taşımaktadır. Çünkü çoğu sağlık biriminde bu işlemi yapacak nitelikli personel bulunmayabilir veya geleneksel yöntemlerle konulan tanılarda hata oranı daha yüksektir. Röntgen görüntüleri sınıflandırdıktan sonra, hastalığın teşhis edilmesi daha kolay olacaktır. Hastalıkların teşhisinde bilgisayar sistemlerinin kullanılması, hem uzmanların iş yükünü hafifletecektir hem de uzman olmayan yerlerde ön teşhis işlemi için kullanılabilir [119, 149]. Bu çalışmada, Resnet50 modelinin katmanlarını temel olarak kullanılıp yeni bir model geliştirilmiştir. Geliştirilen model literatürde yapılmış benzer çalışmalar ve önceden eğitilmiş Alexnet, Googlenet, Resnet50 ve Densenet201 modelleri ile karşılaştırılmıştır. Geliştirilmiş modelde %97.22 doğruluk değeri elde edilmiştir.

6.1. Literatür Taraması

Stephen ve arkadaşları [150] yaptıkları çalışmada zatürre görüntülerini sınıflandırmak için yeni bir model önerdiklerini belirtmişlerdir. Önerdikleri modelin iki önemli kısımdan oluştuğunu ifade etmişlerdir. Modellerinin ilk kısmında özellik çıkarım, ikinci kısımda ise sigmoid aktivasyon fonksiyonu kullanılarak sınıflandırma yapıldığı belirtilmiştir. Bu çalışmada kullandıkları model CNN tabanlı bir modeldir. Ayrıca veri sayılarının az olmasından dolayı veri artırımı yaptıkları ve elde ettikleri doğruluk oranının ortalama %94.81 olduğu görülmüştür.

Garcia ve arkadaşları [151] yaptıkları çalışmada zatürre X-Ray görüntülerini sınıflandırmak için önceden eğitilmiş Xception ağını kullandıklarını belirtmişlerdir. Kullandıkları veri setinin 1 ile 5 yaş arasında ki çocukların X-Ray görüntülerinden oluştuğunu ve toplamda 5232 görüntü ile çalıştıklarını ifade etmişlerdir. Yaptıkları çalışmada %91 F1-score değeri elde etmişlerdir. Önerdikleri bu modeli çalışmalarında diğer ESA modelleriyle karşılaştırmışlardır.

Chouhan ve arkadaşları [152] yaptıkları bu çalışmada göğüs X-Ray görüntülerini sınıflandırmak için önceden eğitilmiş Alexnet, Densenet121, InceptionV3, Resnet18 ve Googlenet mimarilerini kullanmışlardır. Veri setindeki göğüs X-Ray görüntülerinin özelliklerini önceden eğitilmiş bu ESA modelleri kullanarak elde etmişlerdir. Bu çalışmada modellerin performansını

artırabilmek için veri önışleme ve veri çoğullama yapıldığı belirtilmiştir. Önceden eğitilmiş ESA mimarileri kullanılarak önerilen modelde %96.4 doğruluk değeri elde etmişlerdir.


Saraiva ve arkadaşları [153] yaptıkları çalışmada göğüs X-Ray görüntülerini sınıflandırmak için iki farklı yöntem kullanmışlardır. Çok katmanlı algılayıcı ve önerdikleri ESA yöntemi bu çalışmalarında kullandıkları yöntemlerdir. Bu çalışmada veri seti eğitim ve doğrulama için hazırlanırken çapraz doğrulama tercih edilmiştir. Bu aşamada çapraz doğrulama değeri 5 seçildiğinden, bu işlem 5 defa tekrarlanmıştır. Yapılan bu çalışmada veri önışleme adımlarının uygulandığı belirtilmiştir. Çok katmanlı algılayıcı kullanarak elde ettikleri doğruluk oranının %92.16 olduğunu ayrıca kullanmış oldukları ESA mimarilerinde ise bu doğruluk oranının %94.40 olduğunu ifade etmişlerdir.

Jain ve arkadaşları [154] yapmış oldukları çalışmada her yıl dünya çapında çok sayıda çocuğun zatürre nedeniyle öldüğünü belirtmişlerdir. Zatürrenin erken teşhisinin çocuklar arasındaki ölüm oranlarını önemli ölçüde azaltabileceğini ifade etmişlerdir. Bundan dolayı göğüs X-Ray görüntülerini sınıflandırmak için yapmış oldukları çalışmalarında iki sınıflı bir veri seti kullanmışlardır. Burada önceden eğitilmiş ESA mimarileri ve önerdikleri 2 yeni model ile sonuçlar elde etmişlerdir. Çalışmalarında kullanmış oldukları altı model içerisinde en yüksek doğruluk değerlerinin %92.31 olduğu görülmüştür.

Siddiqi ve arkadaşları [155] yapmış olduğu çalışmada zatürrenin otomatik teşhis edilmesine yönelik bir çalışma gerçekleştirdiklerini belirtmişlerdir. Yapılan çalışmada kullanılan veri seti 2 sınıftan oluşmaktadır. Zatürre görüntülerini sınıflandırabilmek için 18 katmandan oluşan yeni bir model önermişlerdir. Modelin eğitimi için 5856 X-Ray görüntüsü kullanmışlardır. Önerdikleri modelin doğruluk oranı %94.39 olmuştur. Yapılan bu çalışmada yazarlar verilere önışleme yapılması ve verilerin veri çoğullama teknikleri ile artırılması halinde modelin başarı oranının artacağını belirtmişlerdir.

6.2. Veri Seti

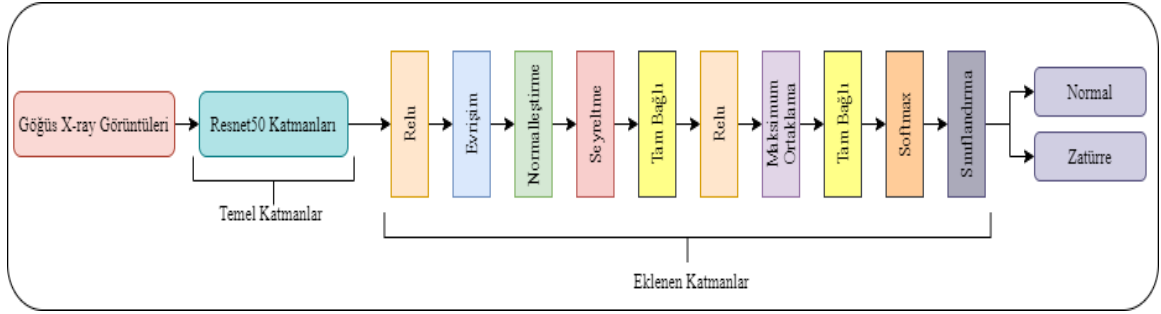
Zatürre ve normal olmak üzere iki sınıftan oluşan görüntü veri seti Kaggle'nin web sitesinden alınmıştır [156]. Çalışmada 3872 zatürre görüntüsü ve 1341 normal görüntü kullanılmıştır. Veri seti göğüs X-Ray görüntüleri kullanılarak oluşturulmuştur. Veri setinde kullanılan göğüs X-Ray görüntü örnekleri Şekil 6.1'de verilmiştir.



Şekil 6.1. Kullanılan veri setinden X-Ray görüntü örnekleri

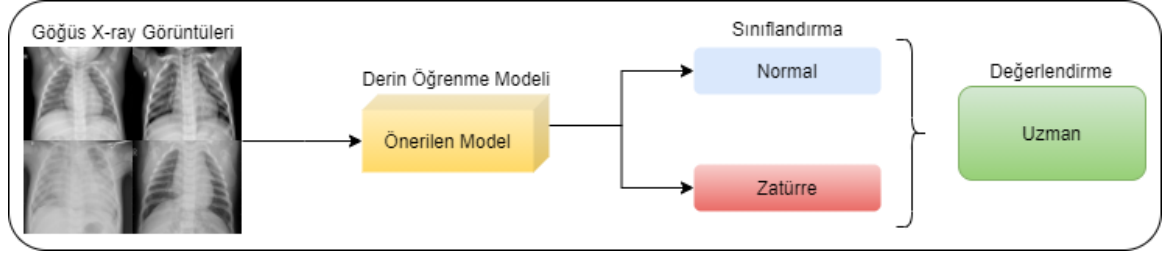
6.3. Materyal ve Yöntem

Yapılan çalışmada X-Ray görüntülerinden oluşan veri seti kullanılarak, görüntülerin normal ve zatürre olarak sınıflandırılması amaçlanmıştır. Bu veri setinde ki göğüs X-Ray görüntüleri mevcut ESA modelleri kullanılarak sınıflandırıldıktan sonra, aynı veri seti önerilen model ile sınıflandırılmıştır. Önerilen modelde, Resnet50 modeli temel olarak kullanılmıştır. Resnet50 modelinin temel olarak kullanılmasının sebebi, ilgili modelin birikiminden faydalanılmak istenmesidir. Önerilen modelde Resnet50 modelinin son 5 katmanı çıkartılarak, yerine 10 yeni katman eklenmiştir. Eklenen katmanlar sırasıyla Relu, evrişim, normalleştirme, seyreltme, tam bağlı, Relu, Maksimum Ortaklama, Tam Bağlı, Softmax ve Sınıflandırma şeklindedir. Ayrıca çalışmada giriş katmanı ve onu takip eden evrişim katmanları da güncellenmiştir. Geliştirilen modelin yapısı Şekil 6.2'de verilmiştir.



Şekil 6.2. Önerilen hibrit modelin katman yapısı

Önerilen modelin kabaca gösterimi Şekil 6.3'te verilmiştir.



Şekil 6.3. Önerilen modelin kaba gösterimi

Önerilen model ile %97.22 oranında bir doğruluk değeri elde edilmiştir. Önerilen model uzmanlara yardımcı olmak için kullanılabilir. Bilgisayar destekli sistemler sayesinde uzmanların iş yükü hafifleyebilmektedir. Ayrıca önerilen model uzman olmayan birimlerde ön teşhis işlemi içinde kullanılabilir.

Uygulama bölümünde zatürre X-Ray görüntülerinin sınıflandırılması için Alexnet, Googlenet, Resnet50, Densenet201 ve önerilen model kullanılmıştır.

6.4. Uygulama

Uygulamada literatürde kabul gören 4 tane ESA modeli ve geliştirilen model kullanılarak zatürre ve normal X-Ray görüntülerinin sınıflandırılması amaçlanmıştır. Uygulamada kullanılan veri setinde ki görüntülerin %80'ni eğitim için kullanılırken, geriye kalan %20'lik görüntüler ise test için kullanılmıştır. 5 farklı modelde alınan sonuçların doğruluk ve kayıp eğrileri, karışıklık matrisleri ve performans metrikleri detaylı bir şekilde incelenmiştir.


Geliştirilen modelde ve çalışmada kullanılan diğer ESA mimarilerinde kullanılan eğitim parametreleri Tablo 6.1'de verilmiştir.

Tablo 6.1. Çalışmada kullanılan parametre değerleri

Solver Name	MiniBatch Size	MaxEpochs	Learning Rate	Shuffle	Validation Frequency	Toplam Adım
Sgdm	10	4	1.0000e-04	every-epoch	3	1668

Alexnet

Göğüs X-Ray görüntülerinden oluşan veri seti kullanılarak Alexnet modelinde zatürre ve normal göğüs X-Ray görüntüleri sınıflandırılmıştır. Alexnet modeli ile elde edilen doğruluk ve kayıp eğrisi Şekil 6.4'te verilmiştir.



Şekil 6.4. Alexnet modelinin doğruluk ve kayıp eğrisi

Alexnet modeli ile göğüs X-Ray görüntülerinden oluşan veri seti kullanıldığında %91.07 ortalama doğruluk değeri elde edilmiştir. Alexnet modelinin karışıklık matrisi Tablo 6.2’de verilmiştir.

Tablo 6.2. Alexnet modelinin karışıklık matrisi

		Normal	Zatürre
		Doğru Sınıf	Normal
Zatürre	3		771
		Tahmin Edilen Sınıf	

Alexnet modelinde elde edilen Tablo 6.2’deki karışıklık matrisi incelendiğinde;

Alexnet modeli 268 tane normal (zatürre olmayan) test görüntülerinden 175 tanesini normal diye doğru tahmin ederken, 90 tanesini zatürre var diye yanlış tahmin etmiştir. 774 tane zatürre test görüntüsünden 771 tanesini zatürre diye doğru tahmin ederken, 3 tanesini normal diye yanlış tahmin etmiştir. Alexnet modelinin performans metrikleri Tablo 6.3’te verilmiştir.


Tablo 6.3. Alexnet modelinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.1045	0.3358	0.0166	79.29%	98.34%	89.55%	91.07%

Alexnet modeli test için kullanılan 1042 görüntünün 949 tanesini doğru tahmin ederken, 93 tanesini yanlış tahmin etmiştir. Modelin doğruluk değeri %91.07 olmuştur.

Googlenet

Göğüs X-Ray görüntülerinin sınıflandırıldığı bir başka model Googlenet'tir. Googlenet modelinde elde edilen doğruluk ve kayıp eğrisi Şekil 6.5'te verilmiştir.



Şekil 6.5. Googlenet modelinin doğruluk ve kayıp eğrisi

Googlenet modeli ile göğüs X-Ray görüntülerinden oluşan veri seti kullanıldığında %94.05 oranında doğruluk değeri elde edilmiştir. Googlenet modelinin karışıklık matrisi Tablo 6.4'te verilmiştir.

Tablo 6.4. Googlenet modelinin karışıklık matrisi

		Normal	Zatürre
Doğru Sınıf	Normal	244	24
	Zatürre	38	736
		Tahmin Edilen Sınıf	

Googlenet mimarisinde elde edilen Tablo 6.4'teki karışıklık matrisi incelendiğinde;

Googlenet modelinin 268 tane normal test görüntülerinden 244 tanesini normal diye doğru tahmin ederken, 24 tanesini zatürre var diye yanlış tahmin etmiştir. Googlenet modeli 774 tane

zatürre test görüntüsünden 736 tanesini zatürre diye doğru tahmin ederken, 38 tanesini normal diye yanlış tahmin etmiştir. Googlenet modelinin performans metrikleri Tablo 6.5’te verilmiştir.


Tablo 6.5. Googlenet modelinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.0316	0.0896	0.1348	88.73%	86.52%	96.84%	94.05%

Googlenet modeli test için kullanılan 1042 görüntünün 960 tanesini doğru tahmin ederken, 82 tanesini yanlış tahmin etmiştir. Modelin doğruluk değeri %94.05 olmuştur.

Resnet50

2015 yılında yapılan ILSVRC ImageNet yarışmasının kazananı olan Resnet50 modeli ile göğüs X-Ray görüntülerinden oluşan veri setindeki görüntüler sınıflandırılmıştır. Resnet50 modelinin doğruluk ve kayıp eğrisi Şekil 6.6’da verilmiştir.



Şekil 6.6. Resnet50 modelinin doğruluk ve kayıp eğrisi

Resnet50 modeli ile göğüs X-Ray görüntülerinden oluşan veri setindeki görüntüler sınıflandırıldığında doğruluk değeri %96.35 olmuştur. Resnet50 modelinin karışıklık matrisi Tablo 6.6'da verilmiştir.

Tablo 6.6. Resnet50 modelinin karışıklık matrisi

		Normal	Zatürre
		Normal	Zatürre
Doğru Sınıf	Normal	249	19
	Zatürre	19	755
		Tahmin Edilen Sınıf	

Resnet50 modelinde elde edilen Tablo 6.6'daki karışıklık matrisi incelendiğinde;

Resnet50 modeli 268 tane normal test görüntülerinden 249 tanesini normal diye doğru tahmin ederken, 19 tanesini zatürre var diye yanlış tahmin etmiştir. Resnet50 modeli 774 tane zatürre test görüntüsünden 755 tanesini zatürre diye doğru tahmin ederken, 19 tanesini normal diye yanlış tahmin etmiştir. Resnet50 modelinin performans metrikleri Tablo 6.7'de verilmiştir.


Tablo 6.7. Resnet50 modelinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.0245	0.0709	0.0709	92.91%	92.91%	97.55%	96.35%

Resnet50 modelinde test için kullanılan 1042 görüntünün 1004 tanesi doğru tahmin edilirken, 38 tanesi yanlış tahmin edilmiştir. Modelin doğruluk oranı %96.35 olmuştur.

Densenet201

Göğüs X-Ray görüntülerinden oluşan veri seti bir başka ESA modeli olan Densenet201 modeli ile de sınıflandırılmıştır. Bu modelin doğruluk ve kayıp eğrisi Şekil 6.7'de verilmiştir.



Şekil 6.7. Densenet201 modelinin doğruluk ve kayıp eğrisi

Densenet201 modeli ile göğüs X-Ray görüntülerinden oluşan veri setindeki görüntüler sınıflandırıldığında doğruluk değeri %96.83 olmuştur. Densenet201 modelinin karışıklık matrisi Tablo 6.8'de verilmiştir.

Tablo 6.8. Densenet201 modelinin karışıklık matrisi

		Normal	Zatürre
Doğru Sınıf	Normal	247	21
	Zatürre	12	762
		Tahmin Edilen Sınıf	

Densenet201 modelinde elde edilen Tablo 6.8'deki karışıklık matrisi incelendiğinde;

Densenet201 modeli 268 tane normal test görüntülerinden 247 tanesini normal diye doğru tahmin ederken, 21 tanesini zatürre var diye yanlış tahmin etmiştir. Densenet201 modeli 774 tane zatürre test görüntüsünden 762 tanesini zatürre diye doğru tahmin ederken, 12 tanesini normal diye yanlış tahmin etmiştir. Densenet201 modelinin performans metrikleri Tablo 6.9'da verilmiştir.


Tablo 6.9. Densenet201 modelinin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.0268	0.0784	0.0463	93.74%	95.37%	97.32%	96.83%

Densenet201 modelinde test için kullanılan 1042 görüntünün 1009 tanesi doğru tahmin edilirken, 33 tanesi yanlış tahmin edilmiştir. Modelin doğruluk oranı %96.83 olmuştur.

Önerilen Model

Resnet50 modeli temel olarak alınıp, beyin tümörü görüntülerine uygulanan hibrit yöntem göğüs X-Ray görüntülerinde de kullanılmıştır. Önerilen modelde Resnet50 modelinin son 5 katmanı çıkartılıp, bunların yerine 10 yeni katman eklenmiştir. Ayrıca önerilen modelde giriş katmanı ve bunu takip eden evrişim katmanı da güncellenmiştir. Önerilen bu yöntem ile göğüs X-Ray veri setinde de başarılı sonuçlar elde edilmiştir. Önerilen bu model ile göğüs X-Ray görüntülerin zatürre görüntüsü mü yoksa normal görüntü mü olduğu tespit edilmiştir. Yapılan bu sınıflandırma işlemi uzmanların iş yükünü hafifletip, zaman ve maliyeti düşürecektir. Önerilen model ayrıca teşhis süresini kısaltıp, tedaviye daha erken başlanmasına imkân tanıyacaktır. Kullanılan veri seti normal ve zatürre görüntülerinden oluşmaktadır. Önerilen modelle elde edilen doğruluk ve kayıp eğrileri Şekil 6.8'de verilmiştir.



Şekil 6.8. Önerilen modelin doğruluk ve kayıp eğrisi

Önerilen model ile göğüs X-Ray görüntülerinden oluşan veri setindeki görüntüler sınıflandırıldığında doğruluk değeri %97.22 olmuştur. Önerilen modelinin karışıklık matrisi Tablo 6.10'da verilmiştir.

Tablo 6.10. Önerilen modelin karışıklık matrisi

		Normal	Zatürre
Doğru Sınıf	Normal	250	18
	Zatürre	11	763
		Tahmin Edilen Sınıf	

Önerilen modelde elde edilen Tablo 6.10'daki karışıklık matrisi incelendiğinde;

Önerilen model 268 tane normal test görüntülerinden 250 tanesini normal diye doğru tahmin ederken, 18 tanesini zatürre var diye yanlış tahmin etmiştir. Önerilen model 774 tane zatürre test görüntüsünden 763 tanesini zatürre diye doğru tahmin ederken, 11 tanesini normal diye yanlış tahmin etmiştir. Önerilen modelin performans metrikleri Tablo 6.11'de verilmiştir.

Tablo 6.11. Önerilen modelin performans metrikleri

FPR	FDR	FNR	F1	Duyarlılık	Özgünlük	Doğruluk
0.0230	0.0672	0.0421	94.52%	95.79%	97.70%	97.22%

Önerilen modelde test için kullanılan 1042 görüntünün 1013 tanesi doğru tahmin edilirken, 29 tanesi yanlış tahmin edilmiştir. Modelin doğruluk değeri %97.22 olmuştur.

6.5. Sonuçlar ve Tartışma

Zatürre, akciğer parankiminin iltihaplanması ve enfeksiyonudur[157]. Zatürre, 60 yaşın üzerindeki bireylerde enfeksiyonlardan kaynaklanan en yaygın ölüm nedenidir. İlerleyen yaşlarda görülme sıklığı artar. Etiyolojisinde başlıca bakteri, virüs ve mantar gibi enfeksiyon etkenleri bulunmaktadır. Zatürre hastalarında ateş, öksürük, nefes darlığı ve taşipne gibi belirtiler görülür. Zatürre, ciddi morbidite ve mortaliteden sorumlu en önemli bulaşıcı hastalıklardan biridir. Radyolojik görüntüleme yöntemleri zatürre hastalarının değerlendirilmesinde önemli bir yere sahiptir. Göğüs röntgeni kolay ulaşılabilirliği ve ucuzluğu nedeniyle zatürre teşhisinde en sık kullanılan görüntüleme yöntemidir [158, 159].

Son yıllarda derin öğrenme yöntemlerinin klinik ve radyolojide kullanımı hızla artmıştır. Bu çalışmada, derin öğrenme mimarilerini kullanarak x-ışını görüntülerinde zatürre hastalığını tespit etmek amaçlanmıştır. Resnet50 modeli temel olarak kullanılıp, yeni bir hibrit model önerilmiştir. Önerilen model ile birlikte veriler Densenet201 modeli, Resnet50 modeli, Googlenet modeli ve Alexnet modeli ile sınıflandırılmıştır. Geliştirilen modelde % 97,22 doğruluk değeri ile en yüksek doğruluk değeri elde edilmiştir. Çalışmada kullanılan modellerde elde edilen doğruluk değerleri Tablo 6.12’de verilmiştir.

Tablo 6.12. Çalışmada kullanılan modellerin doğruluk oranları

Densenet201	Resnet50	Googlenet	Alexnet	Önerilen Yöntem
%96.83	%96.35	%94.05	%91.07	%97.22

Yapılan çalışmada kullanılan modeller arasında en yüksek doğruluk değeri önerilen modelde elde edilmiştir. Bu oran %97.22’dir. Önerilen model ile zatürre görüntüleri sınıflandırıldıktan sonra uzmanların hastalıkla ilgili çıkarımlar yapması daha kolay olacaktır. Derin öğrenme çalışmalarda kullanılan veri sayısının fazla olması, ağız eğitiminde büyük bir öneme sahiptir. ESA mimarileri büyük miktarda veri kümeleriyle çalıştığından dolayı, bu mimarilerin eğitim aşaması uzun zaman alabilmektedir. Bu eğitim süresini kısaltmak için GPU kartları tercih edilebilir.

7. SONUÇLAR VE TARTIŞMA

Derin öğrenme yöntemleri gelişen teknolojiyle birlikte son yıllarda yaygın bir şekilde kullanılmaktadır. Özellikle veri setlerinde tutulan bilgilerin artması, derin öğrenme mimarilerine olan ihtiyacı daha da artırmıştır. Son yıllarda derin öğrenme mimarilerini çalıştıracak olan makinelerinde güçlerinin artmasından dolayı bu mimariler özellikle sınıflandırma konusunda yaygın bir şekilde kullanılmaktadır. Bu tez çalışmasında da derin öğrenme mimarilerinden olan ESA modelleri üzerinde durulmuştur. Ayrıca insan hareketlerinin sınıflandırılması için yeni bir ESA tabanlı model önerilmiştir. Önerilen model önceden eğitilmiş ESA mimarileriyle karşılaştırılmıştır. Önerilen model önceden eğitilmiş ESA modellerinden daha başarılı sonuçlar elde etmiştir. İnsan hareketlerinin sınıflandırılması özellikle sağlık ve güvenlik başta olmak üzere birçok alanda kullanılmaktadır. Bu hareketlerin sınıflandırılmasıyla hem anlık hem geçmişe dönük hem de geleceğe dönük tespitlerde yapılabilmektedir.

Derin öğrenme mimarileri kullanılarak yapılan bir diğer çalışmada beyin MR görüntülerinin sınıflandırılması amaçlanmıştır. Burada beyin MR görüntüleri tümörlü ve tümörsüz diye sınıflandırılmıştır. Beyin tümörleri her yaş grubunda görülen ölümcül bir hastalık türü olduğundan dolayı beyin tümörlerinin erken teşhis edilmesi önemli bir süreçtir. Erken teşhis sayesinde ölüm oranları minimuma indirgenebilmektedir. Bu çalışmada beyin tümörlerinin derin öğrenme yöntemleriyle tespit edilmesi önemli bir adımdır. Bu sayede uzmanların beyin tümörünü daha erken teşhis etmesi sağlanabilir. Ayrıca bu model sayesinde uzman olmayan yerlerde ön teşhis işlemi gerçekleştirilebilir. Önerilen hibrit yöntemde Resnet50 mimarisi taban olarak kullanılmıştır. Ve önerilen model ile elde edilen başarımlar ölçütleri önceden eğitilmiş ESA mimarileriyle karşılaştırılmıştır. Önerilen hibrit model %97.01 doğruluk oranı ile en yüksek başarımları yakalamıştır.

Göğüs X-Ray görüntüleri kullanılarak yapılan bir diğer çalışmada zatürre görüntülerinin normal görüntülerden ayırt edilmesi amaçlanmıştır. Kullanılan veri seti normal ve zatürre X-Ray görüntülerinden oluşmaktadır. Bu görüntülerin sınıflandırılması için ESA tabanlı hibrit bir model önerilmiştir. Önerilen model de önceden eğitilmiş ESA mimarilerinden olan Resnet50 taban olarak kullanılmıştır. Zatürre akciğer dokusunun iltihaplanmasından kaynaklanan ölümcül bir hastalık olduğundan dolayı, bu görüntülerin hızlı bir şekilde sınıflandırılması hastalığın tedavisi açısından önemlidir. Yapılan çalışmada önerilen model önceden eğitilmiş ESA mimarileri ile kıyaslanmıştır. Çalışmada kullanılan mimariler içerisinde en yüksek doğruluk değeri %97.22 ile önerilen hibrit modelde elde edilmiştir.

Yapılan çalışmalarda da görüleceği üzere, derin öğrenme mimarilerinin insan hayatında büyük bir yer edineceği aşikârdır. Bu mimariler ile insan hareketleri ve insan hastalıkları daha rahat bir şekilde sınıflandırılacak ve buradan anlamlı sonuçların çıkarılması kaçınılmaz olacaktır. Bu

sayede veri tabanlarında tutulan gizli bilgiler işlenip, insanların hizmetine sunulacaktır. Bu tez çalışmasında derin öğrenme mimarileri kullanılarak yapılan çalışmalarda kişilerin özel bilgilerine ihtiyaç duyulmamıştır. Burada amaçlanan veri tabanlarında tutulan verilerle modellerin eğitilmesidir. Hangi verinin kime ait olduğunun bilinip ya da bilinmemesi derin öğrenme mimarilerinin başarımlarını etkilememektedir. Yapılan çalışmalarda elde edilen sonuçlar göstermiştir ki insan hareketlerinin veya hastalıklarının sınıflandırılmasında derin öğrenme mimarilerinin başarılı sonuçlar elde ettiği üzerinedir. Bu verilerin sınıflandırılmasında bu modellerin kullanılabilmesi gözlemlenmiştir.



KAYNAKLAR

- [1] Hulslen, T., Jamuar, S.S., Moody, A.R., Karnes, J.H., Varga, O., Hedensted, S., . . . McKinney, E.F. (2019). From big data to precision medicine. *Frontiers in medicine*, 6, 34.
- [2] Alom, M.Z., Taha, T.M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M.S., . . . Asari, V.K. (2019). A state-of-the-art survey on deep learning theory and architectures. *Electronics*, 8(3), 292.
- [3] Ren, L., Cui, J., Sun, Y., and Cheng, X. (2017). Multi-bearing remaining useful life collaborative prediction: A deep learning approach. *Journal of Manufacturing Systems*, 43, 248-256.
- [4] Kumar, R., Liu, A.P., Orr, B.A., Northcott, P.A., and Robinson, G.W. (2018). Advances in the classification of pediatric brain tumors through DNA methylation profiling: from research tool to frontline diagnostic. *Cancer*, 124(21), 4168-4180.
- [5] Erođlu, Y., Yildirim, M., and Çınar, A. (2021). Convolutional Neural Networks Based classification of breast ultrasonography images by hybrid method with respect to Benign, Malignant, and Normal using mRMR. *Computers in Biology and Medicine*, 104407.
- [6] McAllister, D.A., Liu, L., Shi, T., Chu, Y., Reed, C., Burrows, J., . . . Campbell, H. (2019). Global, regional, and national estimates of pneumonia morbidity and mortality in children younger than 5 years between 2000 and 2015: a systematic analysis. *The Lancet Global Health*, 7(1), e47-e57.
- [7] Mahmud, M.S., Huang, J.Z., Salloum, S., Emara, T.Z., and Sadatdiynov, K. (2020). A survey of data partitioning and sampling methods to support big data analysis. *Big Data Mining and Analytics*, 3(2), 85-101.
- [8] Meng, T., Jing, X., Yan, Z., and Pedrycz, W. (2020). A survey on machine learning for data fusion. *Information Fusion*, 57, 115-129.
- [9] Osarogiagbon, A.U., Khan, F., Venkatesan, R., and Gillard, P. (2020). Review and analysis of supervised machine learning algorithms for hazardous events in drilling operations. *Process Safety and Environmental Protection*.
- [10] Grazzini, F., Craig, G.C., Keil, C., Antolini, G., and Pavan, V. (2020). Extreme precipitation events over northern Italy. Part I: A systematic classification with machine-learning techniques. *Quarterly Journal of the Royal Meteorological Society*, 146(726), 69-85.
- [11] Saleh, M.A. Evaluation of Supervised Machine Learning Classifiers for Detecting Ransomware based on Naïve Bayes, SVM, KNN, C 4.5, and Random Forest Algorithms.
- [12] Iqbal, N., Sang, J., Chen, J., and Xia, X. (2021). Measuring Software Maintainability with Naïve Bayes Classifier. *Entropy*, 23(2), 136.
- [13] Paoletti, M.E., Haut, J.M., Tao, X., Miguel, J.P., and Plaza, A. (2020). A new GPU implementation of support vector machines for fast hyperspectral image classification. *Remote Sensing*, 12(8), 1257.
- [14] Źabiński, G., Gramacki, J., Gramacki, A., Mišta-Jakubowska, E., Birch, T., and Disser, A. (2020). Multi-classifier majority voting analyses in provenance studies on iron artefacts. *Journal of Archaeological Science*, 113, 105055.
- [15] Anowar, F., Sadaoui, S., and Selim, B. (2021). Conceptual and empirical comparison of dimensionality reduction algorithms (PCA, KPCA, LDA, MDS, SVD, LLE, ISOMAP, LE, ICA, t-SNE). *Computer Science Review*, 40, 100378.
- [16] Samuk, D.C. and Nurođlu, F.M. (2021). Seri kapasitör içeren şebekelerde k-en yakın komşuluk (k-eyk) sınıflandırma yöntemi kullanılarak geniş bölge izleme tabanlı yeni bir arızalı hat belirleme algoritması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 871-882.

- [17] Rabin, N., Kahlon, M., Malayev, S., and Ratnovsky, A. (2020). Classification of human hand movements based on EMG signals using nonlinear dimensionality reduction and data fusion techniques. *Expert Systems with Applications*, 149, 113281.
- [18] Elmachtoub, A., Liang, J.C.N., and McNellis, R. (2020). Decision trees for decision-making under the predict-then-optimize framework. Paper presented at the International Conference on Machine Learning.
- [19] Yadav, R.S. (2020). Data analysis of COVID-2019 epidemic using machine learning methods: a case study of India. *International Journal of Information Technology*, 12, 1321-1330.
- [20] Subashini, V., Janaki, R., Valarmathi, G., Suganthi, S., Prabha, R., Sivasankari, K., and Kavitha, S. (2021). Survey on regression analysis of photoplethysmography using machine learning. *Materials Today: Proceedings*.
- [21] Maaouane, M., Zouggar, S., Krajačić, G., and Zahboune, H. (2021). Modelling industry energy demand using multiple linear regression analysis based on consumed quantity of goods. *Energy*, 225, 120270.
- [22] Yu, J., Yang, S., Kim, J., Lee, Y., Lim, K.-T., Kim, S., . . . Jeong, H. (2020). A Confidence Interval-Based Process Optimization Method Using Second-Order Polynomial Regression Analysis. *Processes*, 8(10), 1206.
- [23] Liao, Y., Schwarz, K., Mescheder, L., and Geiger, A. (2020). Towards unsupervised learning of generative models for 3d controllable image synthesis. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.
- [24] Rozemberczki, B., Kiss, O., and Sarkar, R. (2020). An API oriented open-source Python framework for unsupervised learning on graphs. *arXiv preprint arXiv:2003.04819*.
- [25] Kuwil, F.H., Atila, Ü., Abu-Issa, R., and Murtagh, F. (2020). A novel data clustering algorithm based on gravity center methodology. *Expert Systems with Applications*, 156, 113435.
- [26] Suwanda, R., Syahputra, Z., and Zamzami, E. (2020). Analysis of Euclidean Distance and Manhattan Distance in the K-Means Algorithm for Variations Number of Centroid K. Paper presented at the *Journal of Physics: Conference Series*.
- [27] Czumaj, A. and Sohler, C. (2020). Sublinear time approximation of the cost of a metric k-nearest neighbor graph. Paper presented at the Proceedings of the Fourteenth Annual ACM-SIAM Symposium on Discrete Algorithms.
- [28] Praveen, P. and Rama, B. (2020). An Optimized Clustering Method To Create Clusters Efficiently. *Journal Of Mechanics Of Continua And Mathematical Sciences*, 15(1), 339-348.
- [29] Campello, R.J., Kröger, P., Sander, J., and Zimek, A. (2020). Density-based clustering. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(2), e1343.
- [30] Jamil, F., Iqbal, N., Ahmad, S., and Kim, D. (2021). Peer-to-Peer Energy Trading Mechanism based on Blockchain and Machine Learning for Sustainable Electrical Power Supply in Smart Grid. *IEEE Access*, 9, 39193-39217.
- [31] Qiu, Z., Chen, R., and Yan, M. (2020). Monitoring Data Analysis Technology of Smart Grid Based on Cloud Computing. Paper presented at the *IOP Conference Series: Materials Science and Engineering*.
- [32] Schmitt, J., Böning, J., Borggräfe, T., Beiting, G., and Deuse, J. (2020). Predictive model-based quality inspection using Machine Learning and Edge Cloud Computing. *Advanced Engineering Informatics*, 45, 101101.

- [33] Xue, M., Yan, H., Zhang, H., Sun, J., and Lam, H.-K. (2020). Hidden-Markov-Model-Based Asynchronous H-infinity Tracking Control of Fuzzy Markov Jump Systems. *IEEE Transactions on Fuzzy Systems*.
- [34] Bucci, A., Carbonari, L., Gil, P.M., and Trovato, G. (2021). Economic growth and innovation complexity: An empirical estimation of a Hidden Markov Model. *Economic Modelling*, 98, 86-99.
- [35] Wen, F., Zhang, G., Sun, L., Wang, X., and Xu, X. (2019). A hybrid temporal association rules mining method for traffic congestion prediction. *Computers & Industrial Engineering*, 130, 779-787.
- [36] Verma, N. and Singh, J. (2017). A comprehensive review from sequential association computing to Hadoop-MapReduce parallel computing in a retail scenario. *Journal of Management Analytics*, 4(4), 359-392.
- [37] Warnars, H.L.H.S., Gaol, F.L., Heryadi, Y., Trisetarso, A., and Sanchez, H.E.P. (2018). Mining Association rule with Attribute Oriented Induction High level Emerging Pattern (AOI-HEP) data mining technique. Paper presented at the 2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT).
- [38] Jiménez-Luna, J., Grisoni, F., Weskamp, N., and Schneider, G. (2021). Artificial intelligence in drug discovery: Recent advances and future perspectives. *Expert Opinion on Drug Discovery*, 1-11.
- [39] Park, T.J., Kanda, N., Dimitriadis, D., Han, K.J., Watanabe, S., and Narayanan, S. (2021). A review of speaker diarization: Recent advances with deep learning. *arXiv preprint arXiv:2101.09624*.
- [40] Chartrand, G., Cheng, P.M., Vorontsov, E., Drozdal, M., Turcotte, S., Pal, C.J., . . . Tang, A. (2017). Deep learning: a primer for radiologists. *Radiographics*, 37(7), 2113-2131.
- [41] Gharsellaoui, S., Mansouri, M., Trabelsi, M., Refaat, S.S., and Messaoud, H. (2020). Fault diagnosis of heating systems using multivariate feature extraction based machine learning classifiers. *Journal of Building Engineering*, 30, 101221.
- [42] Storey, V.C. and Song, I.-Y. (2017). Big data technologies and management: What conceptual modeling can do. *Data & Knowledge Engineering*, 108, 50-67.
- [43] Zhu, L., Yu, F.R., Wang, Y., Ning, B., and Tang, T. (2018). Big data analytics in intelligent transportation systems: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 20(1), 383-398.
- [44] Navarro, P., Miller, L., Gila-Navarro, A., Díaz-Galián, M., Aguila, D., and Egea-Cortines, M. (2021). 3DeepM: An Ad Hoc Architecture Based on Deep Learning Methods for Multispectral Image Classification. *Remote Sens.* 2021, 13, 729. In: s Note: MDPI stays neutral with regard to jurisdictional claims in published
- [45] Ahmed, N. and Wahed, M. (2020). The De-democratization of AI: Deep Learning and the Compute Divide in Artificial Intelligence Research. *arXiv preprint arXiv:2010.15581*.
- [46] Shrestha, A. and Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040-53065.
- [47] Yildirim, M. and Çinar, A. (2019). Classification of White Blood Cells by Deep Learning Methods for Diagnosing Disease. *Revue d'Intelligence Artificielle*, 33(5), 335-340.
- [48] Hassan, M.M., Uddin, M.Z., Mohamed, A., and Almogren, A. (2018). A robust human activity recognition system using smartphone sensors and deep learning. *Future Generation Computer Systems*, 81, 307-313.

- [49] Pintado, D., Sanchez, V., Adarve, E., Mata, M., Gogebakan, Z., Cabuk, B., . . . Oh, P. (2019). Deep learning based shopping assistant for the visually impaired. Paper presented at the 2019 IEEE International Conference on Consumer Electronics (ICCE).
- [50] Trigueros, D.S., Meng, L., and Hartnett, M. (2018). Face recognition: From traditional to deep learning methods. arXiv preprint arXiv:1811.00116.
- [51] Fayjie, A.R., Hossain, S., Oualid, D., and Lee, D.-J. (2018). Driverless car: Autonomous driving using deep reinforcement learning in urban environment. Paper presented at the 2018 15th International Conference on Ubiquitous Robots (UR).
- [52] Yildirim, M. and Cinar, A. (2020). A deep learning based hybrid approach for COVID-19 disease detections. *Traitement du Signal*, 37(3), 461-468.
- [53] Wang, L. and Sng, D. (2015). Deep learning algorithms with applications to video analytics for a smart city: A survey. arXiv preprint arXiv:1512.03131.
- [54] Al-Garadi, M.A., Mohamed, A., Al-Ali, A.K., Du, X., Ali, I., and Guizani, M. (2020). A survey of machine and deep learning methods for internet of things (IoT) security. *IEEE Communications Surveys & Tutorials*, 22(3), 1646-1685.
- [55] Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306.
- [56] Yin, W., Kann, K., Yu, M., and Schütze, H. (2017). Comparative study of CNN and RNN for natural language processing. arXiv preprint arXiv:1702.01923.
- [57] Karakuş, B.A. (2018). Derin öğrenme ve büyük veri yaklaşımları ile metin analizi/Text analysis with deep learning and big data approaches.
- [58] Shewalkar, A. (2019). Performance evaluation of deep neural networks applied to speech recognition: RNN, LSTM and GRU. *Journal of Artificial Intelligence and Soft Computing Research*, 9(4), 235--245.
- [59] Wittenbach, J., d'Alessandro, B., and Bruss, C.B. (2020). Machine Learning for Temporal Data in Finance: Challenges and Opportunities. arXiv preprint arXiv:2009.05636.
- [60] Sak, H., Senior, A.W., and Beaufays, F. (2014). Long short-term memory recurrent neural network architectures for large scale acoustic modeling.
- [61] Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- [62] Bengio, Y. (2009). *Learning deep architectures for AI*: Now Publishers Inc.
- [63] Larochelle, H., Mandel, M., Pascanu, R., and Bengio, Y. (2012). Learning algorithms for the classification restricted boltzmann machine. *The Journal of Machine Learning Research*, 13(1), 643-669.
- [64] Sutskever, I., Hinton, G.E., and Taylor, G.W. (2009). The recurrent temporal restricted boltzmann machine. Paper presented at the Advances in neural information processing systems.
- [65] Yang, Y., Zheng, K., Wu, C., Niu, X., and Yang, Y. (2019). Building an effective intrusion detection system using the modified density peak clustering algorithm and deep belief networks. *Applied Sciences*, 9(2), 238.
- [66] Zhao, L., Zhou, Y., Lu, H., and Fujita, H. (2019). Parallel computing method of deep belief networks and its application to traffic flow prediction. *Knowledge-Based Systems*, 163, 972-987.
- [67] Wang, W. and Gómez-Bombarelli, R. (2019). Coarse-graining auto-encoders for molecular dynamics. *npj Computational Materials*, 5(1), 1-9.

- [68] Tallapally, D., Sreepada, R.S., Patra, B.K., and Babu, K.S. (2018). User preference learning in multi-criteria recommendations using stacked auto encoders. Paper presented at the Proceedings of the 12th ACM Conference on Recommender Systems.
- [69] Nuha, H.H., Balghonaim, A., Liu, B., Mohandes, M., Deriche, M., and Fekri, F. (2020). Deep neural networks with extreme learning machine for seismic data compression. *Arabian Journal for Science and Engineering*, 45(3), 1367-1377.
- [70] Sindagi, V.A. and Patel, V.M. (2018). A survey of recent advances in cnn-based single image crowd counting and density estimation. *Pattern Recognition Letters*, 107, 3-16.
- [71] Li, Z., Yang, W., Peng, S., and Liu, F. (2020). A survey of convolutional neural networks: analysis, applications, and prospects. arXiv preprint arXiv:2004.02806.
- [72] LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W., and Jackel, L.D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541-551.
- [73] Harjoseputro, Y. (2018). Classifying Javanese Letters with Convolutional Neural Network (CNN) Method. Paper presented at the the first International conference and exhibition on sciences and technology (Icest) 2018.
- [74] Zhao, H.-h. and Liu, H. (2020). Multiple classifiers fusion and CNN feature extraction for handwritten digits recognition. *Granular Computing*, 5(3), 411-418.
- [75] Scarpa, G., Gargiulo, M., Mazza, A., and Gaetano, R. (2018). A CNN-based fusion method for feature extraction from sentinel data. *Remote Sensing*, 10(2), 236.
- [76] Yildirim, O., Talo, M., Ay, B., Baloglu, U.B., Aydin, G., and Acharya, U.R. (2019). Automated detection of diabetic subject using pre-trained 2D-CNN models with frequency spectrum images extracted from heart rate signals. *Computers in biology and medicine*, 113, 103387.
- [77] Krizhevsky, A., Sutskever, I., and Hinton, G.E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- [78] Wang, S.-H., Xie, S., Chen, X., Guttery, D.S., Tang, C., Sun, J., and Zhang, Y.-D. (2019). Alcoholism identification based on an AlexNet transfer learning model. *Frontiers in psychiatry*, 10, 205.
- [79] He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- [80] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015). Going deeper with convolutions. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- [81] Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- [82] Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K.Q. (2017). Densely connected convolutional networks. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- [83] Wang, S.-H. and Zhang, Y.-D. (2020). DenseNet-201-based deep neural network with composite learning factor and precomputation for multiple sclerosis classification. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 16(2s), 1-19.
- [84] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.

- [85] Lin, C., Li, L., Luo, W., Wang, K.C., and Guo, J. (2019). Transfer learning based traffic sign recognition using inception-v3 model. *Periodica Polytechnica Transportation Engineering*, 47(3), 242-250.
- [86] Islam, M.S., Foysal, F.A., Neehal, N., Karim, E., and Hossain, S.A. (2018). InceptB: a CNN based classification approach for recognizing traditional bengali games. *Procedia computer science*, 143, 595-602.
- [87] Tan, M. and Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. Paper presented at the International Conference on Machine Learning.
- [88] Kılıç, B., Kablan, E.B., Dogan, H., Ekinci, M., Ercin, M.E., and Ersöz, Ş. Derin Konvolüsyonel Nesne Algılayıcı ile Plevral Efüzyon Sitopatolojisinde Otomatik Çekirdek Algılama. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 13(1), 33-42.
- [89] Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., . . . Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- [90] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L.-C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- [91] Baydilli, Y.Y. (2021). Polen Taşıyan Bal Arılarının MobileNetV2 Mimarisi ile Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*(21), 527-533.
- [92] Leng, J., Li, T., Bai, G., Dong, Q., and Dong, H. (2016). Cube-CNN-SVM: a novel hyperspectral image classification method. Paper presented at the 2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI).
- [93] Huang, C., Ni, S., and Chen, G. (2017). A layer-based structured design of CNN on FPGA. Paper presented at the 2017 IEEE 12th International Conference on ASIC (ASICON).
- [94] Shin, H.-C., Roth, H.R., Gao, M., Lu, L., Xu, Z., Nogues, I., . . . Summers, R.M. (2016). Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE transactions on medical imaging*, 35(5), 1285-1298.
- [95] Agarap, A.F. (2017). An architecture combining convolutional neural network (CNN) and support vector machine (SVM) for image classification. *arXiv preprint arXiv:1712.03541*.
- [96] Chen, H., Chen, A., Xu, L., Xie, H., Qiao, H., Lin, Q., and Cai, K. (2020). A deep learning CNN architecture applied in smart near-infrared analysis of water pollution for agricultural irrigation resources. *Agricultural Water Management*, 240, 106303.
- [97] Radenović, F., Tolias, G., and Chum, O. (2018). Fine-tuning CNN image retrieval with no human annotation. *IEEE transactions on pattern analysis and machine intelligence*, 41(7), 1655-1668.
- [98] Choe, J. and Shim, H. (2019). Attention-based dropout layer for weakly supervised object localization. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.
- [99] Poernomo, A. and Kang, D.-K. (2018). Biased dropout and crossmap dropout: learning towards effective dropout regularization in convolutional neural network. *Neural networks*, 104, 60-67.
- [100] Liu, K., Kang, G., Zhang, N., and Hou, B. (2018). Breast cancer classification based on fully-connected layer first convolutional neural networks. *IEEE Access*, 6, 23722-23732.
- [101] Wu, Y. and Jiang, M. (2018). Multi-layer CNN Features Fusion and Classifier Optimization for Face Recognition. Paper presented at the Proceedings of the 2018 2nd International Conference on Computer Science and Artificial Intelligence.

- [102] Wang, Y., Li, Y., Song, Y., and Rong, X. (2020). The influence of the activation function in a convolution neural network model of facial expression recognition. *Applied Sciences*, 10(5), 1897.
- [103] Kligvasser, I., Shaham, T.R., and Michaeli, T. (2018). xunit: Learning a spatial activation function for efficient image restoration. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
- [104] Lin, G. and Shen, W. (2018). Research on convolutional neural network based on improved Relu piecewise activation function. *Procedia computer science*, 131, 977-984.
- [105] Dureja, A. and Pahwa, P. (2019). Analysis of non-linear activation functions for classification tasks using convolutional neural networks. *Recent Patents on Computer Science*, 12(3), 156-161.
- [106] Tanaka, M. (2020). Weighted sigmoid gate unit for an activation function of deep neural network. *Pattern Recognition Letters*, 135, 354-359.
- [107] Zhang, Y., Hua, Q., Xu, D., Li, H., Bu, Y., and Zhao, P. (2019). A Complex-Valued CNN for Different Activation Functions in Polarsar Image Classification. Paper presented at the IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium.
- [108] Zaheer, R. and Shaziya, H. (2018). GPU-based empirical evaluation of activation functions in convolutional neural networks. Paper presented at the 2018 2nd International Conference on Inventive Systems and Control (ICISC).
- [109] Dewa, C.K. (2018). Suitable CNN weight initialization and activation function for Javanese vowels classification. *Procedia computer science*, 144, 124-132.
- [110] Bawa, V.S. and Kumar, V. (2019). Linearized sigmoidal activation: A novel activation function with tractable non-linear characteristics to boost representation capability. *Expert systems with applications*, 120, 346-356.
- [111] Feng, J. and Lu, S. (2019). Performance analysis of various activation functions in artificial neural networks. Paper presented at the Journal of Physics: Conference Series.
- [112] Kong, S. and Takatsuka, M. (2017). Hexpo: A vanishing-proof activation function. Paper presented at the 2017 International Joint Conference on Neural Networks (IJCNN).
- [113] Liu, J. and Huang, Y. (2020). Comparison of Different CNN Models in Tuberculosis Detecting. *KSII Transactions on Internet and Information Systems (TIIS)*, 14(8), 3519-3533.
- [114] Hao, W., Yizhou, W., Yaqin, L., and Zhili, S. (2020). The Role of Activation Function in CNN. Paper presented at the 2020 2nd International Conference on Information Technology and Computer Application (ITCA).
- [115] Liu, Z., Shen, Z., Savvides, M., and Cheng, K.-T. (2020). Reactnet: Towards precise binary neural network with generalized activation functions. Paper presented at the European Conference on Computer Vision.
- [116] Avenash, R. and Viswanath, P. (2019). Semantic Segmentation of Satellite Images using a Modified CNN with Hard-Swish Activation Function. Paper presented at the VISIGRAPP (4: VISAPP).
- [117] Kouretas, I. and Paliouras, V. (2019). Simplified hardware implementation of the softmax activation function. Paper presented at the 2019 8th International Conference on Modern Circuits and Systems Technologies (MOCAST).
- [118] Liang, X., Wang, X., Lei, Z., Liao, S., and Li, S.Z. (2017). Soft-margin softmax for deep classification. Paper presented at the International Conference on Neural Information Processing.
- [119] Çınar, A., Yıldırım, M., and Eroğlu, Y. (2021). Classification of Pneumonia Cell Images Using Improved ResNet50 Model. *Traitement du Signal*, 38(1), 165-173.

- [120] Hassib, E.M., El-Desouky, A.I., Labib, L.M., and El-kenawy, E.-S.M. (2020). WOA+ BRNN: An imbalanced big data classification framework using Whale optimization and deep neural network. *soft computing*, 24(8), 5573-5592.
- [121] Meng, Z., Zhang, M., Guo, C., Fan, Q., Zhang, H., Gao, N., and Zhang, Z. (2020). Recent progress in sensing and computing techniques for human activity recognition and motion analysis. *Electronics*, 9(9), 1357.
- [122] Golestani, N. and Moghaddam, M. (2020). Human activity recognition using magnetic induction-based motion signals and deep recurrent neural networks. *Nature communications*, 11(1), 1-11.
- [123] Hernandez, N., Lundström, J., Favela, J., McChesney, I., and Arnrich, B. (2020). Literature review on transfer learning for human activity recognition using mobile and wearable devices with environmental technology. *SN Computer Science*, 1(2), 1-16.
- [124] de Oliveira Silva, V., de Barros Vidal, F., and Romariz, A.R.S. (2017). Human Action Recognition Based on a Two-stream Convolutional Network Classifier. Paper presented at the 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA).
- [125] Jaouedi, N., Boujnah, N., and Bouhleb, M.S. (2020). A new hybrid deep learning model for human action recognition. *Journal of King Saud University-Computer and Information Sciences*, 32(4), 447-453.
- [126] Charalampous, K. and Gasteratos, A. (2016). On-line deep learning method for action recognition. *Pattern Analysis and Applications*, 19(2), 337-354.
- [127] Wang, H., Kläser, A., Schmid, C., and Liu, C.-L. (2013). Dense trajectories and motion boundary descriptors for action recognition. *International journal of computer vision*, 103(1), 60-79.
- [128] Ma, S., Sigal, L., and Sclaroff, S. (2015). Space-time tree ensemble for action recognition. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
- [129] Wang, H., Klaser, A., Schmid, C., and Cheng-Lin, L. (2011). Action recognition by dense trajectories. *Computer Vision and Pattern Recognition (CVPR)*. Paper presented at the 2011 IEEE Conference on.
- [130] Le, Q.V., Zou, W.Y., Yeung, S.Y., and Ng, A.Y. (2011). Learning hierarchical invariant spatio-temporal features for action recognition with independent subspace analysis. Paper presented at the CVPR 2011.
- [131] Kovashka, A. and Grauman, K. (2010). Learning a hierarchy of discriminative space-time neighborhood features for human action recognition. Paper presented at the 2010 IEEE computer society conference on computer vision and pattern recognition.
- [132] URL-1, https://www.crcv.ucf.edu/data/UCF_Sports_Action.php , Last Accessed Date: 01.02.2020.
- [133] Belden, C.J., Valdes, P.A., Ran, C., Pastel, D.A., Harris, B.T., Fadul, C.E., . . . Roberts, D.W. (2011). Genetics of glioblastoma: a window into its imaging and histopathologic variability. *Radiographics*, 31(6), 1717-1740.
- [134] Garzín, B., Emblem, K.E., Mouridsen, K., Nedregaard, B., Due-Tønnessen, P., Nome, T., . . . Kvinnsland, Y. (2011). Multiparametric analysis of magnetic resonance images for glioma grading and patient survival time prediction. *Acta radiologica*, 52(9), 1052-1060.
- [135] Özyurt, F., Sert, E., Avci, E., and Dogantekin, E. (2019). Brain tumor detection based on Convolutional Neural Network with neutrosophic expert maximum fuzzy sure entropy. *Measurement*, 147, 106830.

- [136] Toğaçar, M., Cömert, Z., and Ergen, B. (2020). Classification of brain MRI using hyper column technique with convolutional neural network and feature selection method. *Expert Systems with Applications*, 149, 113274.
- [137] Amin, J., Sharif, M., Gul, N., Yasmin, M., and Shad, S.A. (2020). Brain tumor classification based on DWT fusion of MRI sequences using convolutional neural network. *Pattern Recognition Letters*, 129, 115-122.
- [138] Mohsen, H., El-Dahshan, E.-S.A., El-Horbaty, E.-S.M., and Salem, A.-B.M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68-71.
- [139] Pareek, M., Jha, C., and Mukherjee, S., Brain Tumor Classification from MRI Images and Calculation of Tumor Area, in *Soft Computing: Theories and Applications*. 2020, Springer. p. 73-83.
- [140] Anaraki, A.K., Ayati, M., and Kazemi, F. (2019). Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *biocybernetics and biomedical engineering*, 39(1), 63-74.
- [141] Gumaei, A., Hassan, M.M., Hassan, M.R., Alelaiwi, A., and Fortino, G. (2019). A hybrid feature extraction method with regularized extreme learning machine for brain tumor classification. *IEEE Access*, 7, 36266-36273.
- [142] Das, S., Aranya, O.R.R., and Labiba, N.N. (2019). Brain tumor classification using convolutional neural network. Paper presented at the 2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT).
- [143] URL-1, <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection>, Last Accessed Date: 01.01.2020.
- [144] Shahab, S. and Fangusaro, J. (2021). Neonatal Central Nervous System Tumors. *Clinics in perinatology*, 48(1), 35-51.
- [145] Marton, R.M. and Paşca, S.P. (2020). Organoid and assembloid technologies for investigating cellular crosstalk in human brain development and disease. *Trends in cell biology*, 30(2), 133-143.
- [146] Ates, O.F., Taydas, O., and Dheir, H. (2020). Thorax magnetic resonance imaging findings in patients with coronavirus disease (COVID-19). *Academic radiology*, 27(10), 1373-1378.
- [147] Zeng, Q., Liu, H., Zhang, K., Li, C., and Zhou, G. (2011). Noninvasive evaluation of cerebral glioma grade by using multivoxel 3D proton MR spectroscopy. *Magnetic resonance imaging*, 29(1), 25-31.
- [148] Kalpathy-Cramer, J., Gerstner, E.R., Emblem, K.E., Andronesi, O.C., and Rosen, B. (2014). Advanced magnetic resonance imaging of the physical processes in human glioblastoma. *Cancer research*, 74(17), 4622-4637.
- [149] Behrens, F., Funk-Hilsdorf, T.C., Kuebler, W.M., and Simmons, S. (2021). Bacterial Membrane Vesicles in Pneumonia: From Mediators of Virulence to Innovative Vaccine Candidates. *International Journal of Molecular Sciences*, 22(8), 3858.
- [150] Stephen, O., Sain, M., Maduh, U.J., and Jeong, D.-U. (2019). An efficient deep learning approach to pneumonia classification in healthcare. *Journal of healthcare engineering*, 2019.
- [151] Luján-García, J.E., Yáñez-Márquez, C., Villuendas-Rey, Y., and Camacho-Nieto, O. (2020). A transfer learning method for pneumonia classification and visualization. *Applied Sciences*, 10(8), 2908.

- [152] Chouhan, V., Singh, S.K., Khamparia, A., Gupta, D., Tiwari, P., Moreira, C., . . . De Albuquerque, V.H.C. (2020). A novel transfer learning based approach for pneumonia detection in chest X-ray images. *Applied Sciences*, 10(2), 559.
- [153] Saraiva, A.A., Santos, D., Costa, N.J.C., Sousa, J.V.M., Ferreira, N.M.F., Valente, A., and Soares, S. (2019). Models of Learning to Classify X-ray Images for the Detection of Pneumonia using Neural Networks. Paper presented at the Bioimaging.
- [154] Jain, R., Nagrath, P., Kataria, G., Kaushik, V.S., and Hemanth, D.J. (2020). Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement*, 165, 108046.
- [155] Siddiqi, R. (2019). Automated pneumonia diagnosis using a customized sequential convolutional neural network. Paper presented at the Proceedings of the 2019 3rd International Conference on Deep Learning Technologies.
- [156] URL-1, <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>, Last Accessed Date: 12.12.2019.
- [157] Wang, H., Anthony, D., Yatmaz, S., Wijburg, O., Satzke, C., Levy, B., . . . Bozinovski, S. (2017). Aspirin-triggered resolvin D1 reduces pneumococcal lung infection and inflammation in a viral and bacterial coinfection pneumonia model. *Clinical Science*, 131(18), 2347-2362.
- [158] Gothankar, J., Doke, P., Dhumale, G., Pore, P., Lalwani, S., Quraishi, S., . . . Dhobale, R. (2018). Reported incidence and risk factors of childhood pneumonia in India: a community-based cross-sectional study. *BMC public health*, 18(1), 1-11.
- [159] Makhnevich, A., Sinvani, L., Cohen, S.L., Feldhamer, K.H., Zhang, M., Lesser, M.L., and McGinn, T.G. (2019). The clinical utility of chest radiography for identifying pneumonia: accounting for diagnostic uncertainty in radiology reports. *American Journal of Roentgenology*, 213(6), 1207-1212.

ÖZGEÇMİŞ

Muhammed YILDIRIM

[REDACTED]

[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]
[REDACTED] [REDACTED]

[REDACTED] [REDACTED]
[REDACTED] [REDACTED]

[REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED]
[REDACTED]
[REDACTED]
[REDACTED]
[REDACTED]
[REDACTED] [REDACTED]
[REDACTED]
[REDACTED] [REDACTED]

ARAŞTIRMA DENEYİMİ

- ✓ Bilinen programlama dilleri Matlab , C, C++, C#, Python

[REDACTED] [REDACTED]
[REDACTED] [REDACTED]

AKADEMİK FAALİYETLER

Makaleler:

1. Cinar, A., & Yildirim, M. (2020). Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture. Medical hypotheses, 139, 109684. <https://doi.org/10.1016/j.mehy.2020.109684>
2. Yildirim, M., & Cinar, A. (2020). A deep learning based hybrid approach for Covid-19 disease detections. Traitement du Signal, 37(3), 461-468. <https://doi.org/10.18280/ts.3703>

3. Çınar, A., Yıldırım, M., & Eroğlu, Y. (2021). Classification of Pneumonia Cell Images Using Improved ResNet50 Model. *Traitement du Signal*, 38(1), 165-173. <https://doi.org/10.18280/ts.380117>
4. Eroğlu, Y., Yıldırım, M., & Çınar, A. (2021). Convolutional Neural Networks Based classification of breast ultrasonography images by hybrid method with respect to Benign, Malignant, and Normal using mRMR. *Computers in Biology and Medicine*, 104407. <https://doi.org/10.1016/j.combiomed.2021.104407>
5. Yıldırım, M., & Çınar, A. (2019). Classification of White Blood Cells by Deep Learning Methods for Diagnosing Disease. *Revue d'Intelligence Artificielle*, 33(5), 335-340. <https://doi.org/10.18280/ria.330502>
6. Yıldırım, M., & Cinar, A. (2020). Classification of Alzheimer's Disease MRI Images with CNN Based Hybrid Method. *Journal homepage: http://iieta.org/journals/isi*, 25(4), 413-418. <https://doi.org/10.18280/isi.250402>
7. Çınar, A., & Yıldırım, M. (2020). Classification of Malaria Cell Images with Deep Learning Architectures. *Ingénierie des Systèmes d'Inf.*, 25(1), 35-39. <https://doi.org/10.18280/isi.250105>
8. Çınar, A., & Yıldırım, M. Improving the Performance of the Institution by Using Apriori Algorithm. *International Journal of Engineering Sciences & Management Research*.
9. Yıldırım, M., & Cinar, A. (2021). A new model for classification of human movements on videos using Convolutional Neural Networks:MA-Net. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*. DOI: 10.1080/21681163.2021.1922315
10. Yıldırım, M., & Cinar, A. (2021). Classification of 40 Different Human Movements with CNN Architectures and Comparison of Their Performance. *Turkish Journal of Science and Technology*, 16(1), 103-112.
11. Yıldırım, M., & Cinar, A. (2019) Use Of Fpga For Real-Time K-Means Clustering Algorithm. *International Journal of Engineering Science and Application*, 3(3), 130-136.

Bildiriler:

1. Yıldırım, M., & Cinar, A.(2019). Classification of Human Movements by Deep Learning Methods. 4th International Engineering and Natural Sciences Conference(IENSC 2019). 351-358.
2. Yıldırım, M., & Çınar, A. (2019, September). Simultaneously Realization of Image Enhancement Techniques on Real-Time Fpga. In 2019 International Artificial Intelligence and Data Processing Symposium (IDAP) (pp. 1-6). IEEE. doi: 10.1109/IDAP.2019.887595
3. Yıldırım, M., & Cinar, A.(2019). Real-Time Realization of Edge Detection Algorithms on Fpga. 4th International Engineering and Natural Sciences Conference(IENSC 2019). 404-411