T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

TIBBI GÖRÜNTÜ İŞLEME ve DERİN ÖĞRENME YÖNTEMLERİYLE HASTALIKLARDA TEŞHİS OTOMASYON MODELİ

Mustafa GÜLER

DANIŞMAN
Doç. Dr. Ersin NAMLI

II. DANIŞMAN
Doç. Dr. Ramazan ÜNLÜ

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

Ağustos, 2022

TEZ KABUL VE ONAYI

Mustafa GÜLER tarafından, **Doç. Dr. Ersin NAMLI** danışmanlığında hazırlanan **"TIBBİ GÖRÜNTÜ İŞLEME ve DERİN ÖĞRENME YÖNTEMLERİYLE HASTALIKLARDA TEŞHİS OTOMASYON MODELİ"** başlıklı bu çalışma, jürimiz tarafından **16/08/2022** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Doktora Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	Sonuç
DANIŞMAN	Doç. Dr. Ersin NAMLI İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA ENDÜSTRİ MÜHENDİSLİĞİ Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. Yusuf Sait TÜRKAN İSTANBUL ÜNİVESİTESİ-CERRAHPAŞA ENDÜSTRİ MÜHENDİSLİĞİ Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. MURAT TAHA BİLİŞİK İSTANBUL KÜLTÜR ÜNİVERSİTESİ İŞLETME Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi FUNDA HATİCE SEZGİN İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA ENDÜSTRİ MÜHENDİSLİĞİ Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. HAKAN BEKTAŞ İSTANBUL ÜNİVERSİTESİ İSTATİSTİK Anabilim Dalı		☒ Kabul ☐ Ret

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve bilimsel etik kuralları içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını ve her türlü hukuki sorumluluğu aldığımı kabul ederim.

Mustafa GÜLER

Aileme ithaf ediyorum…

BÜTÇE DESTEKLERİ

TIBBİ GÖRÜNTÜ İŞLEME ve DERİN ÖĞRENME YÖNTEMLERİYLE HASTALIKLARDA TEŞHİS OTOMASYON MODELİ

Bu çalışma İstanbul Üniversitesi-Cerrahpaşa Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje numarası: 35916

TEŞEKKÜR

Doktora eğitimime başladığım ilk günden bugüne kadar hem akademik hem de özel hayatımda yeri geldiğinde hocam, yeri geldiğinde ağabeyim kadar yakın olan, bana tüm bilgi ve tecrübelerini aktaran ve hakkını asla ödeyemeyeceğim tez danışmanım sayın Doç. Dr. Ersin NAMLI'ya, Mühendislik Bilimleri Bölümünde beni her zaman destekleyen kıymetli hocalarım Doç. Dr. Gökhan ÇAYLI ve Doç. Dr. Cengiz KAHRAMAN'a, tezimin hazırlamasında ve yazılım konusunda desteklerini esirgemeyen çok kıymetli arkadaşım Yüksek Mühendis Öykü Zeynep BAYRAMOĞLU'na ayrı ayrı teşekkürlerimi ve şükranlarımı sunmayı bir borç bilirim.

İyi günde ve kötü günde her daim yanımda olan kadim dostlarım Mesut YILDIZ ve Ahmet ÇEBİ'ye sıcak ve içten dostlukları için en içten saygı ve sevgiyle teşekkür ederim.

Son olarak bugün bulunduğum noktaya gelmemde maddi ve manevi imkanlarını hiçbir zaman esirgemeyen, aldığım her kararımda arkamda duran kıymetli ailem; canım ağabeyim Doç. Dr. Mehmet GÜLER, kıymetli babam Mahmut GÜLER ve fedakâr annem Nazan GÜLER'e ömrümün sonuna kadar minnettar kalacağım.

Ağustos 2022 Mustafa GÜLER

İÇİNDEKİLER

Sayfa No

1. GİRİŞ 1
1.1. TEZİN AMACI ve KAPSAMI 1
1.2. TEZİN ORGANİZASYONU 3
2. KAVRAMSAL ÇERÇEVE 5
2.1. GÖRÜNTÜ SINIFLANDIRMA 5
2.1.1. Evrişimsel Sinir Ağı (CNN) Mimarileri 6
2.1.2. AlexNet Mimarisi 7
2.1.3. VGG Mimarisi 8
2.1.4. ResNet50 Mimarisi 11
2.1.5. Xception Mimarisi 12
2.1.6. NASNet Mimarisi 13
2.1.7. DarkNet53 Mimarisi 14
2.1.8. EfficientNet Mimarisi 14
2.1.9. ShuffleNetv2 Mimarisi 15
2.1.10. DenseNet Mimarisi 16
2.1.11. SqueezeNet Mimarisi 17
2.1.12. U-Net Mimarisi 18
2.2. GELENEKSEL MAKİNE ÖĞRENMESİ SINIFLANDIRICILARI 20
2.2.1. Destek Vektör Makinaları 21
2.2.2. K-En Yakın Komşu 22
2.2.3. Karar Ağaçları 24
2.2.4. Lojistik Regresyon 25
2.2.5. Naive Bayes 26
2.2.6. Doğrusal Diskriminant Analizi 27
2.2.7. Aktivasyon Fonksiyonları 27
2.2.7.1. Basamak Step Fonksiyonu 27
2.2.7.2. Sigmoid Fonksiyonu 28
2.2.7.3. Softmax Fonksiyonu 29
2.2.7.4. Hiperbolik Tanjant Fonksiyonu 29

2.2.7.5. ReLU (Rectified Linear Unit) Fonksiyonu *30*
2.3. TOPLULUK YÖNTEMLERİ 31
2.3.1. Torbalama Yöntemi (Bagging) 31
2.3.2. Yükseltme Yöntemi (Boosting) 33
2.3.3. Oylama Yöntemi (Voting) 34
2.3.3.1. Sert Oylama *34*
2.3.3.2. Olasılığa Dayalı Oylama *35*
2.4. MEDİKAL GÖRÜNTÜLER KULLANILARAK YAPILAN DERİN ÖĞRENME UYGULAMALARI 35
2.4.1. Medikal Görüntüler Kullanılarak Beyin Tümörü Tespiti İçin Yapılan Derin Öğrenme Uygulamaları 35
2.4.2. Medikal Görüntüler Kullanılarak Göğüs Tümörü Tespiti İçin Yapılan Derin Öğrenme Uygulamaları 38
2.4.3. Medikal Görüntüler Kullanılarak Cilt Tümörü Tespiti İçin Yapılan Derin Öğrenme Uygulamaları 40
3. YÖNTEM 43
3.1. KULLANILAN VERİ SETLERİ 43
3.1.1. Beyin Tümörü ve Yapısı 43
3.1.2. Beyin Tümörü Veri Seti 44
3.1.3. Göğüs Tümörü ve Yapısı 45
3.1.4. Göğüs Tümörü Veri Seti 46
3.1.5. Cilt Tümörü ve Yapısı 48
3.1.6. Cilt Tümörü Veri Seti 49
3.2. EĞİTİM AŞAMASI PARAMETRE OPTİMİZASYONU 50
3.2.1. Veri Setinin Boyutu 50
3.2.2. Epoch Parametresi 50
3.2.3. Izgara Araması (Grid Search) 50
3.2.4. Learning Rate Parametresi 50
3.2.5. Standart Gradyan Azalma Algoritması 51
3.2.6. Stokastik Gradyan Azalma Algoritması 51
3.2.7. Mini Batch Size Parametresi 51
3.2.8. Erken Durma (Early Stopping) 51
3.2.9. Topluluk Öğrenmesi 51
3.3. DEĞERLENDİRME KRİTERLERİ 52
3.4. UYGULAMA PLATFORMLARI 54
4. BULGULAR 55
4.1. BEYİN TÜMÖRÜ VERİ SETİ UYGULAMASI 56

4.1.1. Klasik Makine Öğrenmesi Yöntemi ve Sonuçlar 56
4.1.2. Parametre Optimizasyonu Öncesi-Sonrası CNN Modelleri Sonuçları 57
4.1.3. Topluluk Öğrenmesi Uygulaması ve Sonuçlar 61
4.2. GÖĞÜS TÜMÖRÜ VERİ SETİ UYGULAMASI 62
4.2.1. Klasik Makine Öğrenmesi Yöntemi ve Sonuçlar 62
4.2.2. Parametre Optimizasyonu Öncesi-Sonrası CNN Modelleri Sonuçları 64
4.2.3. Topluluk Öğrenmesi Uygulaması ve Sonuçlar 67
4.3. CİLT TÜMÖRÜ VERİ SETİ UYGULAMASI 68
4.3.1. Klasik Makine Öğrenmesi Yöntemi ve Sonuçlar 68
4.3.2. Parametre Optimizasyonu Öncesi-Sonrası CNN Modelleri Sonuçları 69
4.3.3. Topluluk Öğrenmesi Uygulaması ve Sonuçlar 73
5. TARTIŞMA 74
6. SONUÇ VE ÖNERİLER 77

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: CNN Mimarilerinin Genel Yapısı [6] 6
Şekil 2.2: AlexNet Derin Öğrenme Algoritması [10] 8
Şekil 2.3: VGG Derin Öğrenme Algoritması [10] 9
Şekil 2.4: VGG Mimarisi [13] 10
Şekil 2.5: ResNet Artık Blok [16] 11
Şekil 2.6: ResNet Mimarisi [16] 12
Şekil 2.7: Xception Mimarisi [19] 12
Şekil 2.8: NASNet CIFAR10 ve Imagenet Mimarisi [21] 13
Şekil 2.9: DarkNet53 Mimarisi [23] 14
Şekil 2.10: EfficientNet Mimarisi [26] 15
Şekil 2.11: ShuffleNetv2 Diyagramı [29] 16
Şekil 2.12: DenseNet Mimarisi [31] 17
Şekil 2.13: SqueezeNet Mimarisi [34] 18
Şekil 2.14: U-Net Mimarisi [35] 19
Şekil 2.15: Makine Öğrenmesi Yöntemlerinin Gösterimi [38] 21
Şekil 2.16: Destek Vektörlerinin Doğrusal Düzlemde Gösterimi [41] 22
Şekil 2.17: K-En Yakın Komşu Algoritması [45] 23
Şekil 2.18: Karar Ağacı Algoritması [46] 24
Şekil 2.19: Lojistik Regresyon [47] 25
Şekil 2.20: Naive Bayes Modeli [50] 26
Şekil 2.21: Doğrusal Fonksiyon ve Türevi [53] 28

Şekil 2.22: Sigmoid Fonksiyonu ve Türevi [53] 28
Şekil 2.23: Hiperbolik Tanjant Fonksiyonu ve Türevi [53] 30
Şekil 2.24: ReLU Fonksiyonu ve Türevi [53] 30
Şekil 2.25: LReLU Fonksiyonu ve Türevi [53] 31
Şekil 2.26: Torbalama Yöntemi İş Akış Diyagramı 32
Şekil 2.27: Yükseltme Yöntemi İş Akış Diyagramı 33
Şekil 2.28: Oylama Yöntemi İş Akış Diyagramı 34
Şekil 3.1: Glioma ve Meningioma Beyin Tümörü 44
Şekil 3.2: Pituitary ve Notumor (Sağlıklı) Beyin Tümörü 45
Şekil 3.3: Adeno Carcinoma ve Notumor (Sağlıklı) Göğüs Tümörü 47
Şekil 3.4: Large Cell Carcinoma ve Squamous Cell Carcinoma Göğüs Tümörü 47
Şekil 3.5: İyi ve Kötü Huylu Cilt Tümörleri 49
Şekil 4.1: DenseNet + SVM CM 57
Şekil 4.2: SqueezeNet + DenseNet + ResNet + VGG CM 57
Şekil 4.3: ResNet Mimarisi Parametre Optimizasyon Öncesi 58
Şekil 4.4: VGG Mimarisi Parametre Optimizasyon Öncesi 58
Şekil 4.5: SqueezeNet Mimarisi Parametre Optimizasyon Öncesi 58
Şekil 4.6: DenseNet Mimarisi Parametre Optimizasyon Öncesi 58
Şekil 4.7: ResNet Doğrulama-Epoch Sayısı Grafiği 59
Şekil 4.8: ResNet Optimizasyon Sonrası Karmaşıklık Matrisi 60
Şekil 4.9: Beyin Tümörü Veri Seti Oylama Yöntemi Karmaşıklık Matrisi 61
Şekil 4.10: VGG + SVM Karmaşıklık Matrisi 63
Şekil 4.11: SqueezeNet + DenseNet + ResNet+VGG Karmaşıklık Matrisi 63
Şekil 4.12: ResNet Mimarisi Parametre Optimizasyon Öncesi 64
Şekil 4.13: VGG Mimarisi Parametre Optimizasyon Öncesi 64
Şekil 4.14: SqueezeNet Mimarisi Parametre Optimizasyon Öncesi 64

Şekil 4.15: DenseNet Mimarisi Parametre Optimizasyon Öncesi ……65
Şekil 4.16: DenseNet Doğrulama-Epoch Sayısı Grafiği 65
Şekil 4.17: Optimizasyon Sonrası DenseNet Karmaşıklık Matrisi 66
Şekil 4.18: Göğüs Tümörü Veri Seti Oylama Yöntemi Karmaşıklık Matrisi 67
Şekil 4.19: SqueezeNet+SVM Karmaşıklık Matrisi.....69
Şekil 4.20: SqueezeNet+DenseNet+ResNet+VGG Karmaşıklık Matrisi ……...69
Şekil 4.21: ResNet Mimarisi Parametre Optimizasyon Öncesi.....70
Şekil 4.22: VGG Mimarisi Parametre Optimizasyon Öncesi ……70
Şekil 4.23: SqueezeNet Mimarisi Parametre Optimizasyon Öncesi 70
Şekil 4.24: DenseNet Mimarisi Parametre Optimizasyon Öncesi ……70
Şekil 4.25: DenseNet Doğrulama-Epoch Sayısı Grafiği 71
Şekil 4.26: Optimizasyon Sonrası DenseNet Karmaşıklık Matrisi 72
Şekil 4.27: Cilt Tümörü Veri Seti Oylama Yöntemi Karmaşıklık Matrisi.....73

TABLO LİSTESİ

Sayfa No

Tablo 3.1: Karmaşıklık Matrisi ve Performans Metrikleri 52

Tablo 4.1: Kullanılan Ortak Parametreler 55

Tablo 4.2: Beyin Tümörü ML Doğruluk Oranı 56

Tablo 4.3: DenseNet + SVM Başarım Metrik Değerleri 57

Tablo 4.4: SqueezeNet + DenseNet + ResNet +VGG Başarım Metrik Değerleri 57

Tablo 4.5: Beyin Tümörü Veri Seti Parametre Optimizasyonu Değerleri 59

Tablo 4.6: ResNet Optimizasyon Sonrası Model Başarım Oranları 60

Tablo 4.7: Beyin Tümörü Veri Seti Oylama Yöntemi Model Başarım Oranları 61

Tablo 4.8: Göğüs Tümörü ML Doğruluk Oranı 62

Tablo 4.9: VGG + SVM Başarım Metrik Değerleri 63

Tablo 4.10: SqueezeNet + DenseNet + ResNet +VGG Başarım Metrik Değerleri 63

Tablo 4.11: Göğüs Tümörü Veri Seti Parametre Optimizasyon Değerleri 65

Tablo 4.12: DenseNet Optimizasyon Sonrası Model Başarım Oranları 66

Tablo 4.13: Göğüs Tümörü Veri Seti Oylama Yöntemi Model Başarım Oranları 67

Tablo 4.14: Cilt Tümörü ML Doğruluk Oranı 68

Tablo 4.15: SqueezeNet + SVM Başarım Metrik Değerleri 69

Tablo 4.16: SqueezeNet + DenseNet + ResNet +VGG Başarım Metrik Değerleri 69

Tablo 4.17: Cilt Tümörü Veri Seti Parametre Optimizasyon Değerleri 71

Tablo 4.18: DenseNet Optimizasyon Sonrası Model Başarım Oranları 72

Tablo 4.19: Cilt Tümörü Veri Seti Oylama Yöntemi Model Başarım Oranları 73

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
AI	: Artificial Intelligence (Yapay Zeka)
BT	: Bilgisayarlı Tomografi
X-ray	: Röntgen
ML	: Machine Learning (Makine Öğrenmesi)
MRG	: Manyetik Rezonans Görüntüleme
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağları)
CPU	: Central Process Unit
GPU	: Graphics Process Unit
VGG	: Visual Geometry Group
ReLU	: Doğrultulmuş Doğrusal Birim
YOLO	: You Only Look Once
CUDA	: Compute Unified Device Architecture
SVM	: Support Vector Machine (Destek Vektör Makinesi)
LDA	: Linear Discriminant Analysis (Lineer Diskriminant Analizi)
k-NN	: k-Nearest Neighbors (k-En Yakın Komşu Kestrimi)
DT	: Decision Tree (Karar Ağaçları)
NB	: Naive Bayes
TanH	: Hiperbolik Tanjant Fonksiyonu
ACC	: Accuracy (Doğruluk)
PREC	: Kesinlik
TP	: Doğru Pozitif
TN	: Doğru Negatif
FP	: Yanlış Pozitif
FN	: Yanlış Negatif
CAD	: Bilgisayar Destekli Tespit
CM	: Confusion Matrix (Karmaşıklık Matrisi)

ÖZET

DOKTORA TEZİ

TIBBİ GÖRÜNTÜ İŞLEME ve DERİN ÖĞRENME YÖNTEMLERİYLE HASTALIKLARDA TEŞHİS OTOMASYON MODELİ

Mustafa GÜLER

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

Danışman: Doç. Dr. Ersin NAMLI

II. Danışman: Doç. Dr. Ramazan ÜNLÜ

Yapay zekâ biliminin son yıllarda gelişmesiyle birlikte hayatın her alanında etkin bir şekilde kullanılmaya başlandığı bilinmektedir. Yapay zekanın bir alt dalı olarak kabul edilen makine öğrenmesi ve derin öğrenme çalışmalarının da hız kazanmasıyla birlikte sağlık sektöründe uygulama alanı oldukça genişlemiştir. Salgın hastalıkların son zamanlarda artması ve kanser hastalığı gibi insan yaşamını tehdit eden ölümcül hastalıkların her yıl artış göstermesinden dolayı bu alanda yapılan çalışmalara daha fazla önem verilmeye başlanmıştır. Özellikle son yıllarda derin öğrenme yöntemleri kullanılarak görüntü ve veri işleme konusunda yapılan çalışmalar artmış, hastalık ön tanısı ve MR görüntüsü işleme alanında birçok çalışma yapılmıştır. Bu tez çalışmasında, Beyin, Göğüs ve Cilt tümörlerinin MR görüntüleri kullanılarak klasik makine öğrenmesi ve derin öğrenme yöntemleriyle sınıflandırılması ve hastalığın erken teşhisi ve tanısı bir için uygulama yapılmıştır. Önerilen yöntemlerde Evrişimsel sinir ağları esas alınmıştır. Üç farklı veri seti kümesine sırasıyla klasik makine öğrenmesi teknikleri (Destek Vektör Makinesi, K-En Yakın Komşu, Naive Bayes, Karar Ağacı ve Lineer Diskriminant Analizi), dört farklı Evrişimsel sinir ağı (VGG, ResNet, SqueezeNet, DenseNet) modeli ve Topluluk öğrenmesi (Oylama) yöntemi ile karşılaştırmalı olarak analiz yapılmış ve uygulanmıştır. Modellerin eğitim ve test aşaması sırasında Kaggle kütüphanesinde açık erişimli şekilde bulunan veriler kullanılmıştır. Önerilen yöntemlerin iyileştirilmesi için Python yazılım programından faydalanılmış, kullanılan metrikler ve sınıflandırma başarım oranları karşılıklı olarak değerlendirilmiştir. Bulunan sonuçlar literatürdeki benzer çalışmalarla karşılaştırılmış ve tüm sonuçlar ayrıca verilmiştir.

Ağustos 2022, 91 sayfa.

Anahtar Kelimeler: Derin Öğrenme, Görüntü İşleme, Evrişimsel Sinir Ağları, Sınıflandırma

ABSTRACT

Ph.D. THESIS

DIAGNOSTIC AUTOMATION MODEL in DISEASES with MEDICAL IMAGE PROCESSING and DEEP LEARNING METHODS

Mustafa GÜLER

Istanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Industrial Engineering

Industrial Engineering Programme

Supervisor : Assoc. Prof. Dr. Ersin NAMLI

Co-Supervisor: Assoc. Prof. Dr. Ramazan ÜNLÜ

It's known that, in last years by the development of the Artificial Intelligence Science it was started to be used in every field of the life. With acceleration in the Deep Learning and machine learning studies which are mentioned as the subfields of the Artificial Intelligence, the application of those studies in the health sector have expanded. In last times, researches in this field was gotten more importance because of the increase in the epidemic diseases and the increase in the fatal illnesses like cancer. Specially in last years, the studies in which the deep learning methods was used have increased and many researches were done for disease prediagnosis and MR image processing. The suggested methods are based on the convolutional neural networks. Classical machine learning techniques (Support Vector Machines, k-Nearest Neighbors, Naive Bayes, Decision Trees, Lineer Regression Analysis), Four different Convolutional neural networks models (VGG, ResNet, SqueezeNet, DenseNet) and Ensemble learning (Hard Voting) were applied to three different data sets. For the models education and test phases Kaggle library's open source data was used. To develop the suggested methods, the Python software programme was used. Used metrics and classification success rates were evaluated. As last, all results were compared with the other similar studies in literature and all results were written.

August 2022, 91 pages.

Keywords: Deep Learning, Image Processing, Convolutional Neural Networks, Classification

1. GİRİŞ

Yapay zekâ (AI), insan zekasını taklit etmeye çalışan, topladığı bilgilerle yaratıcı çözümler sunabilen son derece akıllı programlar ve makinelerden oluşan bir teknolojidir. Yapay zekanın temel amacı genellikle insanlarda gözlemlediğimiz akıllı davranışları bilgisayarlara ve makinalara uyarlamaktır. Son yıllarda özellikle ekonomik faaliyetlerde, sosyal yaşamda ve tıbbi gelişmelerde yapay zekâ teknolojileri sıklıkla kullanılmaya başlanmış ve son derece başarılı sonuçlar elde edilmiştir.

Yapay zekanın bir alt kümesi olarak karşımıza çıkan Makine öğrenmesi, kendi kendine öğrenebilen modeller üzerinden tahmin yapabilen algoritmaların mimarilerini araştıran bir sistemdir. Makine öğrenmesi içerisinde birçok değişik tipte problemi çözmeye yardımcı farklı algoritmalar bulundurmaktadır. Bununla birlikte makine öğrenmesinin bir alanı olarak karşımıza çıkan Derin öğrenme ve Görüntü işleme konusunda yapılmış birçok çalışma bulunmaktadır. Bunlar genellikle görüntülerden çıkarım, sınıflandırma ve nesne bulma üzerine yoğunlaşmıştır. Görüntüden doğru bir şekilde çıkarım yapılabilmesi için görüntünün doğru bir şekilde değerlendirilebilmesi gerekmektedir. Buda genellikle uzman bilgisini gerektirmektedir [1].

Makine öğrenmesi yöntemlerine kıyasla çok katmanlı bir yapıdan oluşan derin öğrenme metotları, verilerden özellik çıkarımı ve dönüşümü işlemleri sırasında doğrusal olmayan birçok işlem katmanını kullanmaktadır. Bu sayede hiyerarşik bir düzen oluşturularak üst düzey özellikler alt katmandaki özelliklerden elde edilmektedir. Burada temel öğrenme prensibi verinin temsilinden öğrenmeye dayanmaktadır. Ayrıca son yıllarda derin öğrenmenin birçok alanda başarılı bir şekilde uygulanmasının en önemli sebebi de ihtiyaç duyulan veri büyüklüğünün kolayca elde edilebilir olmasından kaynaklanmaktadır [2].

1.1. TEZİN AMACI ve KAPSAMI

Bu tez çalışması, son yıllarda yapay zekanın gelişiminden faydalanarak görüntü işleme ve derin öğrenme teknolojilerine odaklanmaktadır. Bu doğrultuda beyin, göğüs ve cilt bölgelerinde bulunan tümörlerin tespiti ve sınıflandırma çalışması yapılmıştır.

Özellikle son yıllarda birçok alanda başarıyla uygulanan yapay zekâ teknolojileri bugün tıp alanında teşhis ve tedavi süreçlerinde başarıyla uygulanmaya başlandığı görülmektedir. Bunun en önemli kaynağı yapay zekâ teknolojilerinin alt sınıfında kabul edilen ve beslendiği yer olan veri madenciliğinin ve onun bir kolu olan makine öğrenmesi algoritmalarının örüntüler arasında ki görünmeyen ilişkileri ortaya çıkartabilme yeteneği sayesindedir. Bu sayede belirsizliklerin olduğu süreçlerde ve değişkenlerin birbirinden ayırt edilebilmesi gereken hassas durumlarda önemli başarılar sağlanabilmektedir. Hastalık tanısında, birçok belirsizliğin olduğu durumlarda ve özellikle sınıfların birbirinden ayırt edilebilmesi çok güç olan durumlarda yapay zekâ önemli başarılara ulaşmaktadır.

Tıbbi görüntü işlemede yapay zekanın başarılı olmasında ki en önemli güç verilerin etkin şekilde kullanılmasından kaynaklanmaktadır. Özellikle son iki yılda yaşanan koronavirüs (COVID-19) salgını gibi radyolojik görüntülerin sık kullanıldığı hastalıklarda uzmanlara düşen sorumluluklar artmış, bununla birlikte radyolojik görüntülerin incelenmesi ve analizi oldukça zor ve zaman gerektiren bir hal almıştır. Sadece salgın hastalıklarda değil, X-ray görüntülerinin ya da Bilgisayarlı Tomografi (BT) gerektiren beyin tümörleri, akciğer enfeksiyonları, meme kanseri ve cilt kanseri gibi birçok hastalıkla birlikte iş yükü oldukça ciddi bir seviyeye ulaşmıştır. Ayrıca radyoloji alanı görsel dikkatin çok fazla olduğu, aynı zamanda belirsizlikler altında karar vermeyi içerdiğinden yoğun çalışma ve iş yükü altında uzmanların hata yapmaları kaçınılmaz bir hale gelmektedir.

Bu tez çalışmasında derin öğrenme metotları kullanılarak üç farklı hastalığa ait görüntüler için sınıflandırma ve teşhis koyma uygulaması gerçekleştirilmiştir. Bu kapsamda uygulanan ilk bölüm, beyin tümörlerini sınıflandırmada yaşanan sorunları ortadan kaldırmak için, beyin tümörlerine ait üç boyutlu Manyetik Rezonans (MRG) görüntülerinden tümör ve doku özelliklerinin sınıflandırılması, hastalıklı ve sağlıklı dokuların birbirinden kolayca ayırt edilmesi için sınıflandırma amacıyla modeller geliştirilmiştir. Önerilen yöntemde Evrişimsel Sinir Ağları (CNN) mimarilerinden faydalanılarak özellik çıkartma, birleştirme ve sınıflandırma işlemleri uygulanmış ve farklı mimarilere ait sonuçlar karşılaştırılmıştır. Performans ölçüm kriterleri ve literatürde yapılan benzer çalışmalar ile kıyaslandığında yüksek doğruluk veren sonuçlara ulaşılmıştır.

Tez kapsamında uygulanan ikinci bölümde özellikle Covid-19 hastalığı sonrası önemi daha fazla ortaya çıkan akciğer görüntülerinden derin öğrenme yöntemleri kullanılarak göğüs tümörü tanısı yapılmasıdır. Bu amaçla X-ray görüntüleri kullanılmıştır. Derin öğrenme mimarilerinden farklı ön eğitimli CNN mimarileri eğitilerek tümörlü yapıların sınıflandırılması yapılmıştır.

Birden fazla parametre ve ölçü değerleri farklı algoritmalar ile sınıflandırma çalışması yapılarak oluşturulan hibrit model birbirinden farklı veri kümeleriyle analiz edilmiştir.

Tez kapsamında yapılan ilk iki çalışmada beyin ve akciğer tümörü tespiti ve sınıflandırması yapılırken veri olarak hastalıklara ait X-ray, tomografi ve MR görüntüleri kullanılmaktadır. Yapılan son çalışmada ise cilt kanserine ait görüntülerden hastalığın çeşidi ile ilgili sınıflandırma çalışması yapılmıştır. Cilt kanserine ait vakalar iki farklı kategoride sınıflandırılmış, beyin ve akciğer görüntülerinde kullanılan vakalar ise 4 farklı kategoride sınıflandırılmıştır. CNN algoritmaları kullanılarak doğruluk kriterinin yüksek olduğu hassasiyeti yüksek bir model önerilmiştir. Kullanılan model, literatürde yapılan benzer çalışmalarla karşılaştırıldığında ve kullanılan metrik ve parametre değerleri göz önüne alındığında yüksek başarı oranı sağlamıştır.

Üç farklı hastalığa ait veriler farklı algoritmalar ve parametre değerleri kullanılarak oluşturulan modellerde yüksek başarı oranlarına ulaşılmaya çalışılmıştır. Tez çalışması kapsamında son olarak CNN algoritmalarından farklı olarak elde edilen sonuçlar topluluk öğrenmesi metodu ile modellenmiş ayrıca klasik makine öğrenmesi teknikleriyle de sınıflandırma çalışması yapılarak en yüksek başarım oranları hesaplanmıştır. Doğruluk değerleri ve karmaşıklık matrisleri bulgular kısmında ayrıca hesaplanmış ve gösterilmiştir.

1.2. TEZİN ORGANİZASYONU

Bu tez çalışması altı bölümden oluşmaktadır. Tezin organizasyon şeması şu şekildedir. Birinci bölüm tezin giriş bölümü olup, tezin amacını, kapsamını ve yapılmış olan çalışmayı kısaca özetlemektedir.

İkinci bölümde, kavramsal çerçeve içerisinde derin öğrenmenin temel problemlerinden olan görüntü işleme ve sınıflandırma konusu incelenmiştir. Geleneksel makine öğrenmesi sınıflandırıcıları, evrişimsel sinir ağı modelleri, aktivasyon fonksiyonları ve literatürde bu alanda yapılan çalışmalar incelenmiş ve başarı ölçüm metrikleri anlatılmıştır.

Tezin üçüncü bölümü olan yöntem kısmında kullanılan veri setleriyle ilgili bilgiler verilmiştir. Bununla birlikte eğitim aşamasında uygulanan parametre optimizasyonu ve modelin bilgisayar yazım dili olan Python hakkında açıklayıcı bilgiler verilmiştir. Son olarak değerlendirme kriterlerinden bahsedilmiş ve burada bulunan metrik değerlerinin ne anlama geldiği açıklanmıştır.

Dördüncü bölümde, veri kümelerine ait sınıflandırma değerlerine ait bulgulara yer verilmiştir. Sınıflandırma işlemi, her bir hastalık veri kümesi için ayrı ayrı yapılmış olup dört farklı CNN

algoritmasında en iyi çözüm bulunmaya çalışılmıştır. Ayrıca bu bölümde topluluk öğrenmesi ve makine öğrenmesi sınıflandırıcılarıyla yapılan modellerden bahsedilmiş ve elde edilen sonuçlar grafik ve tablolarla birlikte verilmiştir. Elde edilen sonuçlar analiz edilmiş, önerilen yöntem literatürdeki benzer çalışmalar ile kıyaslanmıştır.

Beşinci bölümde elde edilen sonuçlar karşılıklı olarak analiz edilmiş ve tartışılmıştır. Bu bölümde eğitim, test ve doğrulama işlemleri ayrı ayrı incelenmiş, tavsiye edilen modele ait analiz sonuçları verilmiştir. Elde edilen sonuçlar literatürdeki benzer çalışmalara ait sonuçlarla karşılaştırılmıştır.

Tezin son bölümünde yapılan tüm çalışmaların sonuçları verilmiş ve ayrıntılı olarak açıklanmıştır. Yöntem, bulgular ve tartışma bölümlerinde verilerin detaylı analizi yapıldığı için sonuç bölümünde tekrar üzerinde durulmamıştır. Nihai sonuç olarak önerilen model hakkında bilgiler ve sonuçlar verilmiştir. Bu bölümde tezin genel bir değerlendirilmesi yapılmıştır.

2. KAVRAMSAL ÇERÇEVE

Görüntü işleme resimsel görüntüler, videolardan alınan kesitler, nesnelerin tanımlanması ve anlamasını sağlamaya odaklanan yazılım bilimidir. Yapay zekâ ürünü olan görüntü işlemenin temel amacı insana has yetenekleri kopyalayabilen ve bunu kendi kendine öğrenebilen sistemler oluşturmaktır. Ayrıca görüntü işleme uygulamaları, canlılardaki görme işleyişini taklit ekmek için makine öğrenimi ve derin öğrenme mimarilerini kullanmaktadırlar [3]. Günümüzde birçok görüntü işleme tekniklerinden faydalanılmaktadır. Özellikle makine ve derin öğrenme yöntemleri kullanılarak yapılan görüntü işleme çalışmaları, görüntülerden sayısal analizler yapılarak elde edilmektedir. Sayısal görüntü işleme tekniklerinin çoğu görüntünün sabit olduğu durumlar için geçerlidir. Kullanıldıkları alanlar göz önüne alındığında; Tarım alanlarında kullanılan drone görüntülerinden hasat çalışmalarını izlemek, spor müsabakalarında nesne algılama ve strateji analizi, yüz tanıma sistemleri, metin madenciliği ve robotik kodlama ve sağlık hizmetlerinde tomografi görüntülerinden hızlı tanı koymaya yardımcı birçok alanda kullanılmaktadır.

Sağlık alanında uygulanan tıbbi görüntü işleme hızlı tanı koymak için yaygın şekilde kullanılan bir yöntemdir. Teknolojinin gelişmesiyle birlikte tüm tıbbi görüntüler büyük veri olarak tanımlanmakta ve yüksek büyüklükteki dosyaları saklama kapasitesine sahip bulut sistemlerde saklanmaktadırlar. Görüntü işleme yöntemleri genellikle; görüntü zenginleştirme, filtreleme, bölütleme, örüntü tanıma, sınıflandırma ve görüntü sıkıştırma olarak adlandırılan adımlardan oluşmaktadır.

Tezin bu bölümünde önerilen yöntemlerle ilgili literatür bilgisi, kullanıldıkları alanlar ve problemlerin çözümünde kullanılan başarı ölçütlerine yer verilmiştir.

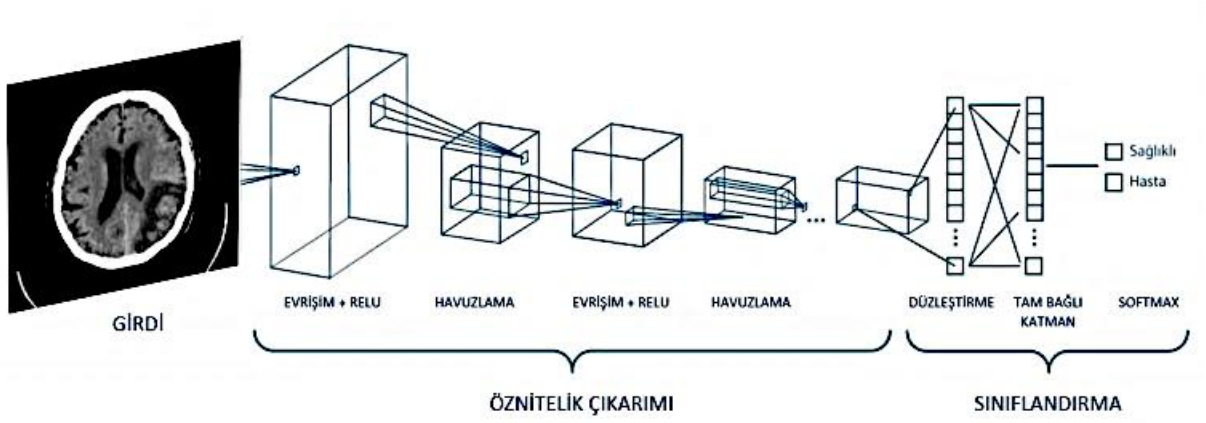
2.1. GÖRÜNTÜ SINIFLANDIRMA

Görüntü sınıflandırılması, literatürde bilinen görsel tanıma problemlerinin başında gelmektedir. Bir görüntü ya da video kesitinden belirlenmiş bir bölge ya da bir nesnenin sadece sınıfının ayırt edilmesi, sınıflandırma işlemi olarak adlandırılmaktadır. Bu ayırt etme süreci, birbirleriyle ilişkili ya da bağımsız görüntülerin kendi sınıflarına dahil edilmesini sağlama sürecidir.

Görüntü sınıflandırma biyomedikal görüntüleme, araç takip sistemleri, görsel analiz, uzaktan algılama, robotik navigasyon gibi insan yaşamının her alanında kullanılan bir teknolojidir [4]. Görüntü sınıflandırma yöntemlerinin çalışma prensibini genel hatlarıyla açıklamak gerekirse; önceden etiketlenmiş bir veri setinden bu veri kümesini en iyi şekilde açıklayan karakteristik özelliklerin seçimi ile elimizde bulunan görüntü desenlerinin hedef desenlerle karşılaştırarak yeni görüntüyü önceden belirlediğimiz sınıflara ayırmış olmayı amaçlamaktadır. Görüntü sınıflandırma yaparken veri setinin önceden etiketlenmesi yani sınıf etiketli veri seti kullanılması ya da görüntülerin herhangi bir sınıfa ait olduğu bilgisi olmaksızın alınarak görüntü özelliklerine göre doğal bir şekilde gruplara ayırılması işlemi makine öğrenmesi yöntemlerinin denetimli ya da denetimsiz öğrenme yöntemi olarak literatürde tanımlanmaktadır [5].

2.1.1. Evrişimsel Sinir Ağı (CNN) Mimarileri

Görüntü işleme alanında yapılan çalışmalara bakıldığında Evrişimsel Sinir Ağları (CNN) bugüne kadar birçok problemin çözümünde en çok tercih edilen yöntemlerin başında gelmektedir. CNN algoritmaları ileri beslemeli yapay sinir ağları olmakla birlikte özellikle iki boyutlu verilerin işlenmesinde oldukça başarılı sonuçlar vermektedirler. Şekil 2.1'de CNN mimarilerinin genel yapısı basitçe ifade edilmektedir.



Şekil 2.1: CNN Mimarilerinin Genel Yapısı [6]

CNN mimarileri temel olarak üç katmandan oluşur. Evrişimli Katman (Convolutional Layer), Havuzlama Katmanı (Pooling Layer) ve Tam Bağlantılı Katman (Fully Connected Layer). CNN ile birlikte görüntüler ham girdi olarak ağ yapısına doğrudan aktarılabilirler. Bu şekilde standart öğrenme algoritmalarında ki özellik elde etme prosedürüne gerek kalmamaktadır. CNN mimarisi ağda bulunan parametre değerlerini bir takım uzaysal ilişkiler kullanarak azaltmakta ve standart geri yayma algoritmalarını geliştirmektedir. Son yıllarda iş istasyonu bilgisayarların

CPU ve GPU'larının hızla gelişmesiyle birlikte hesaplama teknikleri CNN'leri daha verimli bir şekilde eğitmek için kullanılmaktadır [6].

Şekil 2.1'de CNN yapısı girdi verisi olarak görüntüleri kullanan bir derin öğrenme algoritması olarak gösterilmektedir. Burada görüntü özelliklerinin birbirinden ayırılması başka bir deyişle sınıflandırma işlemi gerçekleştirilmektedir. CNN algoritmalarının diğer sınıflandırma algoritmalarından farklı olarak öğrenme yeteneğine sahip olmalarından dolayı CNN mimarisinde kullanılacak veriler için gerekli ön işleme işlemlerini diğer sınıf algoritmalarına göre oldukça kısa sürede yapmaktadırlar [7].

Evrişim katmanı görüntüler üzerinde işlem yapan ilk katmandır. Temel amacı girdi görüntüsünden öznitelikleri çıkarmaktır. Görüntüler içlerinde değerler taşıyan piksellerden oluşan matrislerdir. Burada evrişim girdi verisinin küçük karelerini kullanarak görüntü özelliklerini öğrenir. Evrişimsel ağlar mimarisinde arka arkaya gelen evrişim katmanları arasında düzenli olarak bir havuzlama katmanı eklenebilir. Bazı çalışmalarda havuzlama katmanın yanı sıra örnekleme katmanlarının olduğu modellerde bulunmaktadır. Havuzlama katmanının temel amacı, çok büyük görüntüler olduğunda parametre sayısını azaltarak görüntüyü küçültmektir. Burada boyutsallık azaltılmasına rağmen önemli bilgiler muhafaza edilmektedir. Bu aşamadan sonra tam bağlantılı katman olan çıktı katmanına, yani giriş görüntüsünün üst düzey özelliklerinin temsil edildiği son kısma gelinmektedir. Bu katman genellikle tüm sinir ağlarında bulunur ve çıktı katmanının boyutlarını ve şekil özelliklerini kontrol etmek için kullanılmaktadır [8].

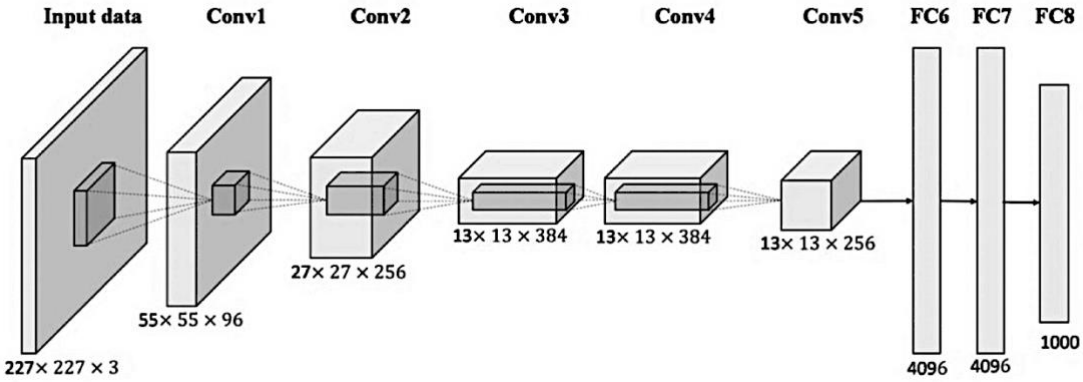
2.1.2. AlexNet Mimarisi

Evrişimsel sinir ağlarının yakaladığı başarı yüzdeleri ile birlikte ilk defa 2012 yılında bir görüntü sınıflandırma yarışması olan Large-Scale Visual Recognition Challenge (ILSVRC) adı duyulan AlexNet, bu yarışmayı kazanan ilk CNN mimarileri arasındadır. Bu yarışmada AlexNet mimarisi Alex Krishevsky ve arkadaşları tarafından oluşturulan, 1000 sınıftan oluşmuş ve yaklaşık 1,2 milyon görüntüyü en doğru şekilde sınıflandırmışlardır. Burada yakaladıkları başarı sayesinde yarışmayı kazanmışlar ve her yıl düzenlenen görüntü sınıflandırma yarışmasına CNN mimarisi tabanlı çalışmalar çoğalarak katılımlar devam etmiştir [9].

AlexNet mimarisi 25 katmandan oluşmaktadır. Bu konvolüsyonel sinir ağında 5 adet konvolüsyon katmanı, 3 adet maxpool katmanı, 2 adet dropout katmanı, 3 adet tam bağlı katman, 7 adet relu katmanı, 2 adet normalizasyon katmanı, softmax katmanı, giriş ve sınıflandırma katmanlarından oluşmaktadır. Giriş katmanında yer alan görüntü 227x227x3

boyutlarında olmakta ve son katmanda sınıflandırma işlemi yapılarak giriş görüntüsünde ki sınıflandırma sayısı değeri verilmektedir [10].

Şekil 2.2'de AlexNet'e ait katmanlar gösterilmektedir.



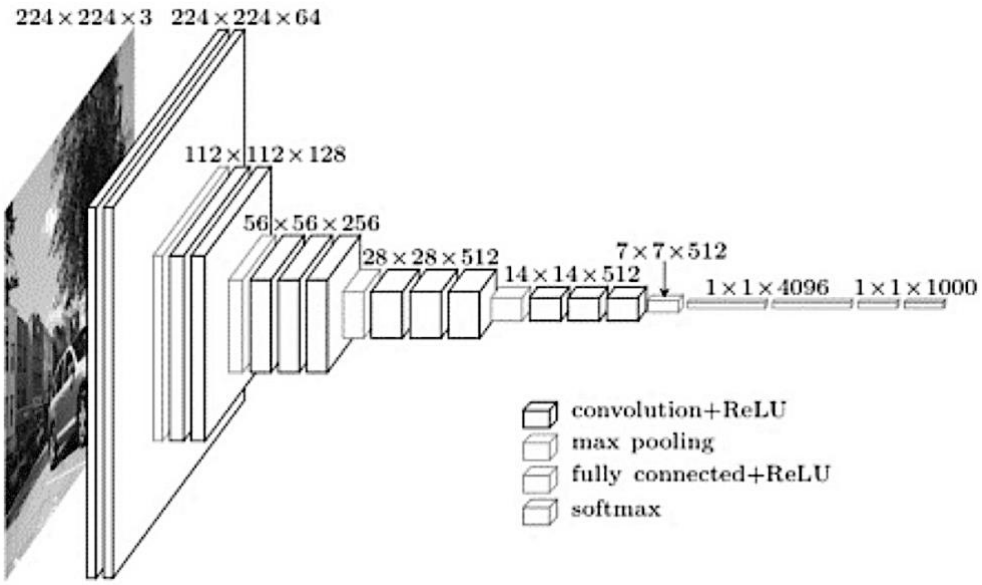
Şekil 2.2: AlexNet Derin Öğrenme Algoritması [10]

Krishevsky'nin AlexNet'i ise 11 katmandan meydana gelmektedir. Bunların ilk iki katmanı evrişim, maksimum havuzlama ve normalizasyon daha sonra üç ve dördüncü katmanlar tekrar evrişim, beşinci katman evrişim ve maksimum havuzlama, altıncı ve yedinci katmanlar tam bağlantılı katman ve son katman ise sınıflandırma işlemini yapan softmax'dır.

2.1.3. VGG Mimarisi

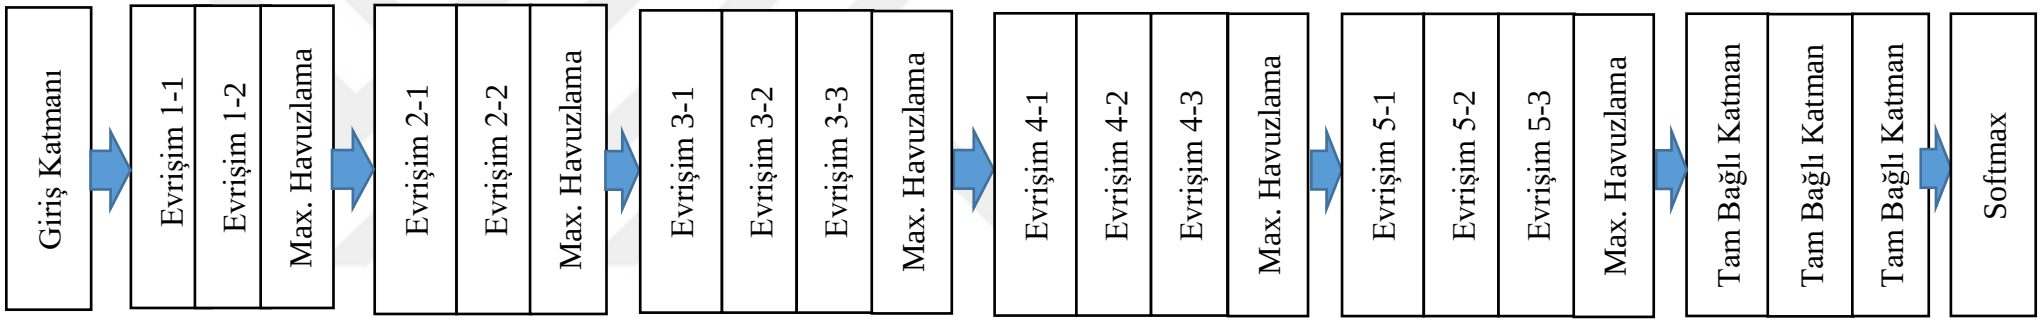
VGG (Visual Geometry Group) bir derin öğrenme algoritması olup özellikle AlexNet'in başarısından sonra ortaya çıkan birçok ağ modelinden bir tanesidir. Oxford üniversitesi Görsel Geometri Grubu tarafından ILSVRC-2014 yarışmasında daha yüksek başarı yüzdeleri elde etmek amacıyla kullanılan 13 konvolüsyonel, 3 tam bağlı katmandan oluşan bir ağdır. Ağ yapısı içerisinde Maxpool, Relulayer, Fullconnectedlayer, Dropoutlayer ve Softmaxlayer katmanlarıyla birlikte toplamda 41 katman yer almaktadır. Bu mimaride girdi katmanında yer alacak görüntü 224x224x3 boyutunda olmakla birlikte son katman yine sınıflandırma katmanıdır [11].

VGG mimarisi içerisinde çok fazla hiper parametre yerine daha sade bir yapı kullanmaktadır. Bu sayede sahip olduğu sinir ağı mimarisini de sadeleştirmektedir. Literatürde bulunan VGG16 ve VGG19 ifadeleri katman sayılarından ayırt edilmektedir.



Şekil 2.3: VGG Derin Öğrenme Algoritması [10]

2014 yılında düzenlenen yarışmada sunulan bu model, 1000 sınıfa ait 14 milyondan fazla veri kümesine sahip olan ImageNet içerisinde %92 oranında başarıya ulaşmış, bununla birlikte burada her evrişim katmanından sonra aktivasyon fonksiyonu olarak doğrultulmuş doğrusal birim (ReLU) kullanılmıştır. VGG mimarisi 11x11 ve 5x5 olan filtreleri daha küçük ölçekli katmanlarla değiştirmiştir. Burada amaç küçük boyutlu filtrelerin kullanılmasını sağlamak ve parametre sayısını azaltarak düşük bir hesaplama karmaşıklığının önüne geçmektir. Oluşturulan mimari beş bloktan oluşmakta, ilk iki blok iki evrişim katmanına sahip olmakla birlikte her bir katmanın arkasından R aktivasyonu ve maksimum havuzlama katmanı gelmektedir. Son kısımda üç evrişim katmanı bulunmakta ve yine her biri için ReLU aktivasyonu ve maksimum havuzlanma katmanı bulunmaktadır [12].



Şekil 2.4: VGG Mimarisi [13]

Bir önceki bölümde bahsettiğimiz AlexNet mimarisinde CNN algoritmalarının görüntü kümeleri içeren veri setlerini nasıl eğittiğini ve modelin performansını nasıl geliştirdiği açıklanmıştır. AlexNet modelinin karmaşık özellikleri algılanmadan önce, görüntü üzerindeki özelliklerin nasıl algılanacağının öğrenilmesi gerekmektedir. Bunun sayesinde VGG modelinin başarı yüzdesi çok daha yüksek olabilmektedir.

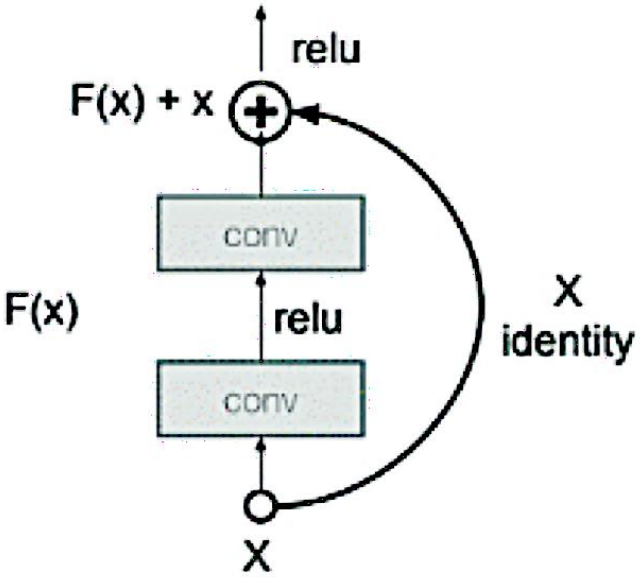
Gerçek dünya uygulamalarında yüksek performans veren sonuçlar elde etmek için bazen sistemin eğitimi günlerce sürebilmekte ve binlerce görüntü gerekebilmektedir. Bu yüzden genel olarak transfer öğrenme yöntemiyle önceden eğitilmiş herhangi bir modeli kendi veri kümemizde eğiterek öğretmek bizim için daha kolay bir yöntem olabilmektedir.

Görüntü sınıflandırma, doğal dil işleme ve metin sınıflandırma dahil olmak üzere birden fazla sınıflandırma problemi çözümünde derin öğrenme yöntemlerinin benzer yaklaşımları kullanılmaktadır. Önceden eğitilmiş bir modeli başka bir göreve uyarlama yeteneği inanılmaz derecede değerlidir. Bu teknik çoğu derin öğrenme yöntemleriyle çözülen birçok problemde kullanılmakla birlikte doğruluk oranlarının yüksek olması ve hızlı çözülebilir olmasından dolayı tercih edilmektedir.

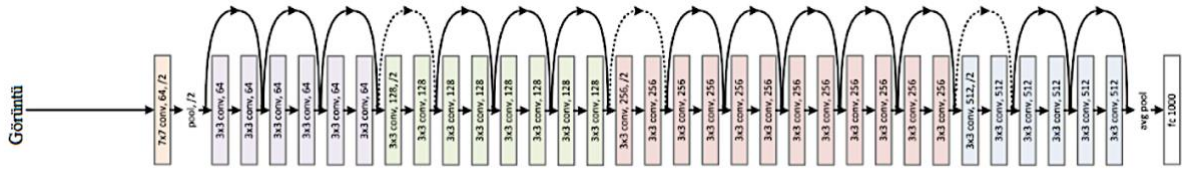
2.1.4. ResNet50 Mimarisi

ResNet mimarisi, VGG ve AlexNet gibi mimarilerden farklı bir yapıya sahiptir. ResNet mikro mimari modül yapısı ile diğer yapılardan ayrışmakla birlikte bazı katmanlar arası geçişleri göz ardı edilebilir ve alt katmana geçiş işlemleri yapılabilmektedir. Bu özellikleriyle ResNet mimarisi başarı oranlarını daha yüksek seviyelere çıkartmayı başarmıştır [14].

ResNet, ILSVRC yarışmasının 2015 yılındaki kazananıdır. CNN'de öğrenme kavramını tanıtarak 152 katmanlı bir konvolüsyonel model geliştirmiş ve derin ağların eğitimi için etkili bir yöntem tasarlamıştır. ResNet bu özelliği ile insan performansının üzerinde başarı gösteren ilk mimari olmuştur. ResNet 'in klasik modellerden ayrılan en önemli özelliği doğrusal ve ReLU katmanları arasında kalan kalıntı değerlerinin, sonraki katmanları besleyen blokların eklenmesiyle birlikte daha hızlı bir model oluşturulacağı düşünülmüştür. Her kalıntı bloğunda iki adet 3x3 konvolüsyon filtresi bulunmakta ve adım sayısı 2 olarak seçilmektedir. Modelin derinleştikçe optimize edilebilmesi daha zor bir duruma geleceğinden dolayı ResNet için en doğru çözüm aktivasyon fonksiyonunu bir katmandan alıp başka bir katmanı beslemeye izin veren atlama bağlantısını kullanmaktır. Bunu kullanmak için derin ağların çok fazla eğitilmesi ve vanishing gradient sorununun ortadan kaldırılması gerekmektedir [15].



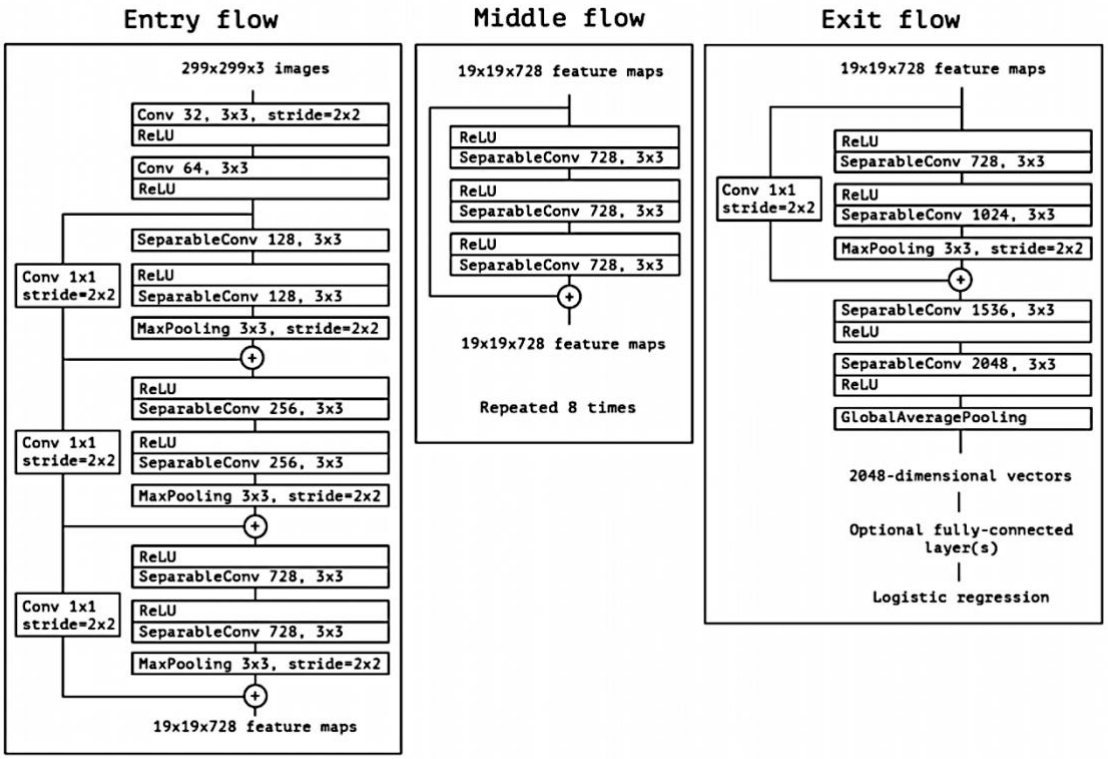
Şekil 2.5: ResNet Artık Blok [16]



Şekil 2.6: ResNet Mimarisi [16]

2.1.5. Xception Mimarisi

2017 yılında Francois Chollet tarafından önerilen Xception mimarisinin temeli derinlemesine ayrılabilen evrişim katmanlarına dayanmaktadır [17]. Bu mimari Inception mimarisindeki ‘‘Inception’’ modülleri ile derinlemesine ayrılabilen evrişimlerinin değiştirilmiş bir versiyonudur [18]. Xception mimarisi tamamen evrişimsel bir sinir ağı mimarisi olmakla birlikte 36 evrişim katmanına sahiptir. Bu katmanlar, ilk ve son modüller hariç olmak üzere hepsinin çevresinde doğrusal bağlantılara sahip 14 modül halinde yapılar bulunmaktadır [19]. Şekil 2.7’de görüleceği üzere Xception mimarisi üç ana bölümden oluşmaktadır. Bunlar; giriş akışı, 8 kez tekrarlanan orta akış ve çıkış akışı olarak adlandırılmaktadır.

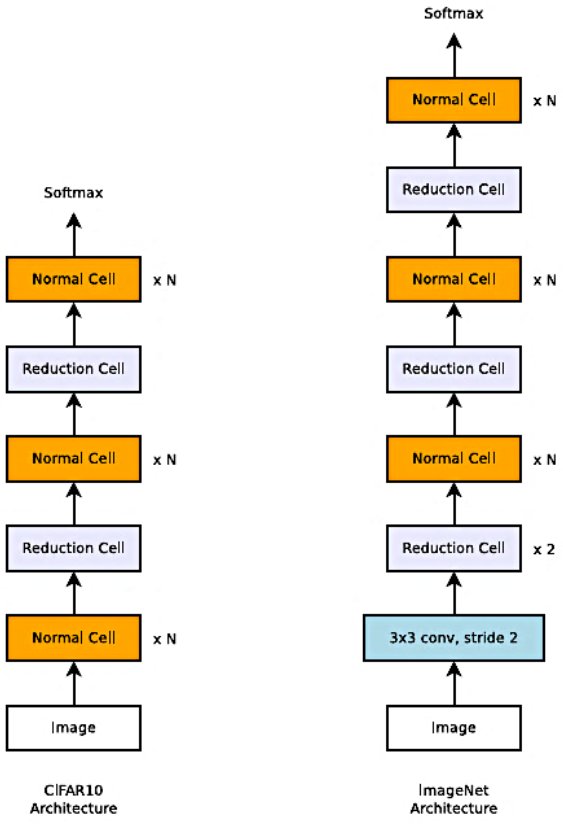


Şekil 2.7: Xception Mimarisi [19]

2.1.6. NASNet Mimarisi

NASNet (Neural Search Architecture Network) temel yapısı ve ilkeleri AlexNet gibi standart mimarilere sahip diğer algoritmalardan farklılıklar göstermektedir. Google Brain tarafından önerilen bu model, pekiştirmeli öğrenme yöntemi ile iyileştirilmiş ayrılabilir evrişim ve ortak basit bloklardan oluşmaktadır. NASNet'in kullanım alanı ve daha önce yapılan çalışmalar göz önüne alındığında kullanıcılar, bir veri kümesinde yapı bloğu aramayı ve ardından bloğu daha büyük bir veri kümesine aktarmayı önermektedirler. Özellikle veri kümelerinde en iyi evrişimsel katmanı veya hücreyi aramaktadırlar [20].

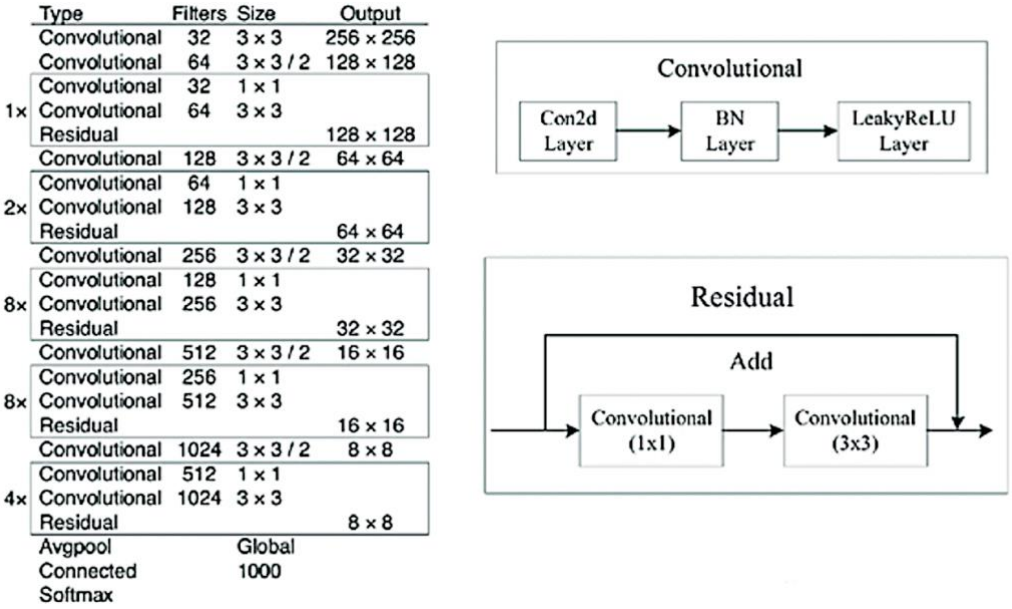
CIFAR-10 veri setinde sınıf başına 5000 görüntü, 10 sınıfta toplam 50000 eğitim görüntüsü ve 10000 test görüntüsü vardır. Veri seti 10000 görüntü içeren bir test ve beş eğitim grubuna bölünmüştür. Test grubu her sınıftan rastgele seçilmiş 1000 görüntü içermektedir. Bununla birlikte eğitim grupları her sınıftan 5000 görüntü içermektedir. Sonuç olarak buradaki hücreleri hücrenin birden çok kopyasıyla bir araya getirerek ImageNet'te uygulanmaktadır. NASNet modeli en sonunda küçük boyutlu modeller ve daha az karmaşıklık ile nihai sonuçlara ulaşmaktadır [21].



Şekil 2.8: NASNet CIFAR10 ve Imagenet Mimarisi [21]

2.1.7. DarkNet53 Mimarisi

DarkNet mimarisi C programlama dilinde CUDA (Compute Unified Device Architecture) eklentisi ve uzantısıyla yazılmış açık kaynaklı bir sinir ağıdır. DarkNet53 genellikle YOLO (You Only Look Once) hedef tespit ağının üçüncü sürümü olan YOLOv3'de kullanılan temel özellikleri ortaya çıkarma ağıdır. Bu model ResNet ve YOLOv2 ağlarını, 1x1 ve 3x3 boyutlarında evrişim katmanları kullanarak DarkNet temel çıkarım modelini oluşturmaktadır. Burada evrişim katmanı, Sızıntı ReLU (Leaky ReLU) ve yığın normalleştirme katmanı ile birlikte en küçük bileşenleri bir araya getirmektedirler. Model toplamda 53 tanesi evrişim ağı olmak üzere 75 katmandan meydana gelmektedir [22].



	Type	Filters	Size	Output
	Convolutional	32	3 × 3	256 × 256
	Convolutional	64	3 × 3 / 2	128 × 128
1×	Convolutional	32	1 × 1	
	Convolutional	64	3 × 3	
	Residual			128 × 128
	Convolutional	128	3 × 3 / 2	64 × 64
2×	Convolutional	64	1 × 1	
	Convolutional	128	3 × 3	
	Residual			64 × 64
	Convolutional	256	3 × 3 / 2	32 × 32
8×	Convolutional	128	1 × 1	
	Convolutional	256	3 × 3	
	Residual			32 × 32
	Convolutional	512	3 × 3 / 2	16 × 16
8×	Convolutional	256	1 × 1	
	Convolutional	512	3 × 3	
	Residual			16 × 16
	Convolutional	1024	3 × 3 / 2	8 × 8
4×	Convolutional	512	1 × 1	
	Convolutional	1024	3 × 3	
	Residual			8 × 8
	Avgpool		Global	
	Connected		1000	
	Softmax			

Şekil 2.9: DarkNet53 Mimarisi [23]

2.1.8. EfficientNet Mimarisi

EfficientNet uygulayıcıları daha iyi bir performans elde etmek ve ağ performansını artırmak için birleşik ölçeklendirme yöntemini benimsemişlerdir. Bu ağ yapısı ve sahip olduğu özellikleri sayesinde ağın genişliğini, derinliğini ve görüntü çözünürlüğünü daha iyi duruma getirmeyi önermektedir. Burada tam anlamıyla bir başarı söz konusu olmamakla birlikte ağda bulunan görüntü boyutlarının nasıl dengeleneceği de hesaplanmamıştır. Gözlem yapılarak ve bir iyileştirme katsayısı kullanılarak tüm genişlik, derinlik ve çözünürlük boyutlarını en iyi şekilde ölçekleyen yeni bir ölçeklendirme sistemi önerilmiştir [24].

Üç temel adımda EfficientNet 'in nasıl verimli çalıştığını şu şekilde açıklayabiliriz.

a) **Depthwise Evrişim + PointWise Evrişim:** Orijinal evrişimi iki aşamaya bölerek hesaplama maliyetini asgari doğruluk kaybıyla önemli ölçüde azaltmaktadır.

b) **Ters Çevrilmiş ResNet:** Bloklar önce kanalları genişleten daha sonra bunları sıkıştıran bir katmandan oluşmaktadır. Böylelikle daha az kanala sahip katmanlar atlanarak bağlanmaktadır.

c) **Lineer Darboğaz:** ReLU 'da bulunan bilgi kaybını önlemek amacıyla her bloktaki son katmanın lineer aktivasyonunu kullanmaktadır.

EfficientNet 'in genel yapısında MobileNetV2 olarak da bilinen ters çevrilmiş darboğaz evrişimi (MBconv) blokları kullanılmıştır. Burada bulunan bloklar öncelikle kanalları genişleten daha sonra sıkıştıran bir katmandan meydana gelmektedir. Bunun sonucunda daha az kanala sahip katmanlar bağlanmaktadır. Farklı ağ yapıları, modelleri ve parametre değerlerine rağmen tüm EfficientNet modelleri farklı katsayılar kullanılarak temelde EfficientNet-B0'dan ölçeklenmektedir [25]. Şekil 2.10'da EfficientNet'e ait ağ yapısı gösterilmektedir.

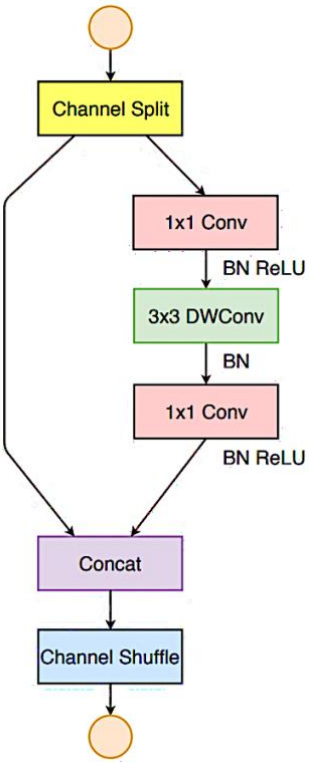


Şekil 2.10: EfficientNet Mimarisi [26]

2.1.9. ShuffleNetv2 Mimarisi

ShuffleNetv2 mimarisi darboğaz bir yapı olmakla birlikte çok sınırlı bir hesaplama gücüne sahip özel olarak tasarlanmış bir evrişim mimarisidir. Diğer CNN mimarileriyle karşılaştırıldığında daha düşük parametre değerlerine ve karmaşıklığa sahip olduğu görünmektedir [27].

Şekil 2.11'de ShuffleNetv2 mimari bloğu gösterilmektedir. Her saniye kayan nokta işlemleri metrik işlemleri yerine hız ile optimize edilmiş ağlar tarafından doldurulur. Her ünitenin başında kanallara giriş için iki ayrı kol bulunmaktadır. Evrişim işleminden hemen sonra dallar birleştirilir. Bu şekilde kanal sayısı aynı kalmaktadır. Bu ağ yapısında bulunan kanal karıştırma işlemi daha sonrasında iki dal arasındaki bilgi alışverişini yönetmek içinde kullanılmaktadır [28].



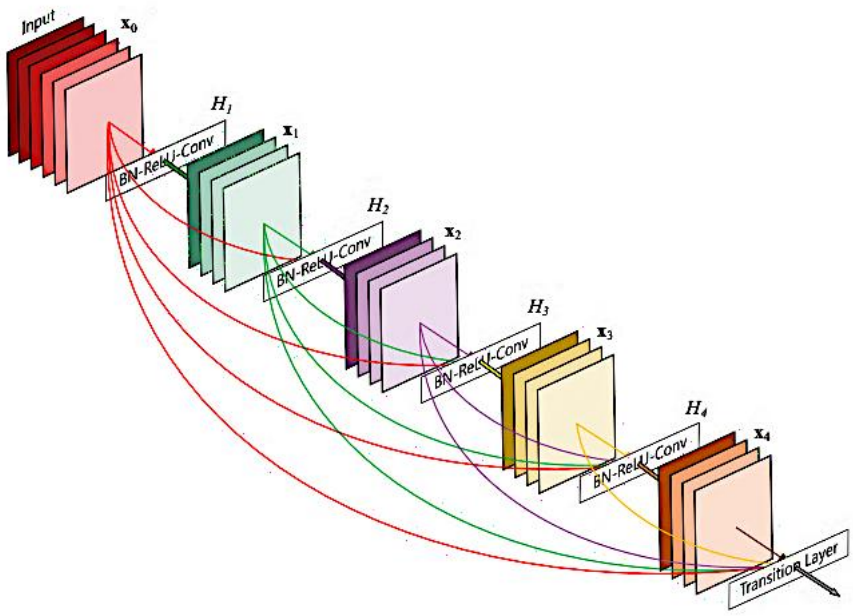
Şekil 2.11: ShuffleNetv2 Diyagramı [29]

ShuffleNetv2 mimarisi başarı oranı yüksek sonuçlara hızlı bir şekilde ulaşabilen yapılar önermektedir. Farklı karmaşıklık düzeylerinde bellek ve kod optimizasyonu gibi ağ tasarımı için önemli yapıları yüksek hızda ve doğrulukta çalıştırmaktadır.

2.1.10. DenseNet Mimarisi

Sinir ağları eğitimi sırasında evrişim ve alt-örnekleme işlemleri nedeniyle özellik çıkarım haritalarında azalmalar meydana gelmektedir. Bununla birlikte katmanlar arası geçişlerde görüntü özelliklerinde kayıplar yaşanmaktadır. Görüntü özelliklerinin daha etkin bir şekilde kullanılabilmesi için DenseNet mimarisi geliştirilmiştir. DenseNet, özellik yapısı itibariyle her katmanı ileriye doğru diğer katmanlara bağlamaktadır. Bu mimari de her katman kendinden önceki tüm katmanların özelliklerini girdi olarak kullanmakta ve kendinden sonra gelen tüm katmanlara da bütün özellikleri girdi olarak vermektedir. DenseNet'in bir diğer önemli özelliği, özellik yayılımını sağlamak için parametre sayısını azaltmasıdır. DenseNet transfer fonksiyonunu en iyi kullanan mimarilerden birine sahip olmakla birlikte özellik yapısının ağ içerisinde yayılım oranı oldukça yüksektir [30].

Şekil 2.12'de DenseNet mimarisi verilmiştir. $[X_0, X_1, X_2, X_3]$ katmanları özellik birleşimi için kullanılmakta; H_1 ise özellik bilgilerini işlemek için transfer fonksiyonu olarak kullanılmaktadır.



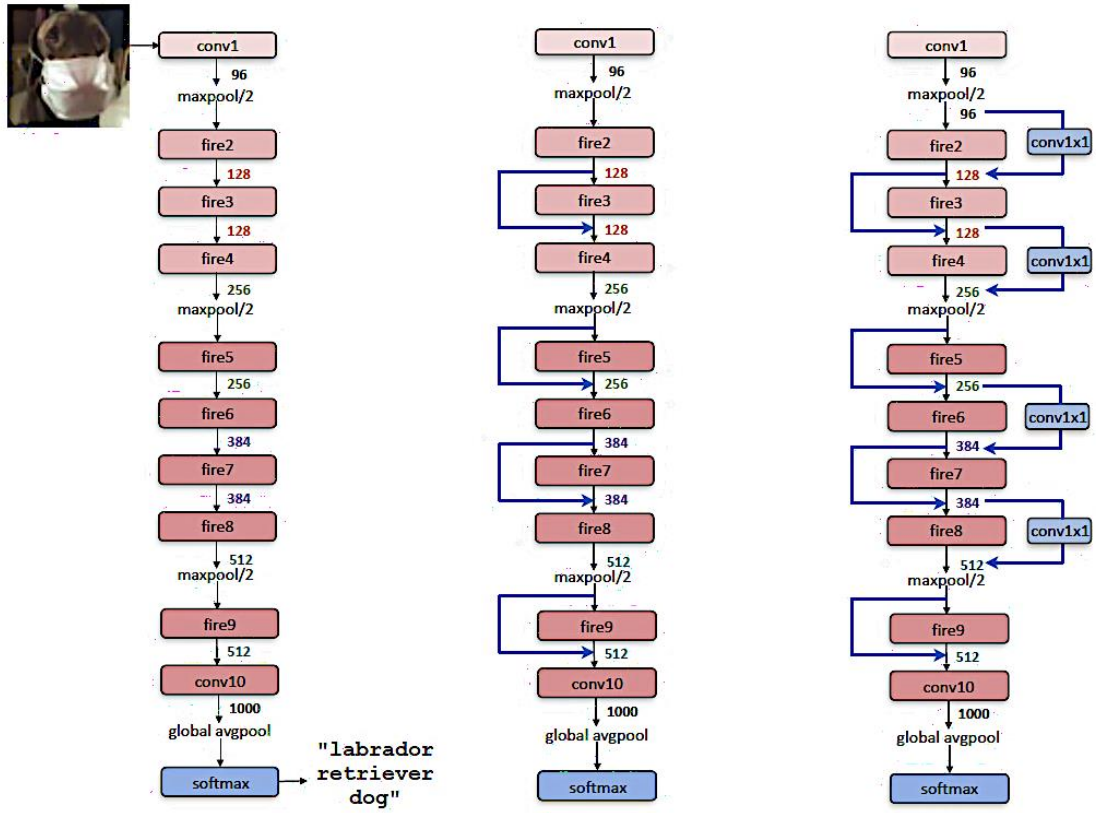
Şekil 2.12: DenseNet Mimarisi [31]

2.1.11. SqueezeNet Mimarisi

AlexNet mimarisine kıyasla çok daha az parametrenin kullanıldığı ve benzer oranda doğruluk oranı sağlayan SqueezeNet modeli özellik sıkıştırma yöntemi kullanılarak küçük bir bellek hafızasında tutulmuştur. SqueezeNet mimarisi, görüntü işleme üzerinde popüler olan evrişimsel sinir ağları algoritmalarının sınıflandırma ve ağ doğruluğunun artırılması için geliştirilen modellerin başında gelmektedir. SqueezeNet mimarisi diğer algoritmalara göre daha hızlı çalışmaktadır çünkü verimli dağıtılmış katmanlar sayesinde sinir ağındaki iş yükü azalmaktadır [32].

Araştırmacılar SqueezeNet mimarisinin doğruluğunu en üst düzeye çıkartmak için bazı stratejiler geliştirmişlerdir. Bunlardan birincisi, 3x3 boyutundaki evrişim süzgeçleri yerine 1x1 boyutundaki evrişim süzgeçleri kullanılmıştır. 1x1'lik süzgeçler 3x3'lük süzgeçlere göre çok daha az parametre oluşturmaktadır. İkinci yöntem olarak, ağın içerisinde bulunan 3x3 boyutundaki süzgeçlerin girdi boyutlarının küçültülmesi amaçlanmaktadır. 3x3'lük bir evrişim süzgeci kullanıldığında kullanılan parametre sayısı; uygulanan süzgeç sayısı, girdi boyutları ve süzgecin boyutlarının çarpımıyla doğru orantılıdır. Burada girdilerin boyutlarının azaltılması

amaçlanmaktadır. Sonuncu yöntem olarak önerilen strateji ise, evrişim katmanlarından daha büyük özellik haritaları oluşturulabilmesi için alt katmanlarda bulunan örneklemenin ağda bulunan mevcut ileri katmanlardan oluşturulması amaçlanmıştır. Burada evrişim işlemine sokulan girdiler, özellik haritalarının boyutları ve alt örneklemenin ağın hangi evrişim katmanlarında yapılacağının seçimi kontrol edilmektedir [33].



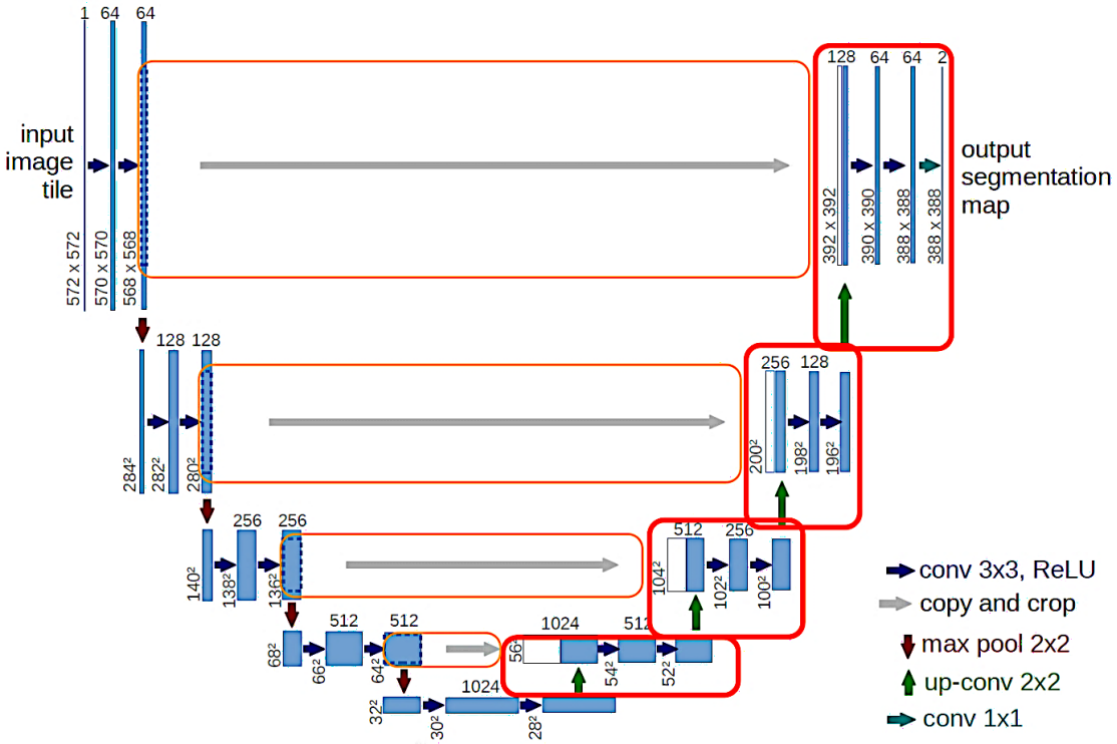
Şekil 2.13: SqueezeNet Mimarisi [34]

2.1.12. U-Net Mimarisi

U-Net modeli, evrişimli sinir ağı katmanlarından oluşturulmuş, öncelikle görüntü segmentasyonu (bölütleme) için tasarlanmış ve özellikle biyomedikal görüntüler üzerinde klasik modellere göre daha başarılı sonuçlar veren bir sinir ağı mimarisidir [35].

U-Net birçok evrişimli sinir ağına göre çok daha az parametreye sahip ve eğitim süresi oldukça kısadır. Klasik evrişimli sinir ağı modellerinde eğitim için büyük veri setlerine ihtiyaç duyulmaktadır. Bu veri setleri içerisinde bulunan görüntüler etiketlenerek ağ yapısına gönderilir ve ağ bu görüntüleri etiket bilgileri üzerinden tanımaktadır. Biyomedikal ve tıbbi alanda kullanılan görüntülerde bu etiketleme işlemi oldukça güç ve zaman alan bir işlemdir. Bunun sebebi biyomedikal görüntüler piksel temelli yaklaşımlar gerektirmektedir. U-Net modeli

simetriktir ve mimari yapısı U şekline benzediği için ismini de buradan almıştır. Şekil 2.14'de U-Net mimarisinin yapısı gösterilmektedir.



Şekil 2.14: U-Net Mimarisi [35]

U-Net mimarisi, alt örnekleme (sol taraf) ve genişleyen üst örnekleme yolundan (sağ taraf) oluşmaktadır. Kutular çok kanallı bir özellik haritasına denk gelmektedir ve kanal sayısı kutunun üstünde gösterilmektedir. Alt örnekleme yolu klasik bir evrişimsel ağdır, 4 bloktan oluşmaktadır ve her blok 2 adet 3x3 evrişimsel katmanı + aktivasyon fonksiyonu ve bir adet 2x2 maksimum havuzlama katmanı içermektedir. Özellik haritasının sayısı her havuzlama işleminde ikiye katlanmaktadır. Burada alt örnekleme yolunun amacı, segmentasyon yapabilmek için girdi görüntülerinin içeriğini yakalamaktır. U-Net mimarisinin tamamen bağlı katmanı yoktur. Yalnızca evrişim katmanları kullanılmaktadır ve standart evrişim işlemi ReLU ile aktive edilmektedir. Burada genişleyen üst örnekleme yolu 4 bloktan oluşmaktadır. Bu bloklar dekonvolüsyon katmanı, alt örnekleme, 3x3 konvolüsyon tabakası ve aktivasyon fonksiyonları içermektedir. Sonuncu olarak da özellik haritasını mümkün olduğunca kanallara indirgemek için ve segmentasyon yapılmış görüntüyü elde etmek için ekstra bir 1x1 evrişim işlemi uygulanmaktadır [36].

U-net mimarisi 2015 yılında ortaya çıkışından itibaren tıbbi görüntüleme alanında ciddi bir şekilde kullanılmaya başlanmıştır. Bunun en büyük sebebi U-Net'in basit mimarisi, esnek

yapısı ve yüksek kalitede piksel düzeyinde bölütleme sonuçları sunmasıdır. Özellikle son yıllarda araştırmacılar tarafından U-Net kullanılarak birçok çalışma yapılmış ve biyomedikal görüntüleme dışında farklı alanlarda da kullanımı yaygınlaşmıştır.

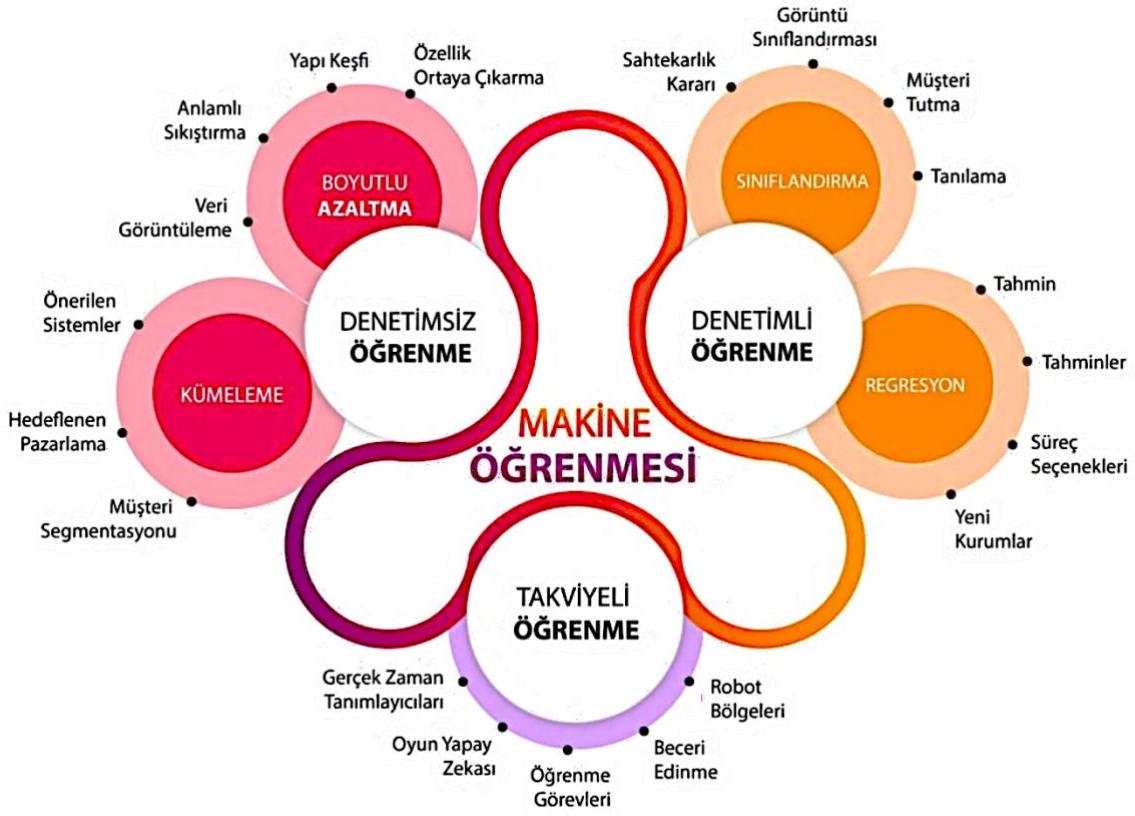
Görüntü segmentasyon performansının değerlendirilmesi farklı yollarla yapılabilmektedir. Bu çalışmalarda genellikle pozitif tabanlı metrikler kullanılmaktadır çünkü segmantasyon da örtüşme alanlarının (Doğru pozitif sayısı, Yanlış pozitif sayısı, Yanlış negatif sayısı) nitelendiği ölçütler önemlidir. Literatürde kullanılan en sık performans değerlendirme ölçütleri; Dice örtüşme indeksi, (Dice Benzerlik Katsayısı) Özgüllük (Specificity) ve Hassasiyet (Senstivity)'dir [36].

Dice skoru, tahmin edilmiş ve önceden etiketlenmiş bölgeler arasındaki ilişkiyi göstermektedir. Etkin örtüşme alanının bütün bir birleşimde ne kadar etkin olduğunu göstermektedir. Dice skoru tahmin ve referans arasındaki örtüşme tabanlı bir metrik olup 0-1 arasında değerlendirilmektedir. Mükemmel bir segmentasyon sonucunun elde edilebilmesi için örtüşme alanının birleşme alanına eşit olması ve aynı zamanda 1'e eşit olması gerekmektedir [36].

2.2. GELENEKSEL MAKİNE ÖĞRENMESİ SINIFLANDIRICILARI

Makine öğrenimi, bilgisayarların bizim onlara sunduğumuz verilere erişerek kendi kendilerine öğrenmelerini ve gelişmelerini sağlayan bir yapay zekâ uygulamasıdır. Makine öğrenimi farklı özellik çıkarma teknikleriyle verilerin tahmin süzgecinden geçirilerek ve sonrasında doğru parametre değerleriyle doğru tahminler yapabilmeyi öğretme süreci olarak da tanımlanabilmektedir. Günümüzde makine öğrenme modelleri ve sınıflandırıcıları kullanılarak birçok problemin çözümünde aktif olarak kullanılmaktadır [37].

Makine öğrenmesi problemlerinin çözümünde; Denetimli (supervised), Denetimsiz (unsupervised) ve takviyeli (reinforcement) öğrenme şeklinde üç ana kategori bulunmaktadır. Bu kategorilere ek olarak yarı denetimli öğrenme modeli de kullanılmaktadır. Bu kategorilerin sınıflandırılması öğrenme yöntemlerine karşılık gelen verilerin nasıl işlendiği ve analiz edildiği ile alakalıdır. Şekil 2.15'de makine öğrenmesi yöntemlerinin gösterimi şematik olarak görünmektedir.

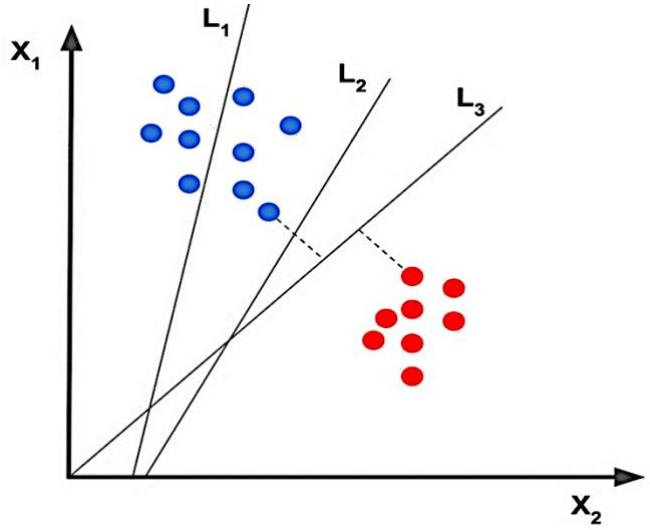


Şekil 2.15: Makine Öğrenmesi Yöntemlerinin Gösterimi [38]

Literatürde yapılan çalışmaları incelediğimizde birçok makine öğrenmesi algoritması karşımıza çıkmaktadır. Bunların en çok bilinenleri; Destek vektör makinaları (SVM), Lineer diskriminant analizi (LDA), K-En yakın komşu (k-NN), Naive bayes (NB), Karar ağacı (DT) çok kullanılan yöntemlerin başında gelmektedir.

2.2.1. Destek Vektör Makinaları

İlk olarak 90'lı yıllarda ortaya çıkan SVM yöntemi özellikle sınıflandırma ve regresyon problemlerinde sıklıkla kullanılan bir denetimli öğrenme yöntemidir [39]. SVM yönteminin temel amacı, farklı çekirdek algoritmaları kullanarak doğrusal olmayan ayrılabilir örnekleri başka bir yüksek boyutlu uzay düzlemine yansıtmaktır. Burada en önemli husus doğrusallıktan doğrusal olmayışa geçişte çekirdek işlevlerinin rolüdür. En çok bilinen çekirdek fonksiyonlarını örnek olarak verecek olursak; Polinom, Doğrusal, Sigmoid ve Radyal temel fonksiyonlar verilebilir [40]. Doğrusal çekirdek fonksiyonları sıklıkla büyük öznitelik kümeleri için kullanılmasına rağmen ikinci dereceden (quadratic) çekirdekler ise Polinom çekirdeklerin yaygın bir türü olarak kullanılmaktadır. Şekil 2.16'de iki kümeli bir sınıflandırma işlemi için oluşturulmuş iki boyutlu doğrusal bir sınıflandırma verilmiştir.



Şekil 2.16: Destek Vektörlerinin Doğrusal Düzlemde Gösterimi [41]

Şekil 2.16'te görülen L-1, L-2 ve L-3 doğrusal çizgilerine bakıldığında L-1 çizgisinin kırmızı ve mavi toplardan oluşan iki kümeyi ayırmakta en başarısız olduğu görülmektedir. Burada L-2 doğrusu mavi renkli noktaların oluşturduğu kümeye daha yakınken kırmızı veri kümesine daha uzak kalır. Bunun sonucunda yeni tahmin edilmesi istenen verinin hatalı bir tahminle sonuçlanmasına neden olacaktır. Bu sebepten dolayı algoritma iki veri kümesinde ki birbirlerine en yakın olan verilerin arasındaki en fazla aralığı yakaladığı bölgeden doğru çizmeyi deneyecektir. Bu şekilde veri kümeleri arasında çizilebilecek sonsuz adet doğru vardır fakat algoritma en iyi çizilebilecek doğrulara karar vermektedir [41].

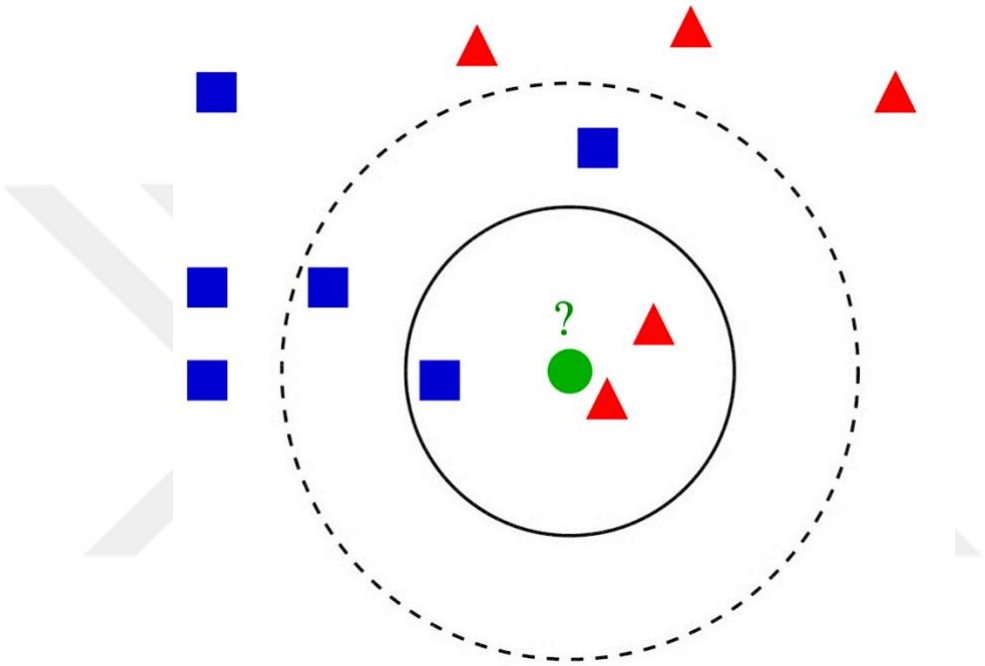
SVM algoritması makine öğrenmesi problemlerinde çok güçlü bir sınıflandırıcıdır. Çalışma prensibi olarak her veri kümesini x ve y boyutlu uzayda bir nokta alarak doğru çizmeye çalışmaktadır. Sınıflandırma işlemi yapılırken bir sınıftan diğer sınıfın örneklerini ayırmak için eğitim işlemleri yapmaktadır.

2.2.2. K-En Yakın Komşu

K-NN (K-Nearest Neighbors) algoritması sezgisel yöntemlerle çalışan en kolay anlaşılabilir sınıflandırma yöntemidir. Burada etiketlenmemiş nesneler benzer etiketli örneklerin sınıfına atama yapılarak sınıflandırma yapılmaktadır. Sınıflandırılacak girdi özelliklerinin sınıf etiketleri kendisine en benzer ve yakın durumda ki komşularına atanmaktadır. Buradaki en temel kural sınıfı ayrılacak girdi özelliği ile eğitim setinde bulunan özellikler kümesinin arasında bulunan uzaklık öklid mesafesi kuralına göre hesaplanmaktadır [42]. K-NN algoritması iki adımdan oluşmaktadır. Birinci adımda, bilinmeyen örneğe en yakın olan k

eğitim örnekleri bulunur. Diğer adımda ise k örneklerinin en sık görüldüğü sınıf seçilmektedir. K-NN sınıflandırması genellikle tüm öznitelikler sürekli olduğunda kullanılmaktadır [43].

K-NN algoritması eğitim verilerini öğrenmek yerine ezberleme yöntemini uygular. Tahmin yapılmak istenildiğinde tüm veri kümesine en yakın olan komşuları aramaktadır. Burada öklid mesafe fonksiyonunun yanı sıra Manhattan, Hamming ve Minkowski fonksiyonları da kullanılabilmektedir [44].



Şekil 2.17: K-En Yakın Komşu Algoritması [45]

Şekil 2.17'de test olarak seçilen veriler kare veya üçgen olarak sınıflandırılmıştır. Burada k değeri 3 olursa, kırmızı üçgen grubuna dahil olur. Bunun sebebi iç çemberde iki üçgen ve bir kare bulunmasıdır. Eğer k değeri 5 olursa, mavi kare sınıfına dahil olur çünkü bunun sebebi dış çemberde üç kare ve iki üçgen bulunmasıdır [45].

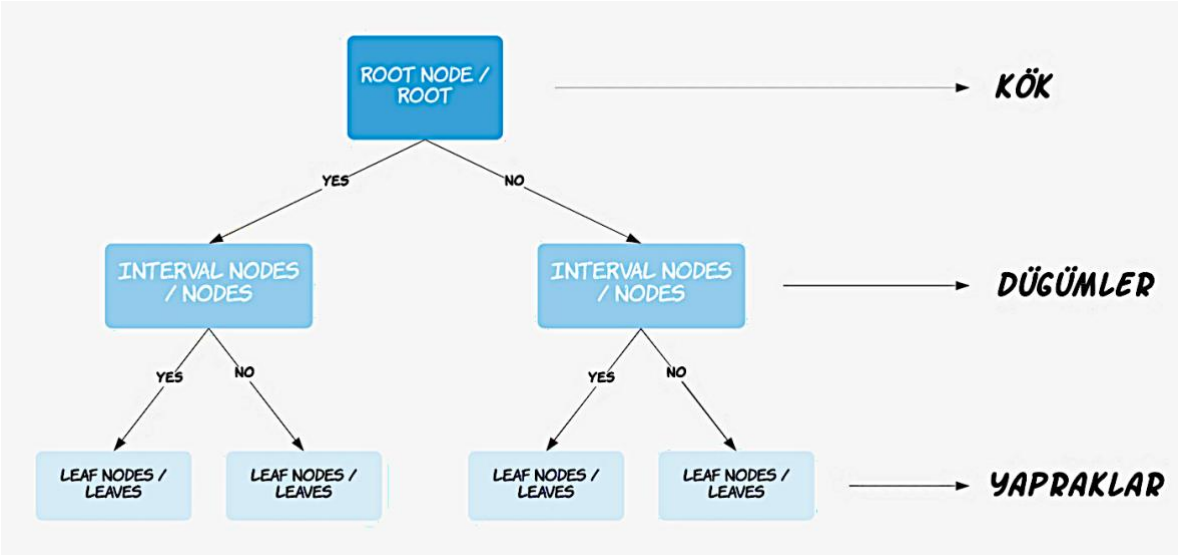
Sınıflandırma işlemleri sırasında performansa yüksek miktarda etkisi olduğundan dolayı k seçimi oldukça kritik bir rol oynamaktadır. Sınıflandırma yapılırken en çok yapılan hatalardan biriside veri örnekleri için sınıf tahminlerinin yapılmamasıdır çünkü bu durumun sonucunda sınıflandırma performansında hatalı bir sonuç ortaya çıkacaktır. Algoritma mesafe fonksiyonlarını kullanarak atama ve sınıflandırma problemlerinde kullanılmasına rağmen parametrik olmayan yapısı sebebiyle örüntü tabanlı öğrenme modellerinde de kullanılmaktadır.

2.2.3. Karar Ağaçları

Tümevarımla bir öğrenme şekli olan Karar ağacı (DT) bir veri kümesi için bir kök düğümden, birkaç bağlı dahili düğümden ve geriye kalan kısımlar için yaprak düğümlerden oluşmaktadır. Burada her yaprak düğüm bir karara karşılık gelirken, diğer tüm düğümler özellik eşleştirmesine karşılık gelmektedir. Oluşturulan algoritmada yaprak olmayan her düğüm bir alt küme içermektedir. Veri örnekleri özellik eşleştirme sonuçlarına göre alt düğümlere bölünmektedir. Burada kök düğüm olarak bilinen kısım tüm veri kümesini kapsamaktadır. Bir karar ağacı oluşturmanın en kolay yolu özellik alanlarını bölme şeklinde yapılmaktadır. Özellik alanı bölünürken belirli bir yol izlenmektedir. Bunun temel amacı yaprak olmayan her düğümün saflığını yüksek seviyeye çıkarmaktır. Burada amaç yaprak olmayan her düğüme olabildiğince çok veri kümesinin herhangi bir kategoriye ait olduğunu göstermektir [46].

Karar ağacı yöntemi uygulanırken başlangıçta yapılan herhangi bir hatanın etkisi tüm bölümlere yayılabilmektedir. Bazen verilerde yapılan küçük bir değişiklik çok farklı bölünmelere neden olmakla birlikte yöntemi anlamsız hale getirebilmektedir. Bu sebepten dolayı kararlı bir bölünme kriteri kullanılarak hata etkisi bir noktaya kadar azaltılabilir fakat istikrarsızlığın ortadan kaldırıldığından söz edilemez.

Şekil 2.18'te görüldüğü gibi Karar ağacı hiyerarşik düzeninde, ana kök en üst düğümde bulunmaktadır. İç düğümler, kök ve yapraklar arasında bulunmaktadır. Bir karar ağacı oluşturulurken temel amaç, bir düğüm üzerinde test edilecek bir özniteliği tekrar bulmak ve daha sonra başka bir düğüme eşlemektir.



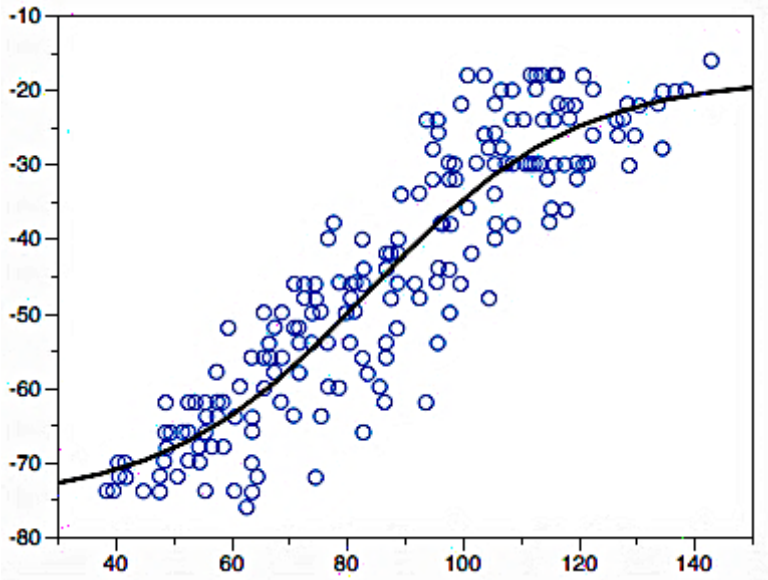
Şekil 2.18: Karar Ağacı Algoritması [46]

2.2.4. Lojistik Regresyon

Lojistik regresyon, karmaşık ve bulanık olayları anlamak ve sınıflandırmak için kullanılan bir istatistiksel bir yöntemdir [47]. Burada kullanılan ve makine öğrenmesi tekniği olarak uygulanan lojistik fonksiyonu aslında sınıflandırma için kullanılan bir analiz yöntemidir. Özellikle doğrusal sınıflandırma problemlerinde adına regresyon denilmesine rağmen sıklıkla kullanılmaktadır.

Lojistik regresyon problemlerinde bağımlı değişkenler minimum ikili değişkenler olduğunda veri kümesi sınıflandırılmaktadır. Lojistik regresyonun temel amacı, iki taraflı karşıt karakteristik yapıyı bir dizi bağımsız değişken ile birlikte inceleyerek arasındaki ilişkiyi tanımlamak amacıyla uygun modeli bulmaktır. Burada tüm olaylar bağımsızdır ve bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişki varsayılmaz. Lojistik regresyon problemlerinde bağımlı değişkenler normal dağılım göstermek zorunda değildir fakat üstel dağılımdan (Binom, Poisson, vb.) gelen varsayımları kabul eder. Tüm regresyon analizlerinde olduğu gibi lojistik regresyonda temelinde bir tahmin analizidir ve sınıflandırma problemlerinde olduğu gibi tahminleme problemlerinde sıkça kullanılmaktadır [47].

Şekil 2.19'da Lojistik regresyonun S-curve (eğri) şeklinde örneği gösterilmiştir. Genellikle veri kümelerinin bu şekilde davranış sergilediği durumlarda tahmin yapmak daha anlamlı olmaktadır.



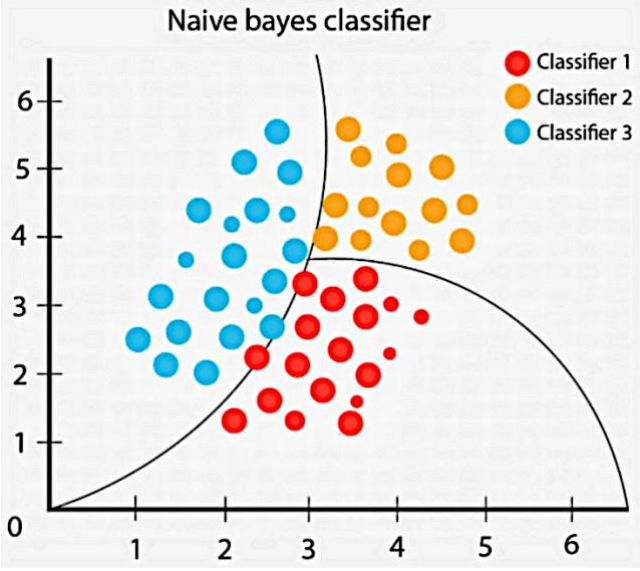
Şekil 2.19: Lojistik Regresyon [47]

2.2.5. Naive Bayes

Thomas Bayes tarafından ortaya atılan Naive Bayes (NB) teoremi tüm olasılıkların kontrol edilmesini amaçlayan bir yöntemdir [48]. Olasılık teorisinde sıklıkla kullanılan Bayes teoremi, iki tesadüfi olayın koşullu ve uç olasılıklarını ilişkilendirir ve genelde hesaplamalar geride kalan olasılıkları hesaplamak için kullanılmaktadır. Naive Bayes sınıflandırıcıları tarafından geliştirilen bu teori denetimli öğrenme ortamında oldukça verimli bir şekilde eğitilmesi mümkün olan bir yöntemdir. İstatistiksel olarak herhangi bir sınıfa ait özelliklerin olasılıklarını belirleyerek sınıfı belli olmayan bir özelliğin hangi sınıfa ait olduğu tahmin edilebilmektedir. Algoritmanın çalışma prensibi göz önüne alındığında, herhangi bir gözlemin koşullu olasılığının belirli bir *x* özelliğini en yakın *y* sınıfına atama yaparak uygulanmaktadır. Burada atama yapılırken istatistiksel olarak belirli koşulları sağlaması beklenmektedir. Aşağıda Bayes kuralı denklem formunda verilmiştir.

$$P(b\backslash a) = P(b)P(a\backslash b) / P(a)$$

Burada $P(b\backslash a)$, *a* olayı gerçekleştiğinde *b* olayının olma olasılığıdır. $P(a)$ ve $P(b)$ ise sırasıyla *a* ve *b* olaylarının olma ihtimalleridir. Naive Bayes özelliklerin sınıflara göre koşullu olarak ve bağımsız oldukları varsayımıyla Bayes teoremine dayanan bir ağ sınıflandırma biçimidir [49]. Şekil 2.20'de Bayes sınıflandırma modeli gösterilmiştir. Bayes algoritması özellikler arası ilişki olmadığını kabul etmekle birlikte özellikler arası korelasyon varsayımını da reddetmektedir.



Şekil 2.20: Naive Bayes Modeli [50]

2.2.6. Doğrusal Diskriminant Analizi

Doğrusal (Lineer) diskriminant analizi (LDA), 1936 yılında R.A. Fischer tarafından geliştirilmiş temel veri analizi ve sınıflandırma metodudur. Özellikle sınıflandırma işlemlerinde veri görselleştirme ve boyut küçültme işlemleri için sıklıkla kullanılmaktadır. Yöntemin basit bir yapısı olmasına rağmen kompleks problemlerde iyi sonuçlar üreten bir modeldir. LDA algoritmasının temel varsayımı, her sınıfın bir gauss dağılımı ile modellenebileceği üzerine dayanmaktadır. Aynı zamanda tüm sınıfların aynı kovaryans matrisini paylaştığı varsayımına da dayanmaktadır. Bu sayede çok sınıflı etiketlerde en iyi ayrımı sağlamak için tüm değişkenleri lineer bir kombinasyonda aramaya çalışmaktadır. LDA, verilerin gerçek dağılımında ve veri sayısı sonsuza doğru eğilim gösterdiğinde optimal olarak kabul edilmektedir. LDA kullanılarak yapılan çalışmalar incelendiğinde iki sınıfı en iyi şekilde ayırabilen kombinasyonlarda kullanıldığı görülmektedir.

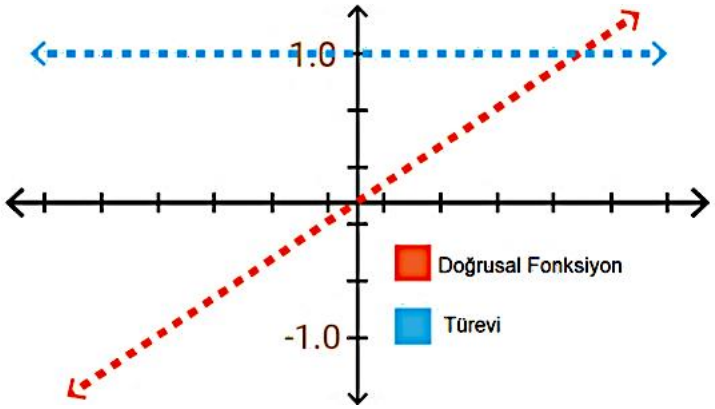
2.2.7. Aktivasyon Fonksiyonları

Literatürde derin öğrenme yöntemleriyle yapılan çalışmalara bakıldığında genelde doğrusal olmayan problemlerin çözümünde kullanıldığı görülmektedir. Derin öğrenme yöntemleri uygulanırken evrişim katmanındaki matris çarpanları sonrasında elde edilen tüm değerler doğrusaldır. Burada aktivasyon fonksiyonları kullanılarak değerlerin doğrusal olmayan hale dönüştürülmesi yapılmaktadır [51].

Aktivasyon fonksiyonları tahmin problemlerinin yapısına bağlı olarak seçilmektedir. Bu fonksiyonlar sinir ağı tasarımlarının kritik bir parçası olmakla birlikte çıktı katmanında ki aktivasyon fonksiyonlarının seçimi modelin kurulacağı tahminlerin özelliklerini tanımlamaktadır [52].

2.2.7.1. Basamak Step Fonksiyonu

İkili sınıflandırıcı olan bu fonksiyon yapısı gereği ikili değer alan fonksiyonlar sınıfındadır. Bu yüzden yapısı gereği çıkış katmanlarında tercih edilmektedir. Doğrusal aktivasyon fonksiyonlarından oluşan bir ağ yapısının eğitilmesi oldukça kolaydır. Bu yüzden genellikle kullanılan fonksiyonların türevi alınabilen bir doğrusal olmayan fonksiyon olması sonucu olumlu yönde etkilemektedir. Şekil 2.21'de doğrusal fonksiyon ve türevinin grafiksel gösterimi verilmiştir.

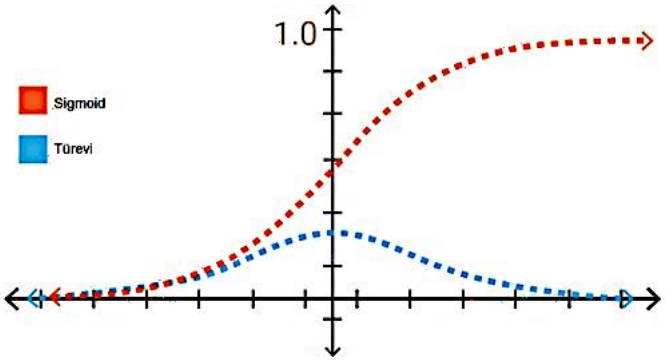


Şekil 2.21: Doğrusal Fonksiyon ve Türevi [53]

Doğrusal fonksiyon bir dizi aktivasyon fonksiyonu üretmektedir ve genellikle ikili değerler değillerdir. Burada ağ yapısında birkaç sinir ağı hücresini birbirine bağlamaya izin vermektedir. Bunun sonucunda tüm katmanlarda doğrusal fonksiyonlar kullanıldığı zaman giriş ve çıkış katmanları arasında daima aynı doğrusal sonuca ulaşılmaktadır. Diğer bir ifadeyle doğrusal fonksiyonların başka herhangi bir doğrusal fonksiyonla birleşimi bir başka doğrusal fonksiyon oluşturmaktadır [53].

2.2.7.2. Sigmoid Fonksiyonu

Doğrusal olmayan bir yapıya sahip olan Sigmoid fonksiyonunun kombinasyonları da doğrusal değildir. Birçok doğrusal olmayan problemin çözümünde Sigmoid fonksiyonu en sık kullanılan aktivasyon fonksiyonlarının başında gelmektedir. Lojistik fonksiyonu olarak da literatürde bazı çalışmalarda tanımlanan sigmoid fonksiyonunun girdisi 0 ile 1 arasında değerlere dönüştürülür. 1'den daha büyük olan girdiler 1 değerine, 0'dan daha küçük olan girdiler 0'a dönüştürülür. Tüm olası girişler için fonksiyonun şekli bir S şeklinde olmaktadır [54].



Şekil 2.22: Sigmoid Fonksiyonu ve Türevi [53]

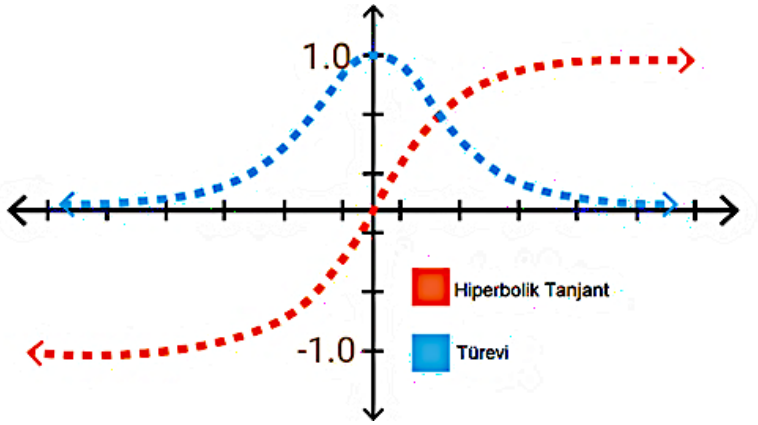
Şekil 2.22'da Sigmoid fonksiyonun grafiği verilmiştir. Grafiğe bakıldığında X değerine belirli aralıklarda karşılık gelen Y değerleri hızlı şekilde değişmektedir. X düzleminde yapılan küçük değişiklikler Y değerleri için büyük olacaktır. Buradan fonksiyonun hem iyi bir sınıflandırıcı olduğu anlamı hem de her zaman [0,1] arasında değerler üreteceği anlamına gelmektedir.
Yapılan çalışmalarda sigmoid fonksiyonunun en büyük dezavantajı olarak kabul edilebilecek durum y değerlerinin genellikle x'deki değişikliklere çok az tepki vermesi olarak açıklanmaktadır. Dolayısıyla bu bölgede ki türev değerleri çok küçük olmaktadır ve sıfıra yaklaşmaktadır. Buna gradyanların ölmesi (vanishing gradient) de denebilir. Sonuç olarak öğrenme düzeyi düşük seyretmekte ve hatayı minimize eden optimizasyon algoritması yerel değerlere takılabilmektedir. [53].

2.2.7.3. Softmax Fonksiyonu

Sigmoid fonksiyonuna çok benzer bir yapıya sahip olan Softmax fonksiyonu, AlexNet, ResNet gibi bilinen birçok mimarinin son katmanında aktivasyon fonksiyonu olarak kullanılmaktadır. Softmax fonksiyonu sınıflandırıcı olarak kullandığında iyi bir performans sergilemektedir. Bu fonksiyonun en belirgin özelliği olasılığa dayanan bir yorumlama mekanizmasına sahip olmasıdır. Bununla birlikte her bir girdinin hangi sınıfa ait olma olasılığını [0,1] aralığında değerler üreterek belirlenmesini sağlamaktadır [53].

2.2.7.4. Hiperbolik Tanjant Fonksiyonu

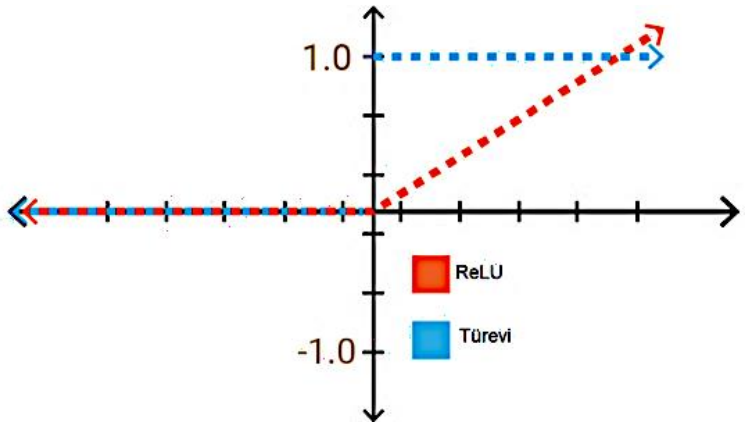
Hiperbolik tanjant fonksiyonu (TanH), [-1, +1] aralığında tanımlanmakla birlikte sigmoid fonksiyonuna göre avantajı türev değerinin daha çok değer alabilmesidir. Fakat bu durum bazen eğitimi kötü etkilemektedir. Softmax fonksiyonu gibi Sigmoid fonksiyonu da benzer bir yapıya sahiptir. Fakat günümüz CNN modellerinde kullanımı çok yaygın değildir. Bunun en büyük sebeplerinden bir tanesi Şekil 2.23'de ki grafik incelendiğinde uç kısımlarda türevin sıfıra yakınsadığı görülmektedir. Hiperbolik Tanjant fonksiyonu literatür de çokça kullanılan bir aktivasyon fonksiyonu olmasına rağmen çok daha başarılı sonuçlar elde edilebilecek fonksiyonlar bulunmaktadır [54].



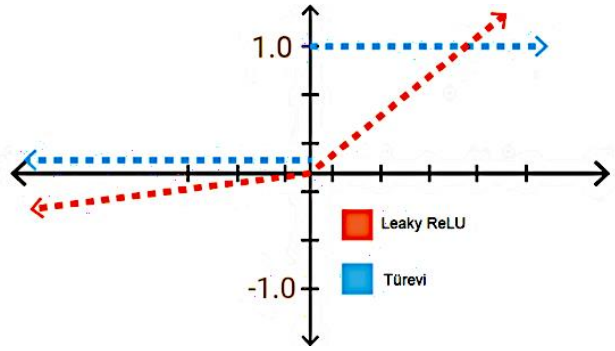
Şekil 2.23: Hiperbolik Tanjant Fonksiyonu ve Türevi [53]

2.2.7.5. ReLU (Rectified Linear Unit) Fonksiyonu

ReLU fonksiyonu [0, +∞) aralığında değer almaktadır. Fonksiyon pozitif eksende doğrusal fonksiyon ile aynı özelliklere sahip gibi görünmektedir fakat ReLU doğrusal değildir. İyi bir tahmin edici ve sınıflandırıcı olan bu fonksiyonu kombinasyonları ile birlikte herhangi bir başka fonksiyona da yakınsamak mümkündür. ReLU fonksiyonu ağın daha hızlı bir şekilde çalışmasını sağlamak amacıyla negatif değerleri 0 (sıfır) olarak alır. Fakat bu bölgede türevin sıfır olması sonucunda öğrenme engellenmektedir. Buradaki dezavantajı ortadan kaldırmak için başka aktivasyon fonksiyonları önerilmektedir. Bunlardan bir tanesi negatif değerleri 0 yapmak yerine 0'a yakın bir değere eşitleyerek negatif eksende ki değerlerin de eğitime katılmasını sağlayan, yine ReLU ailesinden gelen LReLU (Leaky) fonksiyonudur. Bu fonksiyon hesaplama yükünün özellikle sigmoid ve tanjant fonksiyonuna göre daha az olması çok katmanlı ağlarda daha fazla kullanılmasına sebep olmaktadır [55].



Şekil 2.24: ReLU Fonksiyonu ve Türevi [53]



Şekil 2.25: LReLU Fonksiyonu ve Türevi [53]

Şekil 2.25'de verilen LReLU grafiğinde burada ki Leaky (sızdırma) değeri 0,01 gibi eğer sıfıra yakın bir değer verilirse fonksiyonun adı rastgele Leaky ReLU olarak değişmektedir. Burada sızdırılan ReLU fonksiyonunun tanım aralığı eksi sonsuza kadar devam etmektedir. Bu sayede öğrenme negatif bölgedeki değerler içinde devam etmektedir [53].

2.3. TOPLULUK YÖNTEMLERİ

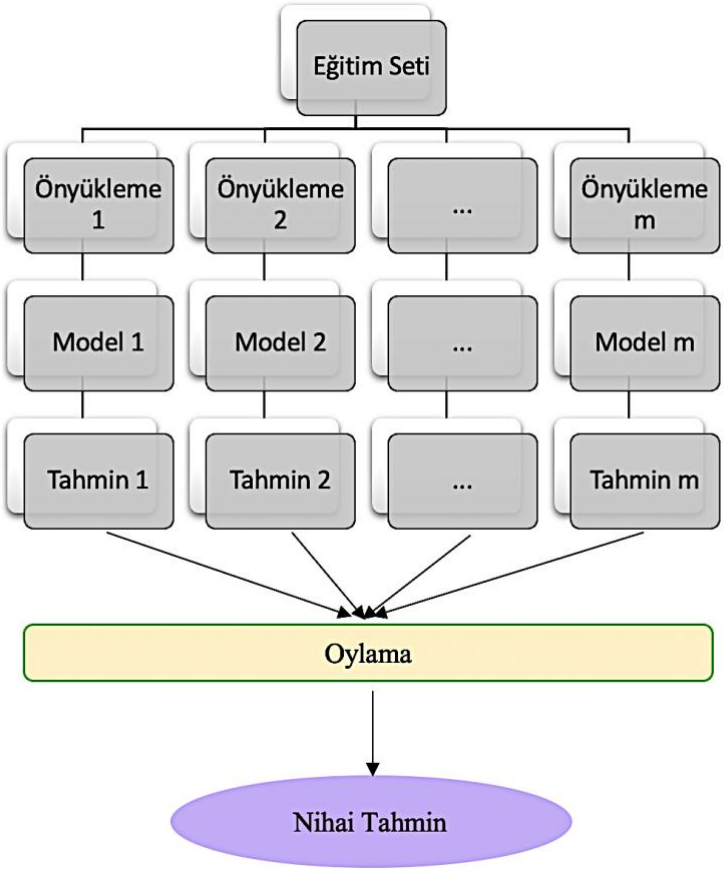
Topluluk öğrenmesi tek bir öğrenici ile modeli eğitmek yerine birden fazla öğreniciyi bir topluluk üyesi gibi eğiterek model oluşturmayı sağlayan öğrenmedir. Burada modellerin topluluk şeklinde veri setleri üzerinde ki tahminlerinin bireysel tahminlere göre daha yüksek doğruluk kararı vereceği amaçlanmaktadır [56]. Bu yöntemlerde başarı kriterleri; temel öğrenicilerin öğrenme başarısı ve birbirlerinden farklılıklarına göre değerlendirilmektedir. Topluluk öğrenmesi öğrenicilerin iyi ve kötü özelliklerini seçerek modelin performansını artırmak aynı zamanda kötü bir seçim yapma olasılığını ortadan kaldırmak için kullanılmaktadır [57]. Topluluk öğrenmesi için en çok kullanılan modeller; Torbalama (Bagging), Yükseltme (Boosting) ve Oylama (Voting) olarak bilinmektedir.

2.3.1. Torbalama Yöntemi (Bagging)

Torbalama yöntemi ilk olarak 1996 yılında Breiman tarafından geliştirilmiş öğrenme algoritmalarının genel yeteneklerini önemli ölçüde geliştirebilen bir eğitim yöntemidir. Torbalama yönteminde bir veri setinden elde edilen girdi örneklerine tahminciler eklenerek bir topluluk oluşturulmaktadır. Burada girdiler iade edilmek üzere rastgele seçimler yapılarak alt örneklemler oluşturulmak amacıyla kullanılmaktadır. Oluşturulan alt örnekler veri setiyle aynı olmakla birlikte örneklemlerde yer alan bazı gözlemler iki veya daha fazla kere görülebilir. Son olarak tahminlerin birleştirilmesi aşamasında sınıflandırma ağaçlarında sonuçlar oylama ile belirlenirken regresyon ağaçları için ortalama alınır. Bu yöntem makine öğrenmesi

algoritmalarıyla birlikte kullanıldığında zamandan tasarruf sağlamaktadır. Aynı zamanda parametrelerin güven aralıklarını bulmada ve hata tahmininde son derece kullanışlı bir yöntemdir [58].

Torbalama yöntemi, belirsiz bir tahminci değişkeninin geçerliliğini artırabilir. Burada düşük yanılma yüksek varyantlı değişkenler kullanılarak daha elverişli hale getirilmektedir. Deneysel sonuçlar göz önüne alındığında torbalama yöntemi tekil ağaçlara göre daha etkin sonuçlar vermektedir. Şekil 2.26'da torbalama yönteminin iş akışı verilmiştir.

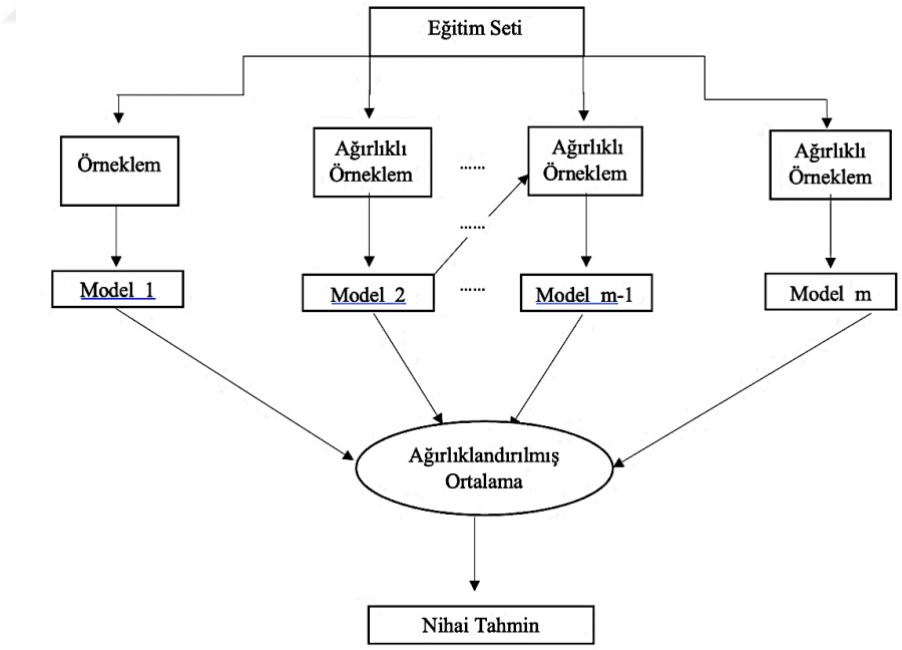


Şekil 2.26: Torbalama Yöntemi İş Akış Diyagramı

Torbalama iş akış diyagramı incelendiğinde modellerin birbirinden bağımsız ve paralel şekilde çalıştıkları görülmektedir. Burada çeşitli alt kümeler veri kümesinden meydana gelmektedir. Her alt grup bir zayıf modelden oluşmuştur ve nihai tahminlerin hepsi tüm modellerden gelen tahminlerin birleştirilmesiyle elde edilmektedir.

2.3.2. Yükseltme Yöntemi (Boosting)

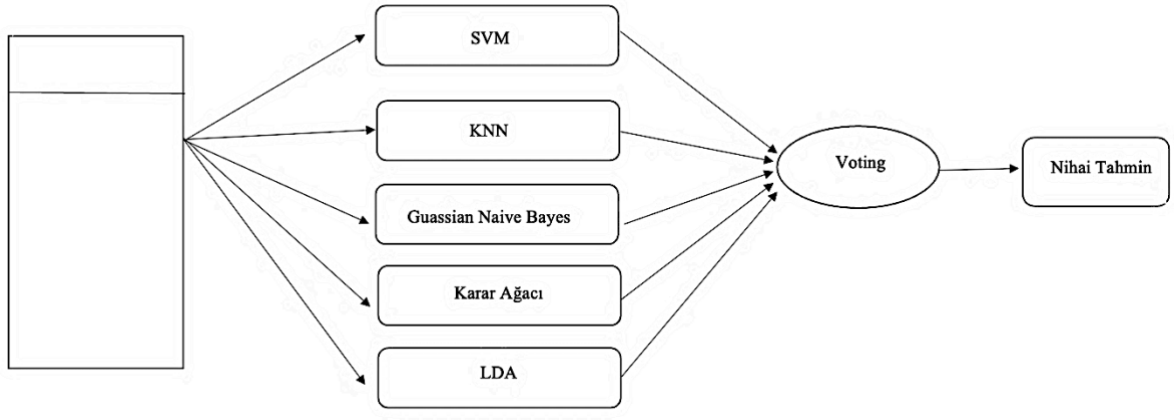
Yükseltme yöntemi teorik olarak zayıf öğrenicileri sınıflandırarak daha güçlü bir öğrenici modeli oluşturmak amacıyla birleştirmektedir. Yükseltme iyi olması gereken sınıflandırıcıları sürekli üreten zayıf öğrenme algoritmasının hatasını azaltmak için kullanabilmektedir. Bu yöntemde sınıflandırıcılar önceki sınıflandırıcıların hatalarını test etmektedirler. Bir sonraki sınıflandırıcıda daha iyi tahminler yapılabilmesi için önceki tahmin hatalarından öğrenme işlemini gerçekleştiren bir topluluk öğrenmesi yöntemidir. Teorik sonuçlarla öngörülen ilerlemenin muhtemel faydalarına rağmen yükseltme yönteminin gerçek potansiyel değeri ancak gerçek hayat öğrenme problemleri üzerinde test edilerek değerlendirilebilmektedir [59]. Yükseltme yönteminde bir öğrenicinin çıktısı diğer öğrenicinin girdisi durumundadır. Veri girdisi, örneklerinin ağırlıklarının son tahmin hatasına göre ayarlandığı bir topluluk oluşturmaktadır. Burada model sınıflandırıcıları bir düzene göre eğitmekte ve sonrasında bu sınıflandırıcıları tahmin için birleştirmektedir. Yükseltme yöntemi torbalama yönteminden farklı olarak sıralı bir yöntem olması sebebiyle burada paralel işlemler kullanılamamaktadır. Şekil 2.27'de yükseltme yöntemi topluluk akış diyagramı gösterilmiştir.



Şekil 2.27: Yükseltme Yöntemi İş Akış Diyagramı

2.3.3. Oylama Yöntemi (Voting)

Topluluk oylama yöntemi, bir ya da daha fazla sınıflandırma algoritması aynı eğitim setiyle eğitilebilmekte ya da tek bir model aynı veri seti ile farklı parametre değerleri kullanılarak eğitebilmektedir. Bu şekilde farklı sınıflandırma modelleri oluşturulmakta ve sonuç olarak elde edilen tüm çıktılar oylama yöntemi kullanılarak nihai çıktı değeri üretilmektedir. Bazı durumlarda bireysel sınıflandırıcılar için kullanılan modeller homojen olmayabilir. Böyle durumlarda farklı öğreniciler eğitilebilmektedir. Oylama yöntemi tez çalışmamızda sert oylama (Hard Voting) ve olasılığa dayalı (Soft Voting) olarak kullanıldığı için bu iki yöntem özellikle açıklanmıştır [60]. Şekil 2.28'de oylama yöntemi topluluk akış diyagramı gösterilmiştir.



Şekil 2.28: Oylama Yöntemi İş Akış Diyagramı

2.3.3.1. Sert Oylama

Sert oylama, topluluk sınıflandırma yöntemleri arasında en sık kullanılan yöntemdir. Burada her sınıflandırıcı bir sınıf için oy kullanmaktadır. Çoğunluk oyuyla son sınıf tahmini belirlenmekte ayrıca nihai çıktı tahmini de oyların yarısından fazlasını alan sınıflandırıcı olmaktadır. Genel anlamıyla çoğunluk kuralları uygulanmaktadır. Burada bulunan modellerden herhangi bir model oyların yarısından fazlasını alamazsa eğer uygulanan sert oylama yönteminin doğru bir sonuç veremeyeceği söylenebilmektedir [60]. Sınıf etiketi Y, her Cj sınıflandırıcısının oyu ile aşağıdaki ki formüle göre belirlenmektedir.

$$Y = \text{mode}\ \{C_1(X), C_2(X), \ldots, C_m(X)\}\ [j= 1, 2, 3,\ldots,m]$$

2.3.3.2. Olasılığa Dayalı Oylama

Olasılığa dayalı oylama her modelin eşit öneme sahip olduğu sert oylama modelinin aksine bazı modellerin öneminin artırılabildiği, her bir sınıflandırıcının belirli bir veri noktasının belirli bir sınıfa ait olduğunu olasılıksal olarak belirleyebilmektedir. Tahminler sınıflandırıcının önemine göre yapılmakta ve en yüksek ağırlıklandırılmış olasılık toplamına sahip model oylamayı kazanmaktadır. Burada ki önemli husus, son olarak ortaya çıkan nihai çıktı sınıflandırıcılar için tahmin edilen olasılıklara bağlı olarak tahmin edilmektedir. Olasılığa dayalı oylama yöntemi sınıf etiketi Y, olasılıkların toplamı argmax / en büyük tahmin edilen değerine dayalı bir etiket tahmin etmektedir [60].

$$Y = \text{argmax}_i \sum_{j=1}^{m} WjPij \; [J = 1,2,3,\dots,m;\; i = 1,2,3,\dots,n]$$

2.4. MEDİKAL GÖRÜNTÜLER KULLANILARAK YAPILAN DERİN ÖĞRENME UYGULAMALARI

Bu bölümde derin öğrenme ve makine öğrenimi teknikleri kullanılarak beyin tümörü tespiti ve sınıflandırılması, göğüs tümörü ve kanseri sınıflandırılması ve cilt kanseri teşhisi ve sınıflandırılmasına ilişkin güncel literatür bilgisi verilmiştir. Tez kapsamında literatür üzerinde yapılan çalışmalarda üzerinde durulan temel konular öncelikle beyin tümörlerinin özelliklerinin tespiti, beyin tümörlerinin sınıflandırılması ve kullanılan modellerin başarı oranlarıdır. Bununla birlikte göğüs kanseri erken evre tespiti ile ilgili yapılmış çalışmalar, tümörlerin sınıflandırılması ve modellerin başarı oranları incelenmiştir. Son olarak cilt kanseri ile ilgili literatürde çok fazla çalışma bulunmamasına rağmen, farklı türde cilt yaralarının ve lekelerinin sınıflandırılması ve bunların zararlı hücre yapıları olup olmadığına karşın yapılan çalışmalar incelenmiştir.

2.4.1. Medikal Görüntüler Kullanılarak Beyin Tümörü Tespiti İçin Yapılan Derin Öğrenme Uygulamaları

Son yıllarda özellikle manyetik rezonans görüntüleri kullanılarak çok fazla tümör tespiti çalışması yapılmıştır. Genelde birinci derece özellikler, dokular, hücre şekilleri ve yayılımları tıbbi görüntüleme teknikleriyle elde edilerek cerrahi prosedür gerektirmeden tespit yöntemleri geliştirilmiştir. Yapılan çalışmalar incelendiğinde CNN ve U-Net algoritmaları kullanılarak birçok çalışma yapıldığı görülmektedir.

Gürkahraman ve Karakiş [61], yaptıkları çalışmada farklı beyin tümörlerinin (hipofiz, glioma ve menenjiyom tümörü) MR görüntüleri üzerine CNN algoritmaları kullanılarak

sınıflandırılması ve koronel, aksiyel ve sagital gibi beyin kesitlerinin sınıflandırmada ki öneminin belirlenmesi amaçlanmıştır. Araştırmacılar burada yeni bir model önermiş ve bu model DenseNet algoritmasından türetilmiştir. Çıkan sonuçlar klasik makine öğrenmesi algoritmalarıyla sınıflandırılmış ve yüksek başarı yüzdelerine ulaşılmıştır.

Noreen ve arkadaşları [62], yaptıkları çalışmada üç farklı beyin tümörü MR görüntülerinden ve önceden eğitilmiş modellerden faydalanılarak, normal görüntülerden tıbbi görüntülerde farklı olan alt katman görüntüleri çıkarmayı denemişlerdir. Burada problemin çözümü gerçekleştirilirken öznitelik çıkarma ve birleştirme yöntemleri kullanılmıştır. Bu problemde Inception-v3 ve DenseNet mimarileri kullanılmış ve bu iki modelden de sırasıyla %99,34 ve %99,51 başarı oranı sağlanmıştır.

Kazdal ve arkadaşları [63], beyin tümörü tespiti için manyetik rezonans görüntülerinden faydalandıkları bir çalışma gerçekleştirmişlerdir. Bu çalışmada kural tabanlı bir tespit sistemi ortaya koymuşlar ve morfolojik özelliklerden faydalanmışlardır. Çalışmada 497 beyin MR görüntüsü incelenmiş sırasıyla ön işleme, segmentasyon, tümörlü bölge belirleme ve tümör tespit aşamaları takip edilmiştir. Bu çalışmada %84,26'lık bir başarı yüzdesine ulaşılmıştır.

Ramtek ve Monali [64], yaptıkları çalışmada malign ve normal beyin hücreleri görüntülerinden faydalanarak bunları istatistiksel doku özelliklerini sınıflandıracak şekilde bir sınıflandırma algoritması oluşturmuştur. Burada en yakın komşu algoritması kullanılmış ve %80'lik bir sınıflandırma doğruluğuna ulaşılmıştır. Bu çalışmaya benzer olabilecek şekilde Gadpayleand ve Mahajani [65], normal ve kötü huylu beyin MR görüntülerini sınıflandırmış ve kullandığı yapay sinir ağı algoritmasıyla %72,5 oranında başarı elde etmiştir.

Sultan, Salem ve Al-Atabany [66], yaptıkları çalışmada iki farklı veri setine ait sınıflandırma yaparken farklı etiketler uygulayarak bunların sınıflandırmada ki başarı oranlarını görmeyi amaçlamışlardır. Açık erişimi olan toplamda 3580 beyin MR görüntüsünden farklı tipte beyin tümörlerini sınıflandırmak için CNN tabanlı bir derin öğrenme algoritması önermişlerdir. Burada kullanılan veri setlerinde birinci, ikinci, üçüncü ve dördüncü evre tümörler sınıflandırılmıştır. İlk sınıflandırma da doğruluk oranı %96,13'tür.

Sobhaninia ve arkadaşları [67], yaptıkları çalışmada daha fazla öznitelik çıkarımı yapmak için segmentasyon işlemi uygulayarak iyi bir sınıflandırma algoritması modellemeyi amaçlamışlardır. Toplamda 3064 gri tonlamalı görüntü 3 farklı veri kümesine (koronal, sagital, eksenel) aittir. Önerilen modelin Dice skoru %80.03 olarak gözlemlenmiştir.

Arı ve Hanbay [68], yaptıkları çalışmada tümörün bulunduğu bölgenin tespit edilebilmesi için bir derin öğrenme mimarisi geliştirmişlerdir. Bu mimari bölgesel sinir ağları tabanlıdır. Bu ağ

ağ yapısı CNN mimarisini kullanan bir yapıdır. Çalışmada kullanılan veri setleri farklı bölgesel sinir ağları tabanlarıyla tasarlanmış ve farklı yüzdelerde başarı oranlarına ulaşmışlardır.

Demirhan ve Güler [69], bir nöro-bulanık çıkarım sistemi kullanarak beyin MR görüntülerini kurucu dokulara ayırmışlardır. MR görüntülerini kullanarak, beyin omurilik sıvısı, ödem ve tümör gibi hastalıklı dokuları ayırmışlardır. Literatürde yapılan benzer çalışmalardan ayrı olarak kafatasını ayırarak sadece beyin dokusu üzerinden değerlendirme yapmışlardır. Sistemden elde edilen istatistiksel öznitelikler kullanılmış ve sonuçlar segmentasyon yapılan doku alanları ile karşılaştırılmış ve Dice indeksi ile değerlendirilmiştir. Nöro çıkarım sistemi MR görüntülerinin segmentasyon işleminde oldukça başarılı sonuçlar verdiği çalışmanın sonuç kısmında gösterilmiştir.

Abidin ve arkadaşları [70], yaptıkları çalışmada glioblastoma ve metastaz tümörlerini tespit etmek amacıyla AdaBoost sınıflandırma algoritmasını kullanmışlardır. Burada CNN ve genetik algoritmaya dayalı sınıflandırma çalışması yapılmış ve iki birleşik düzenlemenin bir modeli önerilmiştir. Çalışma sonucunda AdaBoost algoritmasından %71 doğruluk oranı elde edilmiştir.

George ve arkadaşları [71], radyomik şekil özelliklerine göre klasik makine öğrenmesi yöntemlerini kullanarak normal ve anormal durumdaki beyin tümörlerini, karar ağacı ve çok katmanlı algılayıcı algoritmalarıyla değerlendirmişlerdir. Benzer bir çalışmada Sajjad ve arkadaşları [72], yaptıkları çalışmada beyin tümörü sınıflandırması için CNN ile birleştirilmiş ve genişletilmiş bir veri çoğaltma yöntemi önermişlerdir. VGG-19 algoritması kullanılarak yapılan çalışmada model veri artırmadan önce ve sonra bazı optimizasyon teknikleri uygulanmış ve yüksek başarı yüzdelerine ulaşılmıştır.

Divya, Padma Suresh ve John [73], yaptıkları çalışmada glioma, meningioma ve hipofiz gibi tümör türlerine ait MR beyin görüntülerinin sınıflandırılması amacıyla CNN algoritmalarından ResNet mimarisini kullanmışlardır. Çalışmada daha iyi bir sonuç elde edilmesi amacıyla katmanlarda değişiklik yapıp katman sayıları artırılmıştır. Eğitim sırasında sırasıyla 1426, 708 ve 930 görüntü içeren üç farklı tümör tipine sahip 233 hastanın 3064 T1 ağırlıklı MR görüntülerinden oluşan Figshare MRI veri seti kullanılmıştır. Çalışma sonucunda elde edilen doğruluk oranı %98,67'dir.

Paul ve arkadaşları [74], transfer öğrenme tekniği kullanarak önceden eğitilmiş ResNet50 mimarisini kullanarak, giriş görüntüleri üzerinden kontrast germe ve histogram eşitleme yöntemlerini uygulamış, kesinlik ve duyarlılık açısından başarı yüzdelerini karşılaştırmışlardır.

Burada %99,15 gibi kontrast gerdirmeli ResNet50 yöntemi için oldukça yüksek bir başarı oranı yakalayarak sınıflandırma işlemi yapmışlardır.

Rehman ve arkadaşları [75], yaptıkları çalışmada hipofiz, glioma ve meningioma gibi beyin tümör tiplerini üç farklı evrişimsel sinir ağında; VGGNet, GoogleNet ve AlexNet sınıflandırmışlardır. Yapılan çalışmada VGG16 mimarisi sınıflandırma ve algılama açısından %98,69 oranında bir başarı yüzdesi yakalamıştır.

Eker ve Duru [76], derin öğrenme yöntemlerini kullanarak medikal görüntü işleme alanında yapılan uygulamaları incelemişlerdir. Burada en sık kullanılan yöntemlerden olan segmentasyon, sınıflandırma, görüntü oluşturma, teşhis, iyileştirme ve dönüştürme işlemlerini literatürde yapılan örnekleriyle karşılaştırmış ve sonuçlar sunmuşlardır. Bununla birlikte BRaTS 2020 veri setini kullanarak beyin tümörü segmentasyonu gerçekleştirmişlerdir. Sonuç olarak %86 Dice benzerlik oranı ve %80 hassasiyet yüzdesi elde etmişlerdir.

Anitha ve Raja [77], beyin görüntülerini iki sınıfa ayırarak rastgele orman sınıflandırıcı tabanlı bir sistem önermişlerdir. Öncelikle ön işleme kısmında MR görüntülerine adaptif medyan filtre uygulanmıştır. Buradaki amaç görüntü kenarlarındaki kenar piksellerini korumaktır. Daha sonra tümörlü bölgeyi belirleyebilmek amacıyla özellik çıkarımı uygulanmıştır. Tümörlü ve tümörsüz bölgenin birbirinden ayrılmasını sağlamak ve görüntülerin şiddet tanısını sınıflandırmak için ağırlıklı oylama tekniği kullanan rastgele orman sınıflandırıcısı tekniği kullanılmıştır.

Akkuş ve arkadaşları [78], yaptıkları çalışmada LGG 1p/19q veri setini kullanarak CNN algoritmalarıyla kontrast sonrası MR görüntülerinden oluşan 159 LGG 1p/19q durumunu tahmin etmek için klasik makine öğrenmesi teknikleriyle %93 hassaslık, %82 özgüllük ve %87 doğruluk elde etmişlerdir.

2.4.2. Medikal Görüntüler Kullanılarak Göğüs Tümörü Tespiti İçin Yapılan Derin Öğrenme Uygulamaları

Derin öğrenme çalışmalarının belki de en sık kullanıldığı tıbbi alan akciğer ve göğüs tümörlerinin görüntüleridir. Özellikle bilgisayarlı tomografi görüntüleri kullanılarak çok fazla tümör tespiti çalışması yapılmıştır. Son iki yılda özellikle tüm dünyayı saran Covid-19 virüsünün de etkisiyle bu alanda yapılar çalışmalar bir hayli hız kazanmıştır. Yapılan çalışmalarda çoğu zaman CNN mimarileri tercih edilmekte ve güncel çalışmalar sürekli geliştirilmektedir.

Alakwaa ve arkadaşları [79], yaptıkları çalışmada Data Science Bowl ve Kaggle kütüphanesinden aldıkları verileri inceleyerek problemin çözümü için öncelikle CNN tabanlı

bir algoritma önermişlerdir. Sınıflandırma işlemi sonrasında nodül tespiti için U-Net CNN mimarisini kullanmışlardır. Sonuç olarak U-Net mimarisinin doğruluk oranı %86,6 olarak tespit edilmiştir.

Anthimopoulos ve arkadaşları [80], yaptıkları çalışmada akciğer görüntülerinden farklı hastalık dokularına ait türleri sınıflandırmak amacıyla CNN tabanlı model önermişlerdir. Önerdikleri ağda 5 evrişimsel katman, 1 havuz katmanı ve 3 tane bağlı katman bulunmaktadır. Dokuların sınıflandırılması için AlexNet, VGG ve LeNet algoritmaları kullanılmış, tespiti için CNN algoritmaları kullanılmıştır. Sonuç olarak CNN algoritmasının diğer algoritmalara göre başarı yüzdesi %85,61 doğruluk oranı ile daha yüksek sonuçlar verdiğini tespit etmişlerdir. Yine Bektaş ve arkadaşları [81], çalışmalarında meme kanserinin erken evre teşhisi için farklı makine öğrenmesi algoritmaları kullanmışlardır ve bunların doğruluk oranlarını karşılaştırmışlardır. Burada yapılan çalışmada 139 öznitelik ile %90,72 doğruluk oranında meme kanserinde etkin hücre tespiti yapılmıştır.

Nayak ve arkadaşları [82], Covid-19 hastalığının erken tespiti için X-ray görüntüleri kullanılarak derin öğrenme destekli bir yöntem önermişlerdir. Burada sekiz adet önceden eğitilmiş CNN mimarisi değerlendirilmiştir. En iyi performans ResNet mimarisi ile %98,33 doğrulukla gerçekleştirilmiştir. Xu ve arkadaşları [83], derin öğrenme yöntemlerini kullanarak bilgisayarlı tomografi görüntüleri sayesinde Covid-19 hastalığı taşıyan ve sağlıklı bireyleri ayırt etmeyi amaçlamışlardır. Bu çalışma yüksek oranda doğruluk sağlamıştır. Hemdan ve arkadaşları [84], Covid-19'lu vakaları diğer hastalardan ayırt etmek amacıyla 25 pozitif vakanın görüntülerini kullanmışlardır. Bu çalışma GoogleNet ve ResNet gibi 7 farklı eğitim mimarisi içermektedir. Burada en yüksek doğruluk oranı %90 başarı yüzdesiyle VGG19 ile elde edilmiştir.

Dandıl [85], yaptığı çalışmasında Bilgisayar Destekli Tespit (CAD) sistemi akciğer tümörlerinin erken aşamada teşhisi için bir yöntem oluşturmuştur. Yapılan çalışmada BT görüntüleri üzerinden sinir ağlarını modelleyerek tümörlerin segmentasyon işlemi gerçekleştirilmiştir. Çalışmada toplam 40 hastadan alınan 1128 adet BT görüntüsü başarılı olarak segmente edilmiş olup daha sonrasında sınıflandırma işlemine tabi tutulmuştur.

Deperlioğlu ve arkadaşlarının [86], yaptıkları çalışmada retina görüntülerinden diyabetik retinopatiyi teşhis etmek amacıyla derin öğrenme teknikleri kullanılmıştır. Retina görüntülerini iyileştirmek amacıyla V dönüşüm algoritması ve histogram işlemlerini içeren hibrit bir yöntem önermişlerdir. Görüntü işleme ve sınıflandırma algoritması olarak CNN mimarisi kullanılmıştır.

Garcia ve arkadaşları [87], X-ray görüntülerini sınıflandırmak amacıyla önceden eğitilmiş Xception ağını kullanmışlardır. Toplamda 5232 görüntü kümesine sahip 1-5 yaş arasındaki çocukların X-ray görüntülerinden oluşan veri kümesinden %91 oranında F1-skoru elde edilmiştir. Bu çalışmanın sonuç bölümünde CNN mimarisine sahip benzer algoritmalar karşılaştırılmıştır.

Chouhan ve arkadaşları [88], yaptıkları çalışmada transfer öğrenme ve X-ray görüntülerini sınıflandırmak amacıyla GoogleNet, ResNet, AlexNet, DenseNet ve Inception gibi mimarileri kullanmışlardır. Veri setindeki tüm görüntüler önceden eğitimli CNN algoritmaları kullanılarak elde edilmiştir. Bu çalışmada performans artırmak amacıyla veri önişleme ve çoğaltma işlemleri yapılmış ve önceden eğitimli mimariler sayesinde %96 düzeyinde bir başarı yüzdesine ulaşılmıştır.

Siddiqi ve arkadaşlarının [89], yapmış oldukları çalışmada zatürre hastalığının önceden tespit edilmesine yönelik bir çalışma gerçekleştirilmiştir. İki sınıftan oluşan veri setini sınıflandırabilmek için toplamda 18 katmandan oluşan yeni bir model önerilmiştir. Modelin eğitilmesi için toplamda 5856 adet X-ray görüntüsü kullanılmış ve modelin doğruluk oranı %94,39 olarak bulunmuştur. Burada araştırmacılar veri önişlemesi ve çoğaltma yapılması halinde başarı oranlarının daha da artacağını belirtmişlerdir.

Vesal ve arkadaşları [90], tarafından BACH 2018 yarışması için yapılan çalışmada meme kanserinin normal, iyi huylu, insitu karsinomu ve invaziv karsinom olarak 4 sınıfa ayıran bir CNN algoritması önerilmiştir. ResNet ve Inception gibi ön eğitimli ağların kullanıldığı çalışmada, sınıflandırma doğruluğu 3 kat çapraz validasyon ile değerlendirilmiştir. Yapılan analizler sonucunda Inception V3 ağı ResNet'den daha başarılı olduğunu göstermiştir.

Matsuki [91], çalışmasında yapay sinir ağlarını kullanarak normal ve anormal olan akciğer kanseri görüntülerinin teşhisi için yardımcı bir model önermiştir. Doktorların tanı koymasıyla birlikte ayrıca kullanılan yapay sinir ağı modeli karşılaştırıldığında yapay sinir ağı modelinin daha yüksek doğrulukta sonuç verdiği bulunmuştur. Yapay sinir ağı modelinin başarı oranı %95 civarında bulunmuştur.

2.4.3. Medikal Görüntüler Kullanılarak Cilt Tümörü Tespiti İçin Yapılan Derin Öğrenme Uygulamaları

Yapay zekâ uygulamaları tıp alanında oldukça sık kullanılmasına rağmen bazı problemlerin çözümünde makine öğrenmesi ve derin öğrenme yöntemleri yeterince kullanılamamaktadır. Cilt kanseri tanısı ve tespiti için literatürde çok fazla çalışma yapılmamakla birlikte yapılan çalışmalarda genellikle klasik makine öğrenmesi teknikleri kullanılmıştır.

Filali ve arkadaşları [92], yaptıkları çalışmada ISIC 2017 veri setinde bulunan 2150 adet dermoskopi görüntüsünü eşikleme yöntemini kullanarak segmente etmişlerdir. Cilt kanserinin tespiti için lezyon bölgesinin belirlenmesinden sonra ilgili bölgeye ait renk ve doku örnekleri çıkartılarak boyut küçültme işlemi gerçekleştirilmiştir. Son kısımda belirlenen özellikler klasik makine öğrenmesi algoritması SVM ile sınıflandırılmış ve %84'lük bir başarı yüzdesi elde edilmiştir.

Monika ve arkadaşları [93], ISIC kütüphanesinden bulunan 800 adet dermoskopi görüntüsünden K-means algoritmasını kullanarak cilt lezyonlarını sınıflandırmak için segmentasyon işlemi uygulamışlardır. Bu problemde özellik çıkarımı yapılmış ve çıkarılan özellikler SVM algoritması ile daha sonra tekrar sınıflandırılmıştır. Sonuç olarak %96,2 'lik başarı yüzdesi elde edilmiştir.

Balaji ve arkadaşları [94], 2150 görüntünün olduğu ISIC 2017 veri setinden faydalanarak grafik kesimli segmentasyon işlemi gerçekleştirmişlerdir. Lezyon bölgesinde bulunan doku, renk ve asimetrik özellikleri ABCD kuralına göre çıkartarak bu özellikleri Naive Bayes algoritmasında sınıflandırmışlardır. Sınıflandırma sonucu %91,8 doğruluk yüzdesine ulaşılmıştır.

Kostopoulos ve arkadaşları [95], mikroskobik görüntülerde pigmentli cilt lezyonlarını tespit etmek amacıyla Olasılıksal Sinir Ağı sınıflandırma metodunu kullanmışlardır. Sonuç olarak yüksek başarı sağlanmış ve araştırmacılar tarafından yöntemin daha da geliştirilebilir olduğu vurgulanmıştır. Benzer bir çalışmada Yang ve arkadaşları [96], avuç içlerindeki ve ayaklardaki renk pigmentasyonun çizgili ve düz olduğunu ayırabilen Akral Melanomun saptanması için otomatik bir algoritma sunmuş ve %99 civarında bir başarı yüzdesine ulaşmışlardır.

İsmail ve arkadaşları [97], yine ISIC kütüphanesinden alınan 1635 dermoskopi görüntüsünün özelliklerini, ölçekle değişmeyen özellik çıkarımı ve rastgele orman sınıflandırması yaparak %67,5 düzeyinde bir doğruluğa ulaşmışlardır. Benzer bir sınıflandırma probleminde Tajeddin ve Asl [98], yaptıkları çalışmada SVM ve RUSBoost sınıflandırma yöntemini kullanarak demografik görüntülerde nevus ve atipik nevus'tan lezyonları sınıflandırmak amacıyla bir algoritma geliştirmişler ve %99'luk bir başarı yüzdesi sağlamışlardır.

Barata ve arkadaşlarının [99], çalışmasında renk sabitliği algoritması incelenmiştir. Gri dünya, maksimum-RGB, grinin tonları ve genel gri dünya. Bu dört renk sabitliği, çok kaynaklı görüntülerin sınıflandırılmasını iyileştirdiğinde, özellik olarak yalnızca bir boyutlu RGB diyagramlarını kullanarak sistemin duyarlılığını ve özgüllüğünü oldukça yüksek bir seviyeye çıkarmışlardır.

Dermoskopi görüntüleri için dizayn edilmiş olan bilgisayar destekli tanı sistemlerinin en büyük özelliği sağlamlıktır. Burada sistemin doğru çalışması bulunduğu yer, sistemin kurulumu ve onu kullanan personel de dahil olmak üzere dış etmenler sistemin sağlamlığını oldukça etkileyen faktörlerdir. Özellikle aydınlanma ve yakalama gibi değişiklikler görüntülerin renklerini değiştirebilmekte ve sistemin performansını düşürebilmektedir. Bu nedenden dolayı bir problemin çözümünden önce ya da sistemi eğitmeden önce dermoskopi görüntülerinin renklerini kesinlikle normalleştirmek çok önemlidir. Ortamın duyarlılık seviyesini yükseltmek sonuç doğruluğu için son derece önemlidir.

Abbas ve arkadaşlarının [100], yapmış oldukları çalışmada cilt tümörünün segmentasyonu için bir yaklaşım geliştirilmiştir. Burada önerilmekte olan yöntem çoklu bölgeyi genişleten bölge tabanlı aktif kontur bir algoritma sunmaktadır. Yine benzer bir çalışmada Norton ve arkadaşları [101], dermoskopi görüntülerinden cilt lezyonlarını tespit etmek amacıyla bir segmentasyon uygulaması geliştirmişlerdir. Çalışmanın akışı ön işleme, lezyon segmentasyonu ve bölge segmentasyonundan oluşur. Yöntem 107 adet melanositik olmayan cilt lezyonu ve 319 adet melanositik cilt lezyonu üzerinde test edilmiştir. Burada hassasiyet ve duyarlılık oranları melanositik cilt lezyonları üzerinde yapılan çalışmada çok daha yüksek oranda başarı yüzdesi sağladığı görülmektedir.

3. YÖNTEM

3.1. KULLANILAN VERİ SETLERİ

Bu bölümde tez çalışmasında kullanılan veri setleri, problemin tanımı, değerlendirme kriterleri, kullanılan yazılım dili ve uygulama platformları hakkında bilgiler verilmiştir.

3.1.1. Beyin Tümörü ve Yapısı

Beyin insan vücudundaki en karmaşık ve önemli yapılardan birisidir. Milyonlarca bağlantıyla birbirine bağlanan 50 milyardan fazla sinirden ve birlikte çalışan özel bir alandan oluşmaktadır. Beyin tüm vücudun kontrol merkezi olmakla birlikte kalp, akciğer, damar ve diğer tüm organların koordineli bir şekilde çalışmasını organize etmektedir. Tüm duyu organlarımız beyne bağlıdır. Beyin üç temel bölüm olmak üzere ön beyin, orta beyin ve arka beyin olarak tanımlanmaktadır. Beynin tüm kısımları vücutta önemli fonksiyonları kontrol etmekle birlikte, nefes alıp verme, kalp atış hızı gibi hayati öneme sahip fonksiyonları beynin arka kısmı kontrol etmektedir. Orta beyin, beynin üst kısmında yer almaktadır ve bazı refleks hareketlerinin ve bilinçli hareketlerin kontrolünü sağlamaktadır [102].

Çocuklarda büyümek ve gelişmek için yeni sağlıklı hücreler oluşurken, yetişkinlerde zarar gören ve yaşlı hücrelerin yerini yeni hücreler almaktadır. Beyin tümörleri ise anormal hücrelerin oluşması ve çoğalmasıyla özellikle yetişkinlerde gelişen ölümcül bir hastalıktır. Genellikle merkezi sinir sistemi veya beyin hücrelerinin anormal büyümesiyle ortaya çıkmaktadır. Beyin tümörleri kendi içerisinde birincil ve ikincil beyin tümörleri olarak iki gruba ayrılmış, bu iki grupta bulunan tümör çeşitleri kendi içerisinde ayrıca kategorize edilmiştir. Beyin tümörlerinin hangi gruba ait olduğunun bilinmesi ve sınıflandırılması hayati bir önem taşımaktadır [103].

Birincil beyin tümörleri beynin içerisinde bulunan bir hücre ya da dokudan kaynaklı tümörlerdir. Bunlar kendi aralarında iyi huylu ve kötü huylu olmak üzere kategorize edilebilir. İyi huylu tümörler tek bir bölgede oluşmakta ve görece yavaş büyümektedirler. Cerrahi operasyonla doğru işlem yapıldığı takdirde bu tümörler büyük olasılıkla tekrar oluşmamaktadır. Tümörün tamamen çıkartılması ve bulunduğu yerin temizlenmesi oldukça önemlidir [103].

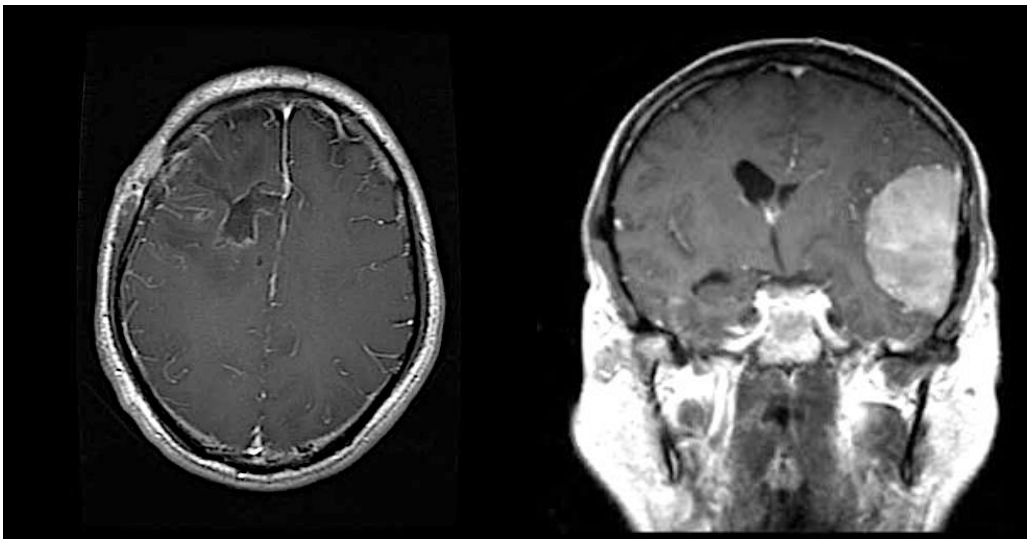
Kötü huylu tümörler ise hızlı bir yayılım özelliğine sahip, beyin ve omurilik bölgesinde çoğalan tümörlerdir. Kötü huylu tümörler ikincil beyin tümörleri sınıfına girmekte ve zaman zaman

vücudun başka bir bölgesinde başlayarak beyine kadar yayılabilmektedirler. Bu tümörler büyüme hızlarına bağlı olmakla birlikte 1 ve 4 arasında derecelendirilmektedirler. Derecelendirme ölçütleri göz önüne alındığında 1 ve 2 derece iyi huylu olarak, 3 ve 4 ise kötü huylu tümör olarak kabul edilmektedir [103].

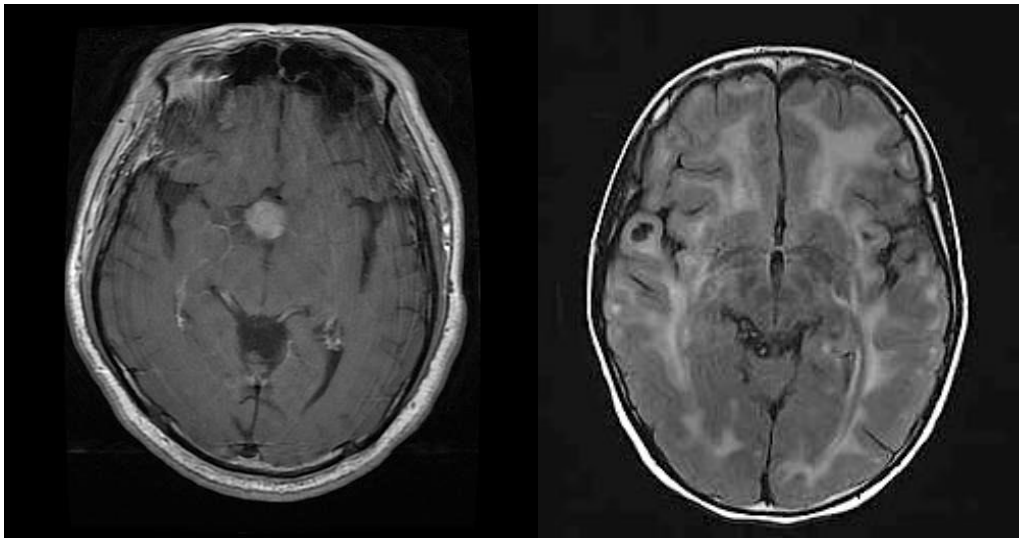
Beyin tümörlerinin erken teşhisi ve sınıflandırılması, tıbbi görüntüleme alanında önemli bir araştırma alanıdır ve buna bağlı olarak hastaların hayatını kurtarmak için en uygun tedavi yönteminin seçilmesine yardımcı olur. Uzmanların bilgisayar destekli sistemleri kullanarak tümör tespiti yapması daha hızlı sonuçlar vermekle birlikte geleneksel yöntemlerle yapılan hatalarında önüne geçmektedir. Bu tez çalışmasının birinci veri kümesini oluşturan beyin tümörü veri seti, MR görüntülerinden faydalanılarak beyin tümörlerinin teşhis edilmesi ve sınıflandırılması amaçlanmıştır.

3.1.2. Beyin Tümörü Veri Seti

Bu çalışmada kullanılan MR görüntüleri Kaggle platformunda Masoud Nickparvar tarafından açık erişimli bir şekilde yayınlanan ‘‘Brain Tumor MRI Dataset’’ veri seti kullanılmıştır. Bu veri seti 4 ayrı sınıftan oluşan toplamda 7022 adet beyin MRI görüntüsünü içermektedir. Aşağıdaki şekillerde dört ayrı sınıftan oluşan görüntüler ve ayrıca bu sınıfların sayıları verilmiştir [104].



Şekil 3.1: Glioma ve Meningioma Beyin Tümörü



Şekil 3.2: Pituitary ve Notumor (Sağlıklı) Beyin Tümörü

Bu veri seti 4 sınıfa ayrılan insan beyni MRI görüntüsünü içerir. Bu 4 sınıf Glioma, Meningioma, Pituitary ve Tümör olmamasıdır. Orijinal veri seti 5711 eğitim verisi ve 1311 test eğitim verisi içermektedir. Ancak değerlendirme amacıyla test setinin %40'ı değerlendirme setine geriye kalan %60 ise eğitim setine ayrılmıştır.

3.1.3. Göğüs Tümörü ve Yapısı

Göğüs kanseri ve tümörleri yapılan araştırmalara göre 20.yüzyılda insan hayatını en çok etkileyen kanser türü olarak belirlenmiştir. Tütün ürünleri kullanımı, yüksek miktarda alkol tüketimi, stresli şehir hayatı ve radyasyona maruz kalma gibi birçok sebepten dolayı akciğer kanseri, kolon kanseri, pankreas kanseri ve prostat kanseri gibi yaygın hastalık türleri ortaya çıkmaktadır [105].

Göğüs tümörü ve kanseri yaygın olarak göğüs ucuna sütü boşaltan kanallarda ya da süt bezlerinde oluşmaktadır. Göğüs içerisinde lobül hücreleri olarak adlandırılan dokuların anormal bir şekilde büyümesi ve hücrelerin hızlı bir şekilde bölünmesi durumunda ortaya çıkmaktadır. Bazı durumlarda göğsün yağlı ve lifli bağ dokularında kanser dokuları da oluşabilmektedir. Göğüs tümörleri de iyi huylu (Malign) ve kötü huylu (Benign) olmak üzere iki grupta incelenmektedir. İyi huylu tümörler genel olarak tedavi edilebilir ve ölümcül riski düşük olan tümörlerdir. Bu tip tümörler insan vücudunda sadece oluştukları bölümde büyüyebilmektedirler. Aynı zamanda kötü huylu tümörler erken teşhis ve tedavi edilerek kontrol altına alınmazsa hızlı bir şekilde diğer organlara da yayılabilmektedirler [106].

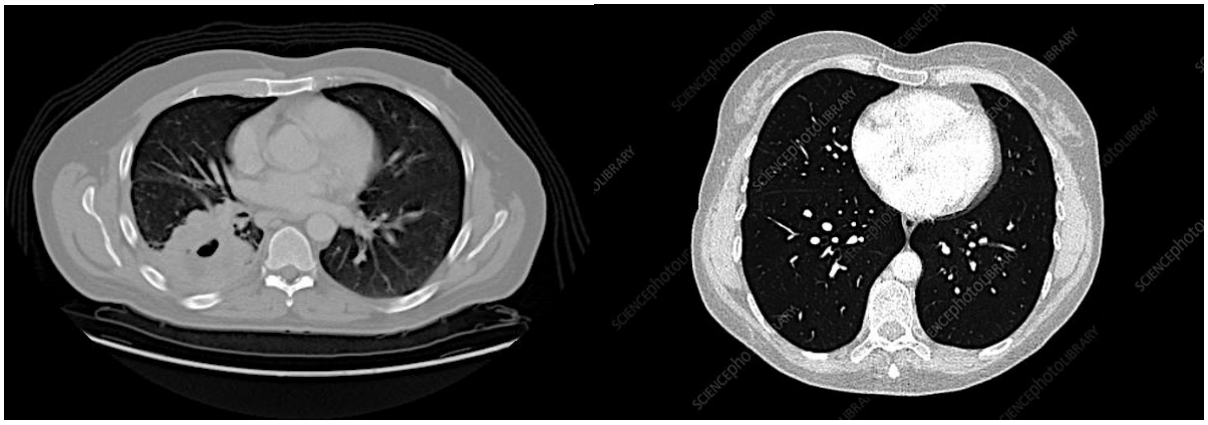
Genel olarak kanserli hücreler sağlıklı hücrelere göre daha büyük bazen de çok daha küçük olup normal hücre görüntülerini kaybetmişlerdir. Sağlıklı bir hücrenin genel görünümüyle bir kanser hücresinin görüntüsü arasında oldukça ciddi farklar vardır. Kanser hücreleri genellikle düzensiz şekillere sahiplerdir. Son yıllarda kadınlarda çok sık bir şekilde görülmekte olan göğüs kanseri, hastalığın erken evrelerinde tümörün fiziki muayeneyle hissedilemeyecek kadar küçük olmasından dolayı çoğu zaman hiçbir belirti göstermemektedir [106].

Göğüs tümörlerinin erken teşhisi tıbbi görüntüleme alanında son derece aktif ve önemli bir alandır. Son yıllarda özellikle vakaların artması ve toplumda bu alanda farkındalık oluşmasıyla birlikte kadınların her yıl düzenli olarak Mamografi çektirerek anormal bir durum oluşmasının hemen öncesinde önlem alınabilmektedir. Görüntüleme sistemlerinin son yıllarda oldukça gelişmesi en küçük hücre yapısında ki değişimin bile görüntülenmesini sağlamaktadır. Bu tez çalışmasının ikinci veri kümesini oluşturan göğüs tümörü veri seti bilgisayarlı tomografi görüntüleri kullanılarak göğüs tümörlerinin teşhis edilmesi ve sınıflandırılması amaçlanmaktadır.

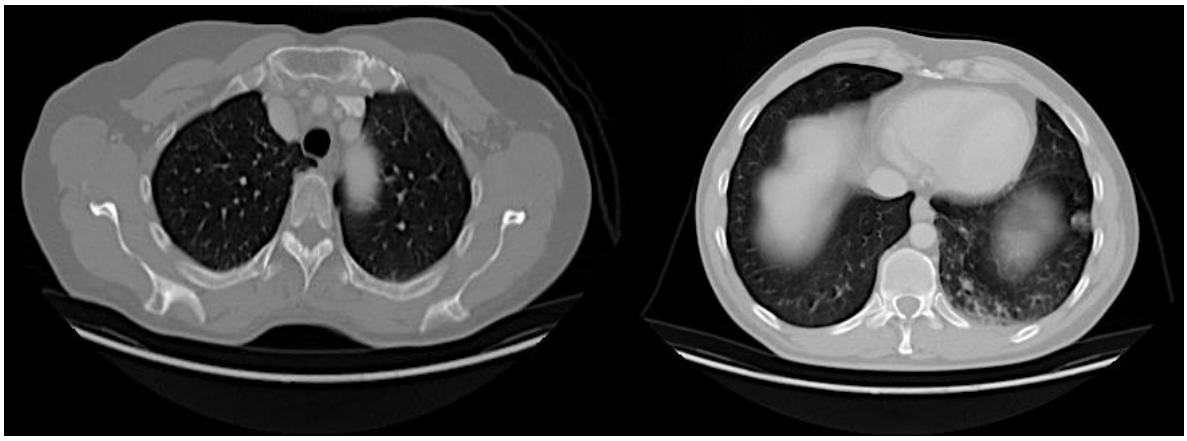
3.1.4. Göğüs Tümörü Veri Seti

Bu çalışmada kullanılan bilgisayarlı tomografi görüntüleri Kaggle platformundan Mohammed Hany tarafından açık erişimli bir şekilde yayınlanmış olan ‘‘Chest CT-Scan Dataset’’ veri seti kullanılmıştır. Bu veri seti 3 farklı kanser türünün Adeno Karsinom, büyük hücreli Karsinom, Skuamöz hücreli Karsinom olduğu ve bir sınıfın normal göğüs görüntülerini içerdiği dört sınıf bilgisayarlı tomografi görüntüleri içermektedir. Veri seti toplamda 1000 örnek içermektedir. Orijinal veri seti %70 eğitim, %20 test ve %10 değerlendirme setine ayrılmış olup, bu çalışmada da orijinal haliyle kullanılmıştır. Test için alınan veri seti incelendiğinde 120 adet adenokarsinom görüntüsü, 51 adet büyük hücreli karsinom, 90 adet Skuamöz hücreli karsinom ve 54 adet tümörsüz normal tomografi görüntüsünden oluştuğu görülmektedir [107].

Aşağıdaki şekillerde dört ayrı sınıftan oluşan göğüs tümörünün görüntüleri verilmiştir.



Şekil 3.3: Adeno Carcinoma ve Notumor (Sağlıklı) Göğüs Tümörü



Şekil 3.4: Large Cell Carcinoma ve Squamous Cell Carcinoma Göğüs Tümörü

Şekil 3.3'de bulunan akciğer Adenokarsinom tümör türü genel olarak kanser vakalarının %30'unu oluşturmakta ve küçük hücreleri olmayan akciğer kanseri oluşumlarının da yarısından fazlasını oluşturan en yaygın kanser türü olarak bilinmektedir. Göğüs bölgesinde özellikle akciğerin dış bölgesinde mukus salgılayan ve nefes almamıza yardımcı olan bezlerde bulunmaktadır. Hastalık belirtisi olan kişilerde öksürük, kilo kaybı ve zayıflık belirtileri göstermektedir. Eğer erken teşhis edilemezse meme, prostat ve pankreas gibi organlara hızlı şekilde yayılım gösterebilmektedir.

Şekil 3.4'de bulunan büyük hücreli karsinom ise akciğerin herhangi bir yerinde bulunabilir ve çok hızlı büyüme gösterebilmektedir. Bu tümör türü genellikle %10-15 arasında görülmektedir. İnsan hayatı için son derece tehlikeli ve erken teşhis edilmemesi durumunda çok hızlı bir şekilde yayılabilmektedir. Aynı şekilde görülen Skuamöz hücreli karsinomlar bronşlar ve akciğerin birleştiği akciğer merkezinde daha sık görülmektedirler. Bunlar küçük hücrelerden meydana gelmekte ve akciğer kanserlerinin %30'unu oluşturmaktadırlar.

3.1.5. Cilt Tümörü ve Yapısı

Cilt kanseri insanlarda çok sık görülen ve ölüm oranı oldukça yüksek olan bir hastalıktır. Birçok kanser türü iyi huylu olmadığı gibi erken teşhis ve tedavi edilmediği durumlarda ölümcül kanser türlerine dönüşebilmektedir. Bu yüzden diğer kanser türleri ve tümörlerde olduğu gibi cilt kanseri ve deri hastalıklarında da hızlı ve erken teşhis insan hayatı için kritik önem taşımaktadır [108].

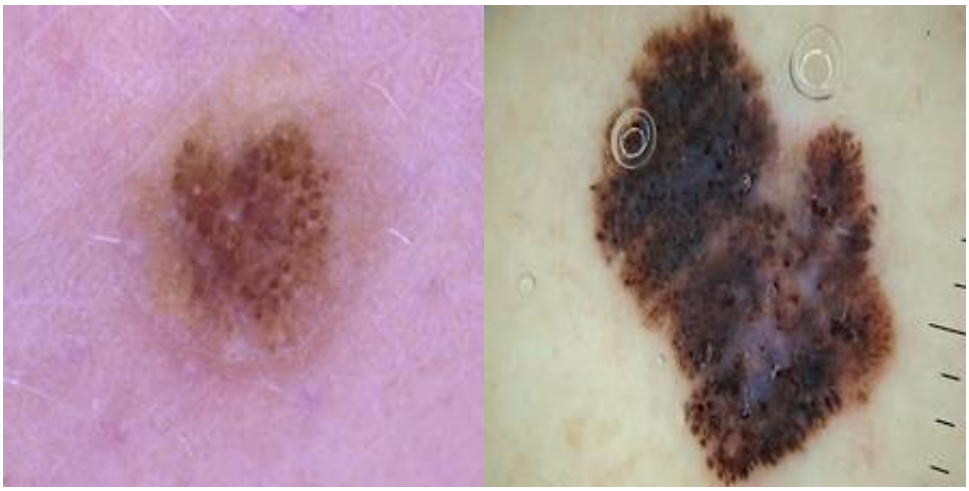
Cilt insan vücudunu saran ve örten en büyük organdır. Vücudu dışardan müdahalelere karşı koruyan, aynı zamanda herhangi bir hasar gördüğünde kendini yenileme özelliğine sahip olan ve toplamda insan ağırlığının ortalama %15'ini oluşturmaktadır. İnsan vücudunda en ince cilt yapısı göz ve çevresinde bulunmakta bununla birlikte en kalın tabaka ise ayak tabanlarında bulunmaktadır. Cilt yapısı 3 katmandan oluşmaktadır. Bunlar epidermis, dermis ve hipodermis olarak adlandırılmaktadır. En dış tabakayı oluşturan kısım epidermis olarak adlandırılmakta, damarlı bir yapı içermeyen bu tabaka keratinosit adı verilen dokulardan oluşmaktadır. Epidermis tabakasının hemen altında dermis tabakası bulunmaktadır. Bu kısım cildin sağlamlığını korumakta ve içerisinde kıl kökleri ve yağ bezlerini barındırmaktadır. Hipodermis ise cildin en alt katmanında yağ dokularından meydana gelen ve cilde enerji veren tabakadır. İçerisinde karbonhidrat yönünden güçlü yağ hücreleri barındırmaktadır [109].

Cilt kanserinin erken teşhisi hastalığın ilerlemesini durdurmak ve tedaviye yanıt alabilmek adına oldukça önemlidir. Makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak cilt kanseri görüntülerinden anlamlı yorumlar çıkarabilmek ve bunları sınıflandırabilmek mümkündür. Cilt kanseri veri kümesi görüntülerinin birçoğu dermoskopi görüntülerinden ya da klasik fotoğraf yoluyla elde edilen görüntülerden meydana gelmektedir. Herhangi bir cilt uzmanı (Dermatolog) tarafından tümörlü bir bölgenin teşhisi öncelikle cilt bölgesinin görsel olarak incelenmesiyle başlamaktadır. Bazı lezyonların görüntüleri birbirlerine çok fazla benzediği için burada uzmanların hata yapma olasılıkları çoğu zaman kişinin tecrübesine bağlı olarak değişmektedir. Uzmanlar şüpheli durumlarda özel yüksek çözünürlüklü kameralarla dermoskopi görüntüleri almaktadırlar. Burada özel filtreler kullanılarak derin cilt katmanları görüntülenebilmektedir. Bununla birlikte teşhisin doğruluğu ve ikinci bir görüş ya da otomatik bilgisayar destekli bir tanı sisteminin geliştirilmesiyle buradaki hata oranı büyük ölçüde azaltılabilmekte, insan hayatının söz konusu olduğu durumlarda hızlı bir şekilde teşhis konulabilmektedir [110].

3.1.6. Cilt Tümörü Veri Seti

Tez çalışmasının üçüncü ve son veri kümesi olan Cilt kanseri sınıflandırılması için kullanılan veri seti Kaggle kütüphanesinde Claudio Fanconi tarafından açık erişimli bir şekilde paylaşılan ‘‘Skin Cancer: Malignant vs. Benign’’ veri kümesidir. Dermoskopi görüntülerinden oluşan bu veri kümesi iyi huylu ve kötü huylu cilt benlerinden oluşmaktadır. Veri seti boyutları 224x244 olan toplamda 1800 görselden meydana gelmektedir. Veri setinde bulunan görsellerin 660’ı test setine bölünmüşken, 1140’ı eğitim setine bölünmüştür [111].

Şekil 3.5’de veri setinden alınan iyi huylu ve kötü huylu örnekler gösterilmektedir.



Şekil 3.5: İyi ve Kötü Huylu Cilt Tümörleri

Kötü huylu olarak bilinen Melanom (Malignant) en ölümcül cilt kanseri olarak bilinmektedir ve her yıl binlerce insan bu yüzden hayatını kaybetmektedir. Bu kanser türü ülkeler arası insanlarda farklılıklar gösterse de özellikle son yıllarda ultraviyole ışınlarına maruz kalan insanlarda %50 oranında artış göstermiştir. Bu kanser türü son derece ölümcül olmasına rağmen erken teşhis edildiğinde insanların hayatta kalma şansı büyük oranda artmaktadır. Melanom deri içerisinde epidermisin alt tabakasında bulunduğundan dolayı diğer dokulara yayılması son derece muhtemeldir. Kanserli hücreler sağlıklı hücrelerin normal fonksiyonlarını bozdukları göz önüne alındığında Melanomun yağlı hücrelerde hızla yayılması söz konusu olabilmektedir. Mümkün olduğunca erken teşhis ve tanı bu kanser türünü önlemekte oldukça önemlidir.

3.2. EĞİTİM AŞAMASI PARAMETRE OPTİMİZASYONU

Bu çalışmada kullanılan modeller PyTorch tarafından sağlanmakta olup ImageNet veri kümesi üzerinde eğitilmiştir. Verilerin eğitim aşamasında kullanılan Python programının ‘‘Tools’’ kısmında bulunan derin öğrenme parametreleri aşağıda başlıklar halinde açıklanmıştır.

3.2.1. Veri Setinin Boyutu

Makine öğrenmesi ve derin öğrenme uygulamalarında kullanılan veri setinin büyüklüğü ve çeşitliliği öğrenme için oldukça önemlidir. Aynı zamanda veri setinin büyüklüğü öğrenme için geçen zamanı ve öğrenme sonunda elde edilen modelin başarısını da etkilemektedir. Buda direkt olarak modelin doğruluğunu etkilemektedir. Bazı durumlarda sadece veri seti büyüklüğü iyi bir model oluşturmak için yeterli olmamakta bunun yanı sıra çeşitliliğin arttığı durumlarda modelin başarı oranı da artış göstermektedir.

3.2.2. Epoch Parametresi

Veri kümeleri eğitilmek amacıyla büyük ya da küçük parçalara ayrılmaktadır. Model eğitilirken verilerin tamamı aynı anda eğitime katılmamaktadır. Her bir parça kendi içerisinde eğitilmekte ve ağırlık değerleri hesaplanmaktadır. Bu işlem her bir eğitim adımında tekrarlanarak model için en uygun ağırlık değerini hesaplamaya çalışır. Bu eğitim adımlarının her birine Epoch (eğitim tur sayısı) denilmektedir. Bu çalışmada kullanılan modeller 30 Epoch değeri ile eğitilmiştir.

3.2.3. Izgara Araması (Grid Search)

Her bir mimari için kullanılacak hiper paremetreler sık kullanılan bir yöntem olan ızgara araması ile aranmıştır. Hiper parametre aranması sürecinde hiper parametre olarak başarıyı en çok etkileyen öğrenme hızı ve optimizasyon fonksiyonu belirlenmiştir. Optimizasyon fonksiyonu olarak sık kullanılan SGD ve Adam fonksiyonları, öğrenme hızı için 0.00001, 0.0001, 0.001, 0.01, 0.1 değerleri değerlendirmeye alınmıştır.

3.2.4. Learning Rate Parametresi

Bu parametre öğrenme oranı değerine karşılık gelmektedir. Python uygulamasında varsayılan olarak alınan değer ‘Adam’ optimizasyon fonksiyonunda 0.0001 olarak kabul edilmekte diğer bir optimizasyon fonksiyonu olan ‘‘SGD’’ ise 0.01 olarak kabul edilmektedir. Öğrenme hızı eğer düşükse eğitimin bitmesi uzun zaman almaktadır. Eğer öğrenme oranı çok yüksek ise eğitim yetersiz olabilir ve nihai bir sonuca ulaşılamayabilir. Genellikle öğrenme hızı için en uygun çözüm başlangıçta öğrenme hızını mümkün olduğunca yüksek tutmak ve gittikçe

azaltmaktır. Bu çalışmada 30 Epoch değeri ile eğitilen modeller eğitime 0.01 değeri ile başlatılmıştır.

3.2.5. Standart Gradyan Azalma Algoritması

Kayıp fonksiyonunu (loss function) en aza indirmek için kaybın negatif Gradyan yönünde her yinelemede küçük hamleler yaparak ağ parametrelerini (ağırlıklar) güncellenmektedir. Noktalar sürekli değişerek veri üzerinde işlem yapılır ve her adımda rastgele alınan bir veri üzerinde işlem yapılmaktadır.

3.2.6. Stokastik Gradyan Azalma Algoritması

Bu algoritma tüm yol boyunca optimum noktaya doğru salınım yapabilmektedir. Parametre güncellemesine momentum terimi eklemek salınım hareketini azaltmanın bir yolu olarak kabul edilmektedir.

3.2.7. Mini Batch Size Parametresi

İş yükünün ve çeşitliliğin fazla olduğu modellerde veri setinin parçalara ayrılması gerekmektedir. Tüm modelin aynı anda çalıştırılması ve veri setinin aynı anda eğitilmesi işlemciye çok fazla yük bindirmektedir. Bu yüzden bu parçaların eğitim ayarlarının belirlenmesi gerekmektedir. Genellikle 8,16,32,64 ve 128 olarak ayarlanan mini toplu iş parametresi tez çalışmasına ait eğitim setlerinde 16 ve 64 olarak ayarlanmıştır.

3.2.8. Erken Durma (Early Stopping)

Eğitim sırasında erken durma mekanizması kullanılarak hiper parametre araması yapılmıştır. Eğitim turlarında elde edilen değerlendirme kayıp değerleri için tolerans değeri olarak 5 kullanılmıştır. Bu durumda, eğer art arda 5 turda değerlendirme kaybı azalmadıysa, modelin eğitim verisini ezberlediği düşünülerek eğitim durdurulmuştur.

3.2.9. Topluluk Öğrenmesi

Eğitim sırasında kullanılan mimariler, ayrıca topluluk öğrenmesi yöntemi ile ortak bir model oluşturmak için de kullanılmıştır. Topluluk öğrenmesi yöntemi olarak sert oylama (hard voting) yöntemi seçilmiş, başka bir deyişle her görsel için tahmin olarak kullanılan CNN modellerinin verdiği tahminler göz önüne alınarak en çok oylanan tahmin kullanılmıştır.

3.3. DEĞERLENDİRME KRİTERLERİ

Yapay zekâ uygulamaları deneme, geri bildirim, düzeltme ve sonuç ilkesine göre çalışmaktadır. Çalışma öncesinde bir model oluşturulur ve modelin geçerliliği ile ilgili geri bildirimler kontrol edilir. Daha sonrasında gerekli iyileştirmeler yapılarak modelin beklenen doğruluğa ulaşması beklenir. Deney sonuçları farklı metrik değerleriyle ölçülür. Buradan çıkan sonuçlara göre modelin performansı belirlenmektedir. Değerlendirme kriterleri farklı modellerin karşılaştırılmasında ve sonuçların ayırt edilmesinde oldukça önemli bir rol oynamaktadır.

Sınıflandırma işlemleri sonucunda başarı oranlarını tahmin etmek amacıyla çeşitli başarım ölçütleri kullanılmaktadır. Genellikle sınıflandırma problemlerinde kullanılan ve en çok bilinen ölçüt Doğruluk (ACC) metriğidir. Fakat doğruluk ölçütü her zaman tek başına kullanıldığında kesinlik sağlamamaktadır. Daha kesin ve güvenilir bir analiz yapmak için başka ölçüm metriklerinin kullanılması gerekmektedir [112].

Literatürde yapılan çalışmalar incelendiğinde doğruluk ölçüm metriğinin yanı sıra; Kesinlik (PREC), Duyarlılık (Recall) ve F1 puanı (F1) metriklerinin kullanıldıkları görülmüştür. Karmaşıklık matrisi (Confusion Matrix) kullanılarak bu değerler matris formunda hesaplanabilmektedir. Doğru Pozitif (TP), Doğru Negatif (TN), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) değerleri, sınıflandırma sonuçları karmaşıklık matrislerinde hesaplanabilmektedir. Tablo 3.1'de karmaşıklık matrisi ve hesaplamalar gösterilmiştir [113].

Tablo 3.1: Karmaşıklık Matrisi ve Performans Metrikleri

		Tahmin Edilen	
		Pozitif	Negatif
Gerçek Değer	Pozitif	Doğru Pozitif (TP)	Yanlış Negatif (FN)
	Negatif	Yanlış Pozitif (FP)	Doğru Negatif (TN)

$$\text{Accuracy (\%)} = \left(\frac{TP+TN}{TP+EP+TN+FN} \right) x100 \qquad \text{Precision} = \frac{TP}{TP+FP}$$

$$\text{Recall} = \frac{TP}{TP+FN} \qquad f1_{score} = 2 \text{ x } \frac{\text{Precision x Recall}}{\text{Precision+ Recall}}$$

Karmaşıklık matrisi, gerçek değerlerin bilindiği bir test veri seti üzerinde, bir sınıflandırma yönteminin performansını sayısal olarak belirlemek için sıklıkla kullanılan bir tablodur. Çalışmada kullandığımız veri seti kümeleri üzerinde karmaşıklık matrisinin verdiği sonuçlar şöyledir;

TP (Doğru Pozitif): Hastaya hasta demek.

FP (Yanlış Pozitif): Hasta olmayana hasta demek.

TN (Doğru Negatif): Hasta olmayana hasta değil demek.

FN (Yanlış Negatif): Hasta olana hasta değil demek.

Burada duyarlılık metriği, hasta olanları doğru tespit etme yüzdeliğini vermektedir. Kesinlik metriği, hasta dediklerimizin gerçekten kaçının hasta olduğunu yüzdelik olarak göstermektedir. Burada duyarlılık ve kesinlik gibi iki önemli metriğin birbirine bağlı olduğu görülmektedir. Burada oluşabilecek anlam karmaşıklığını giderebilmek için F1-skoru kullanılmaktadır. F1-skoru hesaplamasında aritmetik ortalama yerine harmonik ortalama kullanılmaktadır.

Duyarlılık metriğini bazı durumlarda doğru tespit etmek yanlış tespit etmekten daha avantajlı görülebilmektedir. Kanserli bir hastayı tespit edemeyip ölümüne neden olmaktansa, kanser olmayan birini yanlış tahmin yapıp hastaneye çağırmak daha kabul edilebilir bir durumdur. Bununla birlikte herkesi hastaneye çağırıp bütün kanserli vakaları bulabiliriz ama bu durumda birçok yanlış durum ortaya çıkabilmektedir.

Kesinlik metriğinde de benzer bir durum vardır. Birine hasta demeden önce iyice emin olmayı önermektedir. Eğer bir kişiye hasta teşhisi konur ve o kişi gerçekten hasta çıkarsa doğruluk %100 bulunur fakat kalan kişiler tespit edilemezse büyük bir yanılgı ortaya çıkmaktadır.

Bu iki metrik değerini x ve y eksenlerine yerleştirerek çizilen grafikle ayrıca ROC (Receiver Operating Characteristic) eğrisi oluşturulmaktadır. ROC eğrileri, testin ayırt etme gücünün belirlenmesini, uygun pozitiflik eşiğinin belirlenmesini, performansların ve sınıflandırmaların karşılaştırılması gibi amaçlarla kullanılmaktadır.

3.4. UYGULAMA PLATFORMLARI

Tez çalışmasında Google COLAB ortamında Python programlama dili kullanılmıştır. Python esasen nesne tabanlı programlamayı ve belirli bir oranda da fonksiyonel programlamayı desteklemektedir. Açık kaynak erişimli kod mantığına dayanan Python, sahip olduğu standart kütüphanesi, geliştirilebilir araçları ve herhangi bir lisansa gerek duymadan kolay kurulumu sayesinde oldukça tercih edilmektedir. Diğer yazılım dillerine göre basit, kolay ve anlaşılabilir bir dil olmasından dolayı birçok avantaj barındırmaktadır. Python programlama dili özellikle son yıllarda yapay zekâ alanında ortaya çıkan gelişmelerle birlikte masaüstü uygulamaları, oyun geliştirilmesi, ağ programlama, veri madenciliği, veri analizi, makine öğrenimi ve derin öğrenme, nesnelerin interneti ve bilimsel hesaplama uygulamaları gibi çok çeşitli alanlarda yapılan uygulamalara hizmet sağlamaktadır.

Google Colabarotary (Colab) platformu Google tarafından geliştirilmiş ve kullanıcılarına bulut ve GPU (Graphics Processing Unit) imkânı veren ücretsiz bir hizmet platformudur. Bu platformu kullanan kullanıcılar tarafından geliştirilen uygulamalar Google Drive eklentisinde saklanmaktadır. Platform, içerisinde makine öğrenmesi ve derin öğrenme algoritmalarının çok sık kullanıldığı Keras, OpenCv, XGBoots, Pytorch, Scikit-Learn ve TensorFlow gibi birçok kütüphaneyi ücretsiz kullanma imkânı sunmaktadır [114].

Tez çalışmasında Python dilinde yapılan uygulamalar açık kaynaklı kütüphanelerde ve ücretsiz GPU desteği sağlayan Google Colab platformunda geliştirilmiş, oluşturulan modellerin sınıflandırılmasında ve sonuçların ayırt edilmesinde bu yazılım dilinden faydalanılmıştır.

Çalışma Apple M1 pro işlemcili, 8 çekirdekli CPU, 14 çekirdekli GPU, 16 çekirdekli Neural Engine ve 200 GBps bellek bant genişliği olan, inç başına 254 piksel yoğunlukta 3024 x 1964 çözünürlüklü, 32 GB birleşik bellek ve 1 TB SSD'ye sahip dizüstü bilgisayarda gerçekleştirilmiştir.

4. BULGULAR

Tezin bu bölümünde yöntem kısmında açıklanan 3 farklı hastalığa ait iyi ve kötü huylu tümörlerin sınıflandırılması problemine ait uygulanan metotlar ve sonuçlar gösterilmiştir. Öncelikle klasik makine öğrenmesi yöntemleriyle elde edilen modelin başarım ölçütlerine yer verilmiştir. Elde edilen sonuçlar üzerinden kesinlik, duyarlılık ve F1-skoru hesaplanmış sonrasında karmaşıklık matrisleri oluşturulmuştur. Ayrıca doğruluk oranları ve epoch sayılarının gösterildiği CNN algoritmalarına ait grafikler ayrıca gösterilmiştir.

Bireysel sınıflandırıcıların performansını artırmak amacıyla öncelikle CNN algoritmalarına ait varsayılan değerlerle başarım ölçütleri hesaplanmış, daha sonra parametre optimizasyonu yapılarak güncel sonuçlar tekrar incelenmiştir. Burada ek olarak topluluk öğrenmesi yöntemi uygulanmış ve sert oylama metodu kullanılarak buna ait kesinlik, duyarlılık, F1-skoru ve karmaşıklık matrisi oluşturulmuştur. Tüm parametre değerleri, modellere ait doğruluk yüzdeleri ve grafikleri, modellere ait en yüksek doğruluk yüzdeleri ve eğitim sırasında kullanılan modellerin karşılaştırılmaları gösterilmiştir.

Tablo 4.1'de eğitim sırasında tüm modeller için kullanılan ortak parametre değerleri tabloda verilmiştir. Veri kümelerine bağlı olarak kullanılan optimum parametreler ise sınıflandırma algoritmaları ile birlikte verilmiştir.

Tablo 4.1: Kullanılan Ortak Parametreler

Parametre	Değer
Tur sayısı	30
Mini-Batch boyutu	16
Öğrenme Hızı Zamanlayıcı	Reduce LR on Plateau
Öğrenme Hızı Zamanlayıcı Mod	Min
Öğrenme Hızı Zamanlayıcı faktörü	0.1
Öğrenme Hızı Zamanlayıcı sabır katsayısı	10

4.1. BEYİN TÜMÖRÜ VERİ SETİ UYGULAMASI

Tezin yöntem kısmında açıklanan ‘‘Brain Tumor MRI Dataset’’ isimli veri seti kümesine ait klasik makine öğrenmesi, CNN algoritmaları ve topluluk öğrenmesi yöntemleriyle sınıflandırma uygulamasına ait bulgular 4.1.1, 4.1.2 ve 4.1.3 numaralı başlıklarda açıklanmıştır.

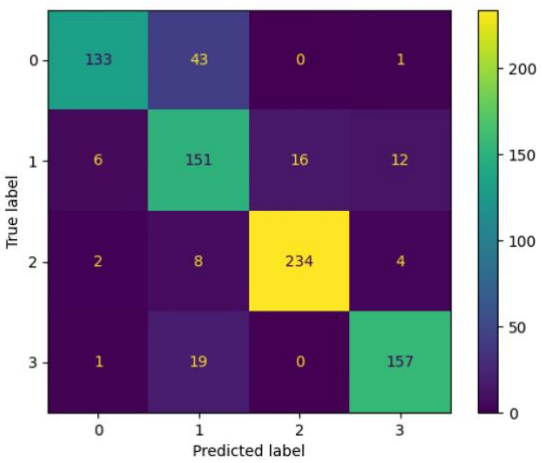
4.1.1. Klasik Makine Öğrenmesi Yöntemi ve Sonuçlar

Yapay sinir ağı ile tahminde kullanılan dört mimarinin ImageNet üzerinde eğitilmiş ağları kullanılarak özellik çıkarımı yapılmıştır. Yapay sinir ağları eğitimine benzer olarak bölünmüş olan veri seti kümesinin sınıflandırma katmanı öncesi öznitelikleri kullanılarak LDA, SVM, K-NN, DT ve NB modelleri eğitilmiştir. Modeller eğitilirken Scikit-Learn kütüphanesi kullanılarak uygulama yapılmış olup, varsayılan parametreler kullanılmıştır. Ayrıca her modelden çıkarılan öznitelikler birleştirilmiş ve 30056 özellik boyutunda bir öznitelik vektörü elde edilmiştir. Burada yeni oluşan öznitelikler aynı sınıflandırma algoritmaları ile eğitilmiştir. Tablo 4.2’de öznitelik çıkarımında kullanılan model ve sınıflandırma algoritmalarının verdiği doğruluk oranları verilmiştir.

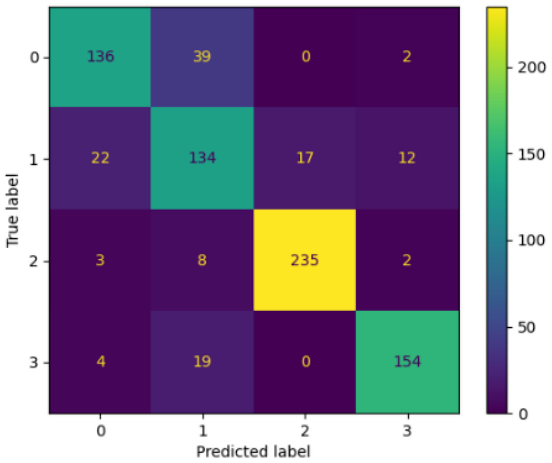
Tablo 4.2: Beyin Tümörü ML Doğruluk Oranı

CNN Mimarileri	LDA	SVM	KNN	DT	NB
SqueezeNet	0.780	0.848	0.815	0.762	0.785
DenseNet	0.837	**0.857**	0.778	0.454	0.640
ResNet	0.679	0.840	0.843	0.719	0.823
VGG	0.661	0.808	0.795	0.694	0.765
SqueezeNet + DenseNet + ResNet +VGG	**0.837**	0.833	0.736	0.487	0.634

Model ve sınıflandırma doğruluk oranları göz önüne alındığında en yüksek başarımı DenseNet algoritması ile sağlanan özellikler ve SVM sınıflandırıcısının kullanıldığı model göstermiştir. Makine öğrenmesi yöntemi uygulanırken hibrit bir model geliştirilerek modeller ikili, üçlü ve dörtlü olarak bir araya getirilmiştir. Daha sonra bu özellik kümelerine sınıflandırma algoritmaları uygulanmıştır. Tablo 4.2’de çoklu sınıflandırma sonuçlarından yüzdelik olarak yüksek olduğu için sadece dörtlü modele ait değerler verilmiştir. Şekil 4.1’de DenseNet + SVM karmaşıklık matrisi gösterilmiş, Şekil 4.2’de SqueezeNet + DenseNet + ResNet + VGG ait karmaşık matrisi verilmiştir.



Şekil 4.1: DenseNet + SVM CM



Şekil 4.2: SqueezeNet + DenseNet + ResNet +VGG CM

Aşağıdaki tablolarda Şekil 4.1 ve Şekil 4.2'ye ait doğruluk, kesinlik, duyarlılık ve F1-skorlarına ait değerler verilmiştir.

Tablo 4.3: DenseNet + SVM Başarım Metrik Değerleri

	PRECISION	RECALL	F1-SCORE	ACCURACY
GLİOMA	0,75	0,94	0,84	0,93
MENINGIOMA	0,82	0,68	0,74	0,86
NO-TUMOR	0,95	0,94	0,94	0,96
PITUITARY	0,89	0,90	0,89	0,95

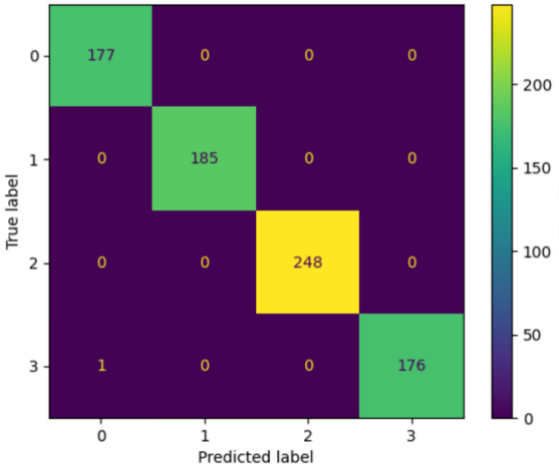
Tablo 4.4: SqueezeNet + DenseNet + ResNet +VGG Başarım Metrik Değerleri

	PRECISION	RECALL	F1-SCORE	ACCURACY
GLİOMA	0,77	0,82	0,80	0,91
MENINGIOMA	0,72	0,67	0,70	0,85
NO-TUMOR	0,95	0,93	0,94	0,96
PITUITARY	0,87	0,91	0,89	0,95

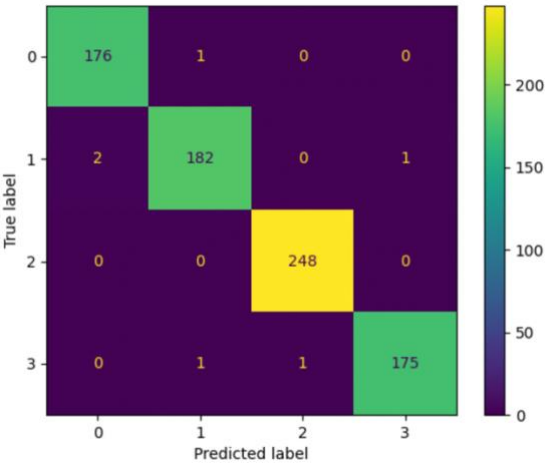
4.1.2. Parametre Optimizasyonu Öncesi-Sonrası CNN Modelleri Sonuçları

Beyin tümörü veri seti kümesinin eğitimi ve sınıflandırılması için farklı mimarilere sahip 4 CNN algoritmasından yararlanılmıştır. Eğitimin ve test sonuçlarının başarılı olabilmesi ve yüksek doğruluk oranlarına ulaşmak için modeli oluştururken öncelikle varsayılan hiper parametre değerleri ve katman sayılarıyla doğruluk oranları hesaplanmıştır. Daha sonra hiper-

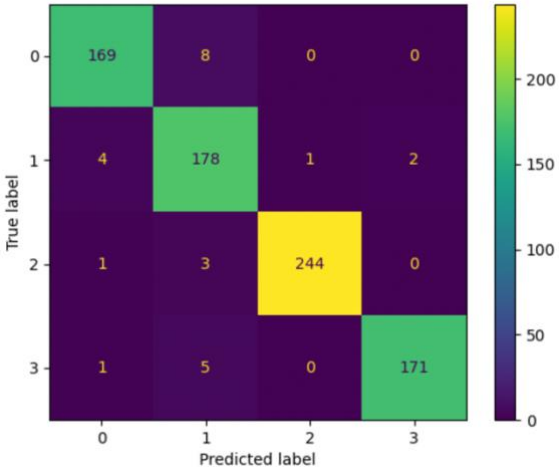
parametre optimizasyonu yapılarak eğitim ve sınıflandırma işlemleri tekrar yapılmıştır. Sonuçlar aşağıdaki tablo ve şekillerde gösterilmiştir.



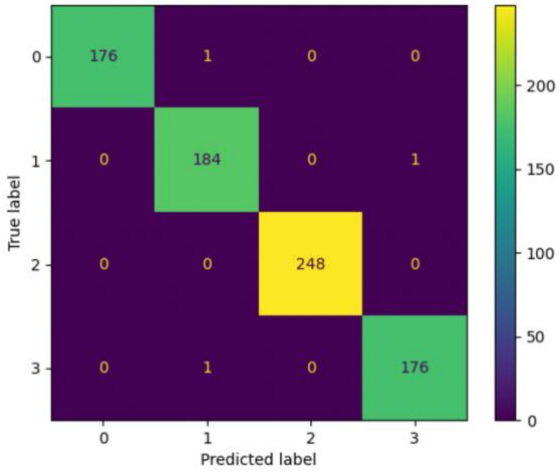
Şekil 4.3: ResNet Mimarisi Parametre Optimizasyon Öncesi



Şekil 4.4: VGG Mimarisi Parametre Optimizasyon Öncesi



Şekil 4.5: SqueezeNet Mimarisi Parametre Optimizasyon Öncesi

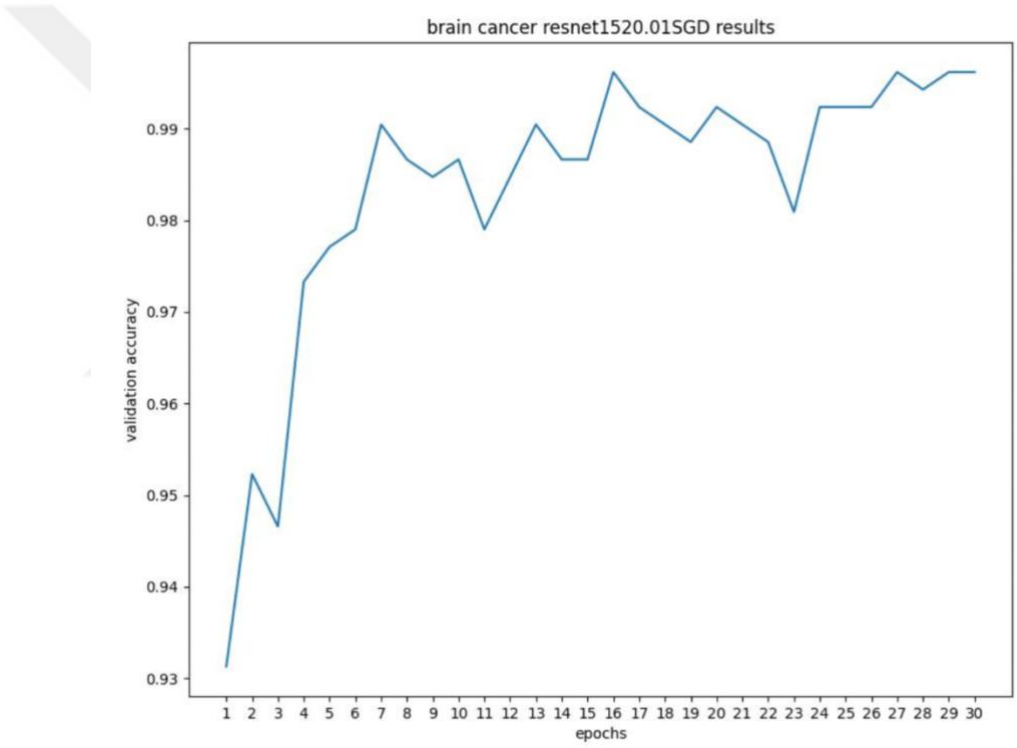


Şekil 4.6: DenseNet Mimarisi Parametre Optimizasyon Öncesi

Veri seti kullanılarak dört farklı model eğitilmiştir. Bu dört model ImageNet veri seti ile önceden eğitilmiş olup her veri seti için bir sınıflandırma katmanı eklenerek eğitilmiştir. Her model 30 tur eğitilmiştir. Model seçimi için eğitim sırasında değerlendirme setindeki doğruluk oranları takip edilmiş ve eğitim sırasında en yüksek değerlendirme doğruluk oranını veren turdaki model seçilmiştir. Modellerden ResNet için 0.99, DenseNet için 0.99, VGG için 0.99, SqueezeNet için 0.98 en yüksek değerlendirme doğruluk oranları alınmıştır. Aşağıdaki tabloda her model için optimum parametreler ve verdikleri doğruluk oranları verilmiştir.

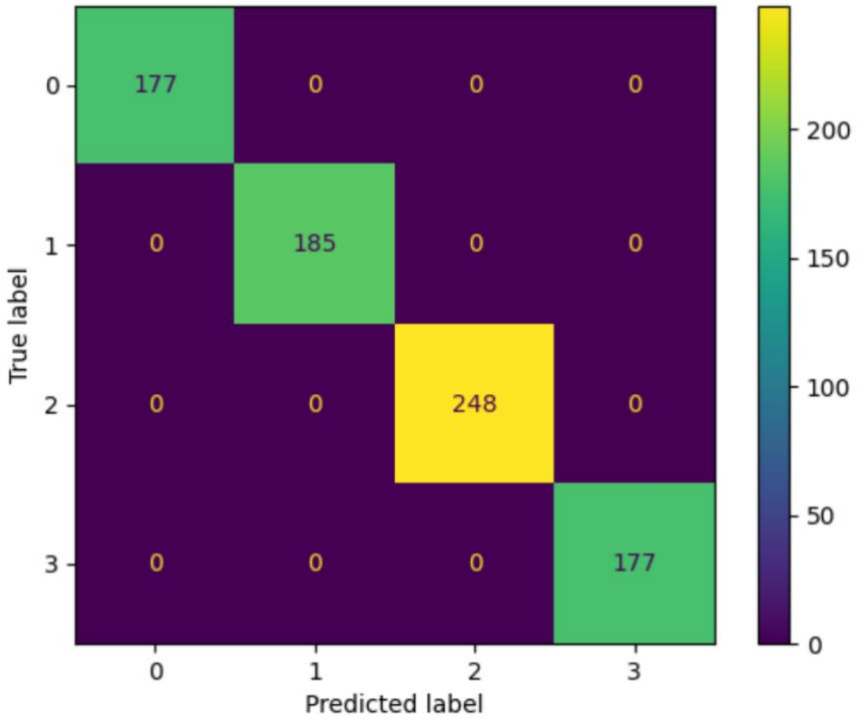
Tablo 4.5: Beyin Tümörü Veri Seti Parametre Optimizasyonu Değerleri

	Öğrenme Hızı	**Optimizasyon Fonksiyonu**	**Değerlendirme Doğruluğu**	**Test Doğruluğu**
SqueezeNet	0.0001	Adam	0.980	0.975
DenseNet	0.01	SGD	0.996	0.997
ResNet	0.01	SGD	**0.996**	**1.0**
VGG	0.01	SGD	0.990	0.996
Topluluk	-	-	-	0.998



Şekil 4.7: ResNet Doğrulama-Epoch Sayısı Grafiği

ResNet mimarisinin eğitim sırasında verdiği değerlendirme doğruluk oranları Şekil 4.7'de gösterilmiştir. En yüksek doğrulama değeri 30. turda verildiği için değerlendirme aşamasında bu model kullanılmıştır. Bu model test seti ile değerlendirildiğinde %100 doğruluk oranı elde edilmiştir. Şekil 4.8'de test seti için karmaşıklık matrisi verilmiştir:



Şekil 4.8: ResNet Optimizasyon Sonrası Karmaşıklık Matrisi

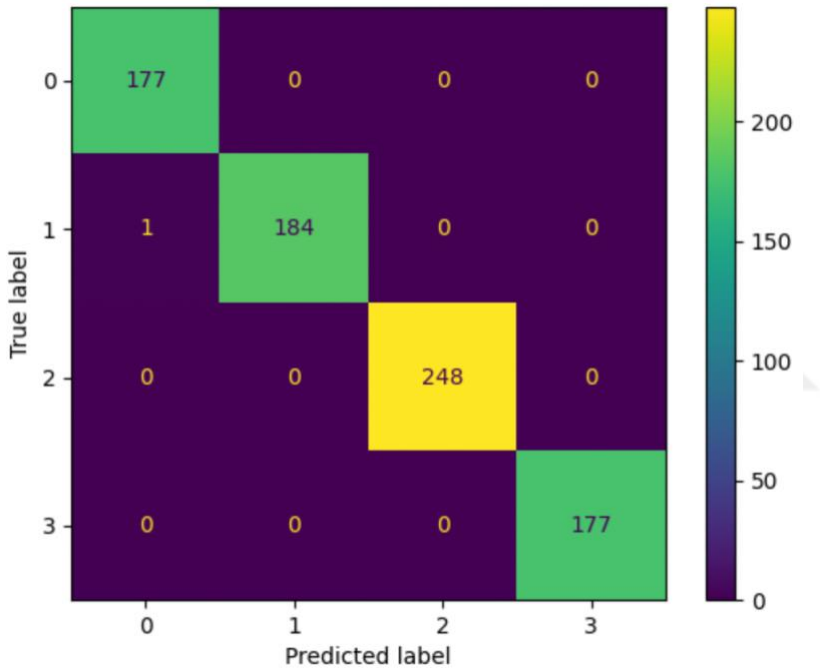
ResNet mimarisine ait optimizasyon sonrası oluşturulan karmaşıklık matrisinden elde edilen başarım oranları Tablo 4.6'da verilmiştir. Doğruluk oranının %100 çıkmasından dolayı tüm değerler eşit ve mutlak doğru şeklinde verilmiştir. Burada bulunan doğruluk sonuçları hem kullanılan algoritmanın sahip olduğu katman yapısı hem de veri kümesiyle ilişkilidir. Görüntülerin içerisinden özniteliklerin çıkarılması işleminde algoritmanın sahip olduğu her katman farklı bir işlev görevi görmekte ve bu işlevlerin doğru özellik kullanımı neticesiyle ortaya çıkan sonucu direkt olarak etkilemektedir.

Tablo 4.6: ResNet Optimizasyon Sonrası Model Başarım Oranları

	PRECISION	**RECALL**	**F1-SCORE**	**ACCURACY**
GLİOMA	1,0	1,0	1,0	1,0
MENINGIOMA	1,0	1,0	1,0	1,0
NO-TUMOR	1,0	1,0	1,0	1,0
PITUITARY	1,0	1,0	1,0	1,0

4.1.3. Topluluk Öğrenmesi Uygulaması ve Sonuçlar

Aşağıda topluluk modelinin test seti üzerinde değerlendirilmesi sonucu karmaşıklık matrisi verilmiştir. Karmaşıklık matrisinin y ekseni örneklerin gerçek etiketlerini gösterirken, x ekseni model tarafından tahmin edilen etiketleri göstermektedir. Karmaşıklık matrisinin diyagonalinin toplamı doğru sınıflandırılmış örnek sayısını verir. Burada topluluk öğrenmesi yöntemi kullanılarak dört modelin verdiği kararlardan sert oylama yöntemi ile tek karar çıkarılmıştır. Topluluk öğrenmesi yöntemi test seti üzerinde uygulanarak test edildiğinde %99 oranında doğruluk elde edilmiştir. Şekil 4.9 ve Tablo 4.7'de karmaşıklık matrisi ve başarım değerleri verilmiştir.



Şekil 4.9: Beyin Tümörü Veri Seti Oylama Yöntemi Karmaşıklık Matrisi

Tablo 4.7: Beyin Tümörü Veri Seti Oylama Yöntemi Model Başarım Oranları

	PRECISION	RECALL	F1-SCORE	ACCURACY
GLİOMA	1,0	0,99	1,0	0,9987
MENINGIOMA	0,99	1,0	1,0	0,9987
NO-TUMOR	1,0	1,0	1,0	1,0
PITUITARY	1,0	1,0	1,0	1,0

4.2. GÖĞÜS TÜMÖRÜ VERİ SETİ UYGULAMASI

Tezin yöntem kısmında açıklanan ‘‘Chest CT-Scan Dataset’’ isimli veri seti kümesine ait klasik makine öğrenmesi, CNN algoritmaları ve topluluk öğrenmesi yöntemleriyle sınıflandırma uygulamasına ait bulgular 4.2.1, 4.2.2 ve 4.2.3 numaralı başlıklarda açıklanmıştır.

4.2.1. Klasik Makine Öğrenmesi Yöntemi ve Sonuçlar

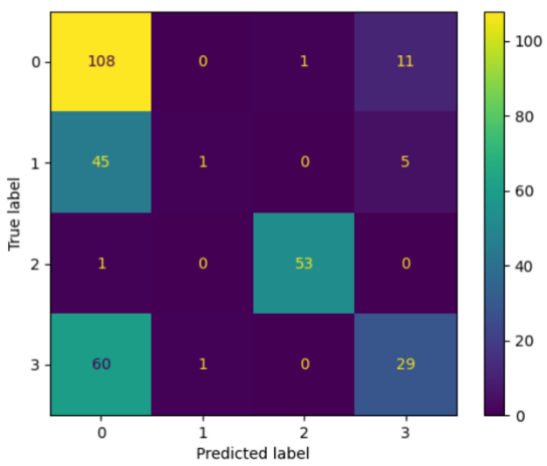
Yapay sinir ağı ile tahminde kullanılan dört mimarinin ImageNet üzerinde eğitilmiş ağları kullanılarak özellik çıkarımı yapılmıştır. Yapay sinir ağları eğitimindeki gibi bölünmüş olan veri setinin sınıflandırma katmanı öncesi öznitelikleri kullanılarak LDA, SVM, KNN, DT ve NB modelleri eğitilmiştir. Modeller Scikit-learn kütüphanesi kullanılarak uygulama yapılmış olup, varsayılan parametre değerleri kullanılmıştır. Tablo 4.8’de öznitelik çıkarımında kullanılan model ve sınıflandırma algoritmalarının verdiği doğruluk oranları verilmiştir.

Tablo 4.8: Göğüs Tümörü ML Doğruluk Oranı

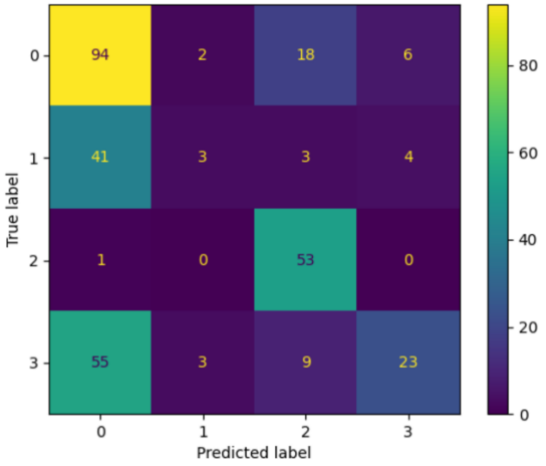
CNN MİMARİLERİ	LDA	SVM	KNN	DT	NB
SqueezeNet	0.530	0.530	0.495	0.393	0.450
DenseNet	0.526	0.450	0.374	0.317	0.533
ResNet	0.492	0.574	0.517	0.438	0.565
VGG	0.485	**0.606**	0.580	0.469	0.539
SqueezeNet + DenseNet + ResNet +VGG	0.542	0.444	0.390	0.273	**0.549**

Model ve sınıflandırma doğruluk oranları göz önüne alındığında düşük bir yüzdelik başarımla VGG algoritması ile sağlanan özellikler ve SVM sınıflandırıcısının kullanıldığı model en iyi sonucu göstermiştir. Burada SVM makine öğrenmesi problemlerinde iyi bir sınıflandırıcı olmasına rağmen veri seti kümesinin özellik çıkarımı yetersiz olmasından dolayı yüksek doğruluk oranında bir sınıflandırma yapılamamıştır. Modelin dörtlü olarak bir araya getirilerek özellik çıkarımı ve daha sonrasında sınıflandırılması sonucunda NB sınıflandırma modeli en yüksek sonucu vermiştir.

Şekil 4.10’de VGG + SVM karmaşıklık matrisi gösterilmiş, Şekil 4.11’de SqueezeNet + DenseNet + ResNet + VGG ait karmaşık matrisi verilmiştir.



Şekil 4.10: VGG + SVM Karmaşıklık Matrisi



Şekil 4.11: SqueezeNet + DenseNet + ResNet + VGG Karmaşıklık Matrisi

Aşağıdaki tablolarda Şekil 4.10 ve Şekil 4.11'ye ait doğruluk, kesinlik, duyarlılık ve f1-skorlarına ait değerler verilmiştir.

Tablo 4.9: VGG + SVM Başarım Metrik Değerleri

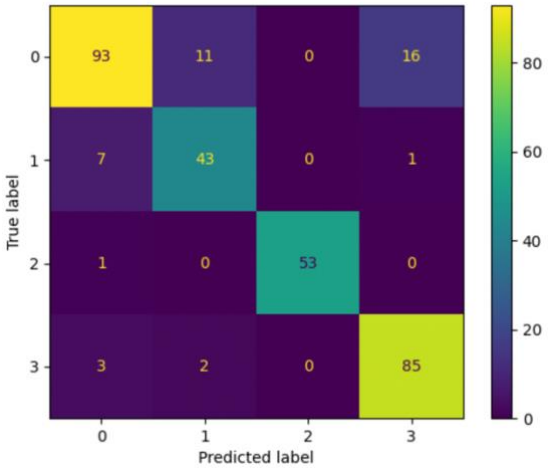
	PRECISION	**RECALL**	**F1-SCORE**	**ACCURACY**
ADENOCARCİNOMA	0,90	0,50	0,65	0,6254
L. CARCİNOMA	0,020	0,50	0,038	0,8381
NO-TUMOR	0,98	0,98	0,98	0,9937
S. CARCİNOMA	0,32	0,64	0,43	0,7556

Tablo 4.10: SqueezeNet + DenseNet + ResNet +VGG Başarım Metrik Değerleri

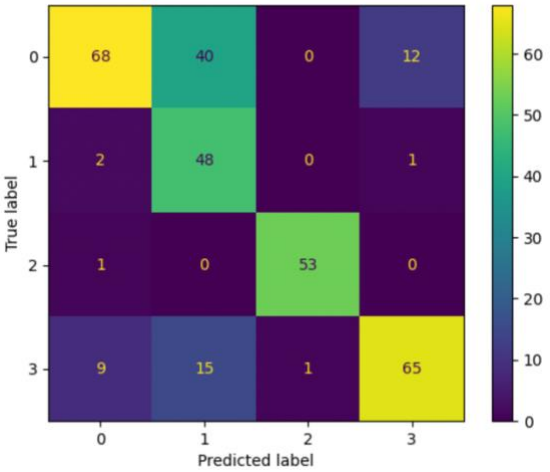
	PRECISION	**RECALL**	**F1-SCORE**	**ACCURACY**
ADENOCARCİNOMA	0,78	0,49	0,60	0,6095
L. CARCİNOMA	0,059	0,38	0,10	0,8317
NO-TUMOR	0,98	0,64	0,77	0,9016
S. CARCİNOMA	0,26	0,70	0,37	0,7556

4.2.2. Parametre Optimizasyonu Öncesi-Sonrası CNN Modelleri Sonuçları

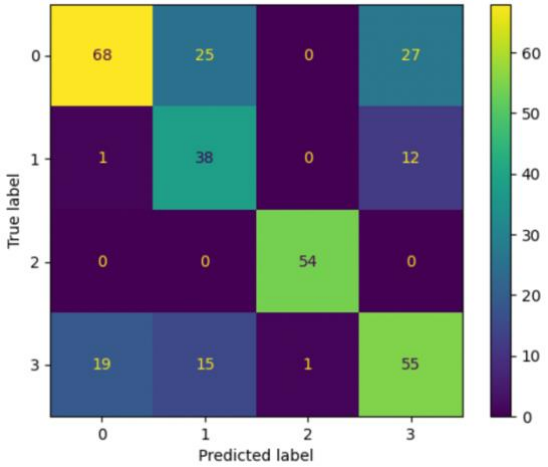
Yöntem kısmında verilen veri seti kullanılarak dört farklı model eğitilmiştir. Bu dört model ImageNet veri seti ile önceden eğitilmiş olup, bu veri seti için bir sınıflandırma katmanı eklenerek eğitilmiştir. Beyin tümörü sınıflandırılmasında kullanılan aynı dört model kullanılarak 30 tur eğitim gerçekleştirilmiştir. Eğitim sırasında en yüksek değerlendirme doğruluk oranını veren turdaki model test edilmek için seçilmiştir. Modellerin doğruluk değerlerine bakıldığında ResNet için 0.86, DenseNet için 0.81, VGG için 0.74, SqueezeNet için 0.68 en yüksek doğruluk oranları hesaplanmıştır. Parametre optimizasyonu sonrası en yüksek doğruluk değerini DenseNet verdiği için ara yüzde kullanılmak üzere DenseNet modeli seçilmiştir. Tablo 4.11'de her model için optimal parametreler ve verdikleri doğruluk oranları verilmiş, ayrıca karmaşıklık matrisleri gösterilmiştir.



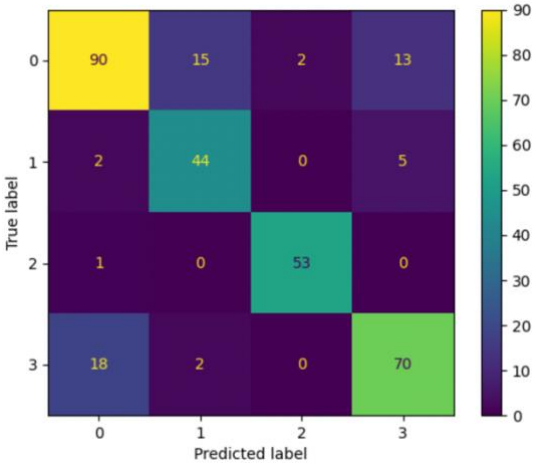
Şekil 4.12: ResNet Mimarisi Parametre Optimizasyon Öncesi



Şekil 4.13: VGG Mimarisi Parametre Optimizasyon Öncesi



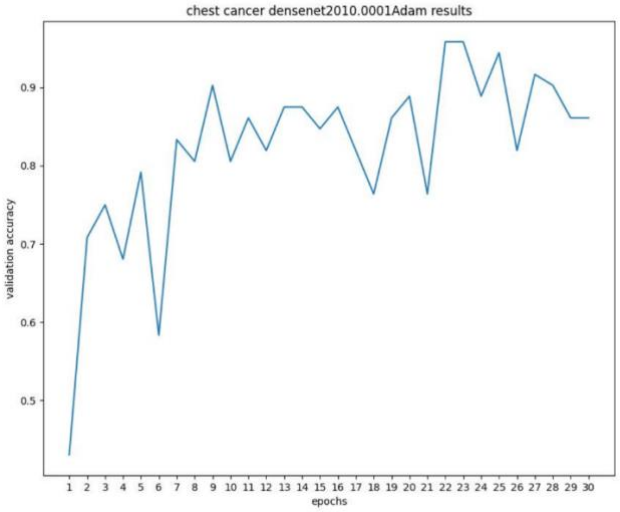
Şekil 4.14: SqueezeNet Mimarisi Parametre Optimizasyon Öncesi



Şekil 4.15: DenseNet Mimarisi Parametre Optimizasyon Öncesi

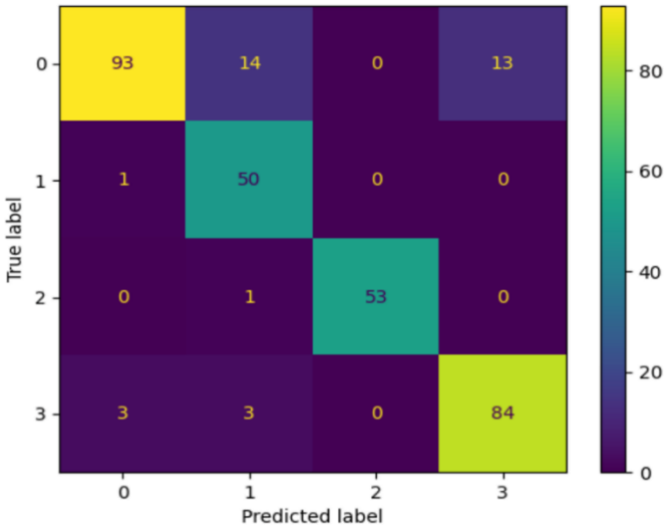
Tablo 4.11: Göğüs Tümörü Veri Seti Parametre Optimizasyon Değerleri

	Öğrenme Hızı	**Optimizasyon Fonksiyonu**	**Değerlendirme Doğruluğu**	**Test Doğruluğu**
SqueezeNet	0.0001	Adam	0.736	0.584
ResNet	0.0001	Adam	0.930	0.755
DenseNet	0.0001	Adam	**0.958**	**0.889**
VGG	0.0001	Adam	0.930	0.800
Topluluk	-	-	-	0.819



Şekil 4.16: DenseNet Doğrulama-Epoch Sayısı Grafiği

DenseNet'in eğitimi sırasında verdiği değerlendirme doğruluk oranları Şekil 4.16'da gösterilmiştir. En yüksek doğrulama değeri 21. turda görüldüğünden dolayı test için bu model kullanılmıştır. Bu model test seti ile değerlendirildiğinde %88 doğruluk oranı elde edilmiştir. Test, eğitim ve değerlendirme seti olarak bölünen veri kümesinde yapılan uygulamada DenseNet mimarisinin bu veri kümesi üzerinde başarılı ve yüksek oranda doğruluk değerlerine ulaşması, algoritmanın her katmanının bir önceki katmanların özelliklerini girdi olarak kullanmasından dolayı uygun veri kümesinde yüksek sonuçlar ortaya koymasıyla bağdaştırılabilmektedir.



Şekil 4.17: Optimizasyon Sonrası DenseNet Karmaşıklık Matrisi

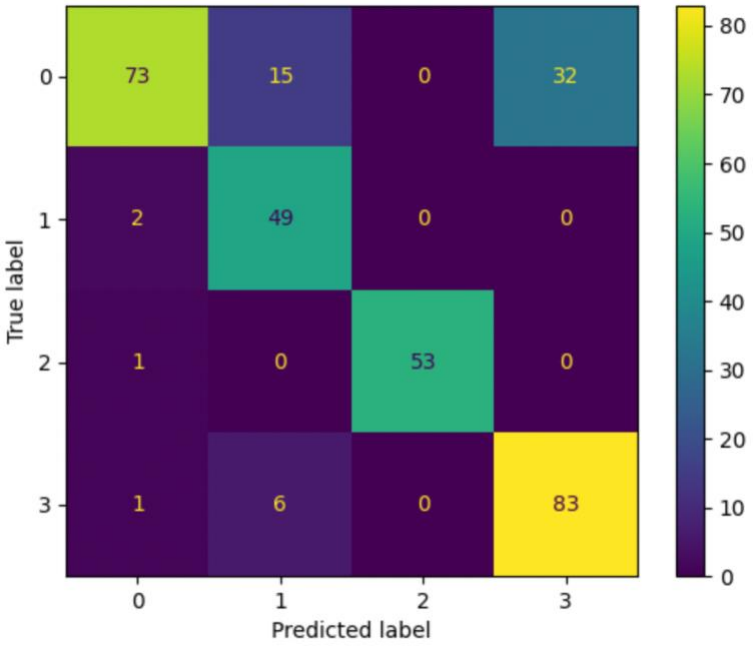
Tablo 4.12: DenseNet Optimizasyon Sonrası Model Başarım Oranları

	PRECISION	RECALL	F1-SCORE	ACCURACY
ADENOCARCİNOMA	0,78	0,96	0,86	0,9016
L. CARCİNOMA	0,98	0,74	0,84	0,9397
NO-TUMOR	0,98	1,0	0,99	0,9968
S. CARCİNOMA	0,93	0,87	0,90	0,9397

Optimizasyon sonrası modelin doğruluk oranları incelendiğinde DenseNet algoritmasının tümörsüz görüntüleri sınıflandırmada %99'luk bir başarı oranı yakaladığı görülmektedir. Aynı zamanda hastalığa ait tümörlü görüntülerin sınıflandırılmasında %90'ın üzerinde doğruluk oranına ulaşılmıştır.

4.2.3. Topluluk Öğrenmesi Uygulaması ve Sonuçlar

Aşağıda topluluk modelinin test seti üzerinde değerlendirilmesi sonucu ortaya çıkan karmaşıklık matrisi verilmiştir. Topluluk öğrenmesi yöntemi kullanılarak dört modelin verdiği kararlardan sert oylama yöntemi ile tek karar çıkarılmıştır. Topluluk öğrenmesi yöntemi test seti üzerinde uygulandığında %81,9 doğruluk oranı elde edilmiştir. Beyin tümörü veri seti üzerinde uygulanan sert oylama yöntemiyle karşılaştırıldığında, burada elde edilen doğruluk değerinin oldukça düşük olduğu görülmektedir. Bunun en büyük sebebi beyin tümörü veri setinde parametre optimizasyonu sonrası ResNet algoritmasının %100'lük bir başarım sağlaması ve bu mimarinin de kullanılarak sert oylama uygulamasının yapılmasıdır.



Şekil 4.18: Göğüs Tümörü Veri Seti Oylama Yöntemi Karmaşıklık Matrisi

Tablo 4.13: Göğüs Tümörü Veri Seti Oylama Yöntemi Model Başarım Oranları

	PRECISION	RECALL	F1-SCORE	ACCURACY
ADENOCARCİNOMA	0,61	0,95	0,74	0,8381
L. CARCİNOMA	0,96	0,70	0,81	0,927
NO-TUMOR	0,98	1,0	0,99	0,9968
S. CARCİNOMA	0,92	0,72	0,81	0,8762

4.3. CİLT TÜMÖRÜ VERİ SETİ UYGULAMASI

Tezin yöntem kısmında açıklanan ‘‘Skin Cancer: Malignant vs. Benign’’ isimli veri seti kümesine ait klasik makine öğrenmesi, CNN algoritmaları ve topluluk öğrenmesi yöntemleriyle sınıflandırma uygulamasına ait bulgular 4.3.1, 4.3.2 ve 4.3.3 numaralı başlıklarda açıklanmıştır.

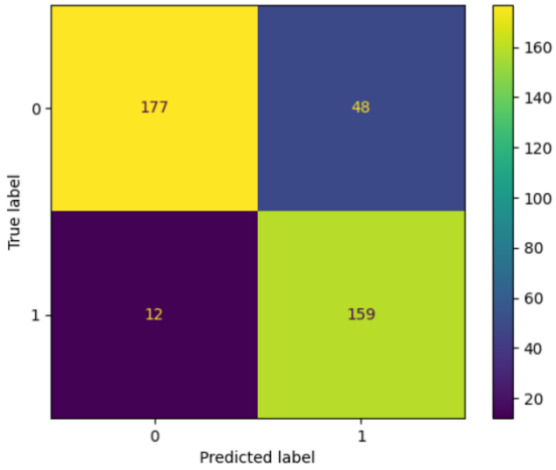
4.3.1. Klasik Makine Öğrenmesi Yöntemi ve Sonuçlar

Beyin ve göğüs tümörü veri setlerinde kullanılan yapay sinir ağı ile sınıflandırma yapılan benzer dört mimarinin ImageNet üzerinde eğitilmiş ağları kullanılarak özellik çıkarımı yapılmıştır. Yapay sinir ağları eğitimindeki gibi bölünmüş olan veri setinin sınıflandırma katmanı öncesi öznitelikleri kullanılarak LDA, SVM, K-NN, DT ve NB modelleri eğitilmiştir. Modeller Scikit-learn kütüphanesi kullanılarak uygulama yapılmış olup, varsayılan hiper parametreler kullanılmıştır. Ayrıca her modelden çıkarılan öznitelikler birleştirilmiştir. Aynı sınıflandırma algoritmaları kullanılarak bu öznitelikler ile eğitim yapılmıştır. Tablo 4.14’de öznitelik çıkarımında kullanılan model ve sınıflandırma algoritmalarının verdiği doğruluk oranları verilmiştir.

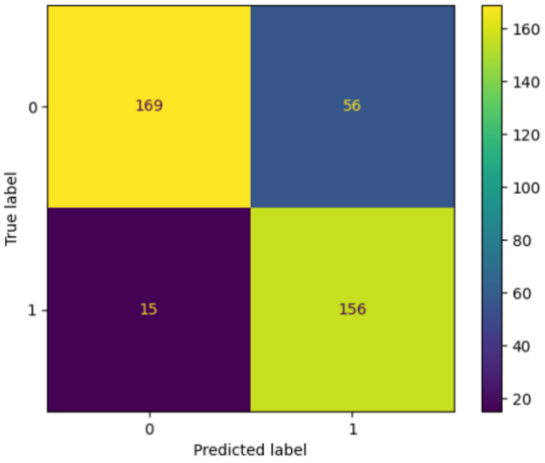
Tablo 4.14: Cilt Tümörü ML Doğruluk Oranları

CNN Mimarileri	LDA	SVM	KNN	DT	NB
SqueezeNet	0.780	**0.848**	0.815	0.762	0.785
DenseNet	0.838	0.848	0.714	0.661	0.818
ResNet	0.679	0.840	0.843	0.719	0.823
VGG	0.661	0.808	0.795	0.694	0.765
SqueezeNet + DenseNet + ResNet +VGG	0.810	**0.820**	0.664	0.679	0.792

Model ve sınıflandırma doğruluk oranları göz önüne alındığında en yüksek başarımı SqueezeNet algoritması ile sağlanan özellikler ve SVM sınıflandırıcısının kullanıldığı model göstermiştir. Dörtlü olarak oluşturulan hibrit modelde ise en yüksek başarım SVM sınıflandırıcısında ulaşılmıştır. Şekil 4.19’da SqueezeNet + SVM karmaşıklık matrisi gösterilmiş, Şekil 4.20’de SqueezeNet + DenseNet + ResNet + VGG ait karmaşık matrisi verilmiştir.



Şekil 4.19: SqueezeNet+SVM Karmaşıklık Matrisi



Şekil 4.20: SqueezeNet+DenseNet+ResNet+VGG Karmaşıklık Matrisi

Aşağıdaki tablolarda Şekil 4.19 ve Şekil 4.20'ye ait doğruluk, kesinlik, duyarlılık ve F1-skorlarına ait değerler verilmiştir.

Tablo 4.15: SqueezeNet + SVM Başarım Metrik Değerleri

	PRECISION	RECALL	F1-SCORE	ACCURACY
BENİGN	0,79	0,94	0,86	0,8485
MALİGNANT	0,93	0,77	0,84	0,8485

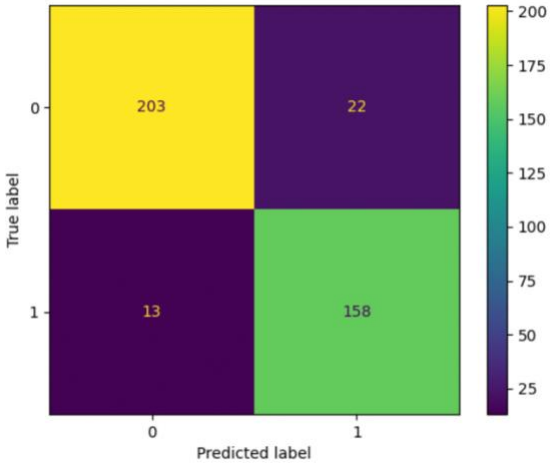
Tablo 4.16: SqueezeNet + DenseNet + ResNet +VGG Başarım Metrik Değerleri

	PRECISION	RECALL	F1-SCORE	ACCURACY
BENİGN	0,75	0,92	0,83	0,8207
MALİGNANT	0,91	0,74	0,81	0,8207

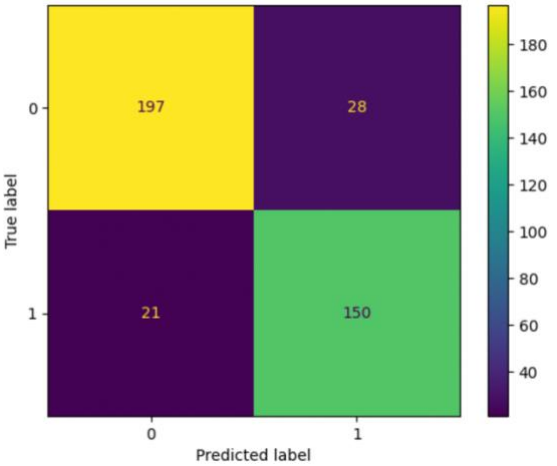
4.3.2. Parametre Optimizasyonu Öncesi-Sonrası CNN Modelleri Sonuçları

Beyin ve göğüs tümörü veri setlerinde olduğu gibi eğitim sırasında en iyi modelin seçilebilmesi için veri setleri test ve eğitim veri seti olarak ayrılmışlardır. Aynı dört model ImageNet veri seti ile önceden eğitilmiş olup, bu veri seti için bir sınıflandırma katmanı eklenerek eğitilmiştir. Her model 30 tur eğitilmiştir. Model seçimi için eğitim sırasında değerlendirme setindeki doğruluk oranları takip edilmiş ve eğitim sırasında en yüksek değerlendirme doğruluk oranını veren turdaki model seçilmiştir. Ayrıca modellerin her biri için önce varsayılan parametre değerleriyle model seçimi yapılmış daha sonra hiper parametre ayarlaması yapılmıştır.

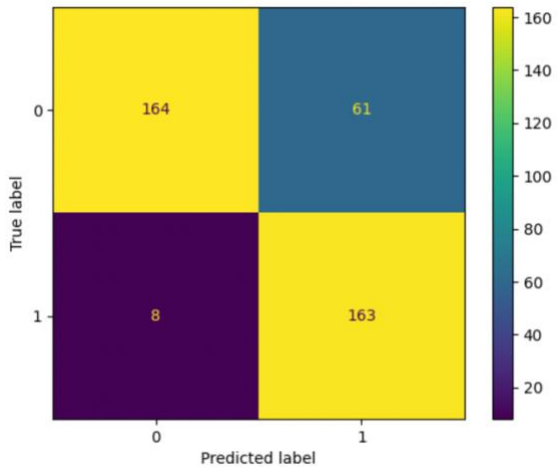
Modellerin parametre optimizasyonu öncesi doğruluk oranları göz önüne alındığında, ResNet için 0.91, DenseNet için 0.87, VGG için 0.87, SqueezeNet için 0.82 en yüksek değerlendirme doğruluk oranlarına ulaşılmıştır. Tablo 4.17'de her model için optimal parametreler ve verdikleri doğruluk oranları verilmiş aynı zamanda varsayılan parametre değerleriyle modellerin karmaşıklık matrisleri verilmiştir.



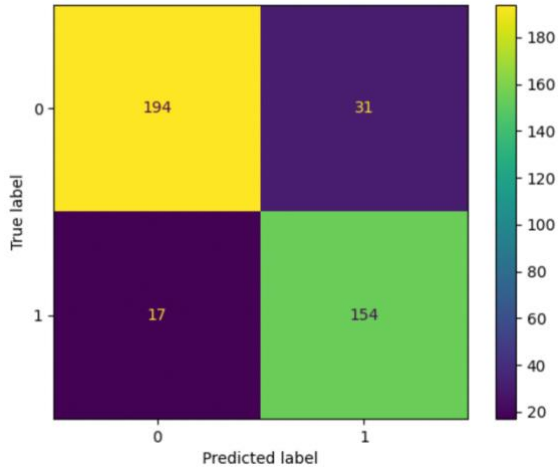
Şekil 4.21: ResNet Mimarisi Parametre Optimizasyon Öncesi



Şekil 4.22: VGG Mimarisi Parametre Optimizasyon Öncesi



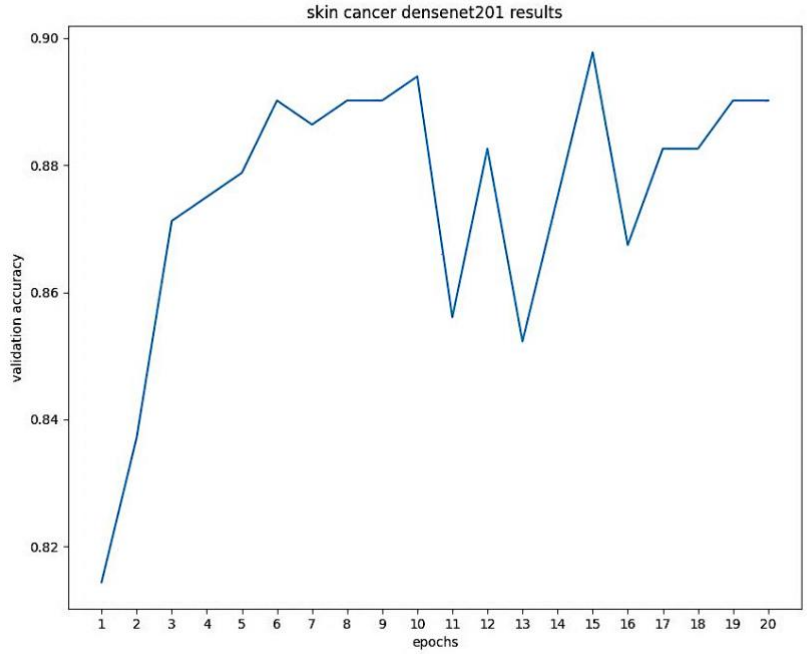
Şekil 4.23: SqueezeNet Mimarisi Parametre Optimizasyon Öncesi



Şekil 4.24: DenseNet Mimarisi Parametre Optimizasyon Öncesi

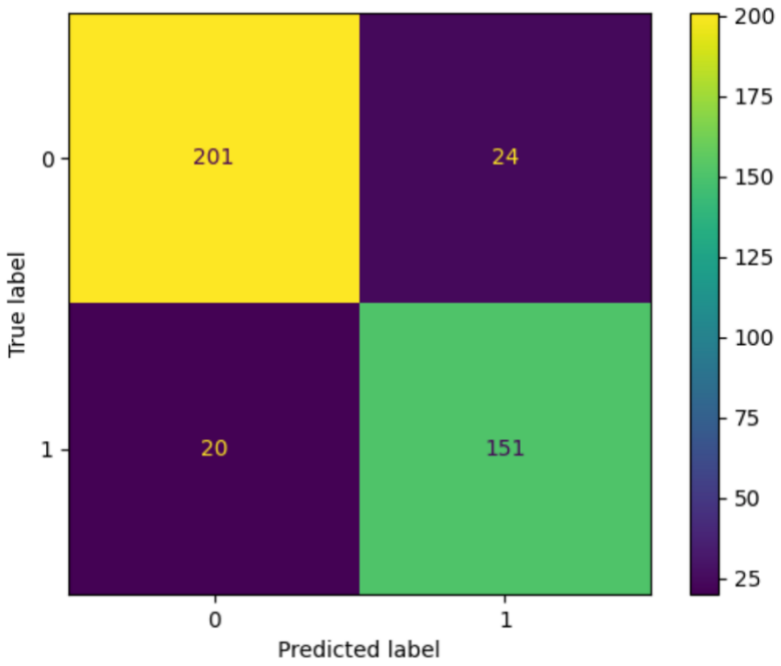
Tablo 4.17: Cilt Tümörü Veri Seti Parametre Optimizasyon Değerleri

	Öğrenme Hızı	**Optimizasyon Metodu**	**Değerlendirme Doğruluğu**	**Test Doğruluğu**
SqueezeNet	0.0001	Adam	0.886	0.873
DenseNet	0.01	SGD	0.920	**0.888**
ResNet	0.01	SGD	**0.924**	0.883
VGG	0.01	SGD	0.918	0.878
Topluluk	-	-	-	0.906



Şekil 4.25: DenseNet Doğrulama-Epoch Sayısı Grafiği

DenseNet'in eğitimi sırasında verdiği değerlendirme doğruluk oranları yukarıdaki şekilde gösterilmiştir. En yüksek doğrulama değeri 15. turda verildiği için uygulama yapılırken bu model kullanılmıştır. Bu model test seti ile uygulandığında %88 doğruluk oranı elde edilmiştir. Bu oran DenseNet mimarisinin parametre optimizasyonu sonrası en yüksek başarım oranıdır. Şekil 4.26 ve Tablo 4.18'de DenseNet mimarisinin optimizasyon sonrası karmaşıklık matrisi ve başarım oranları gösterilmiştir.



Şekil 4.26: Optimizasyon Sonrası DenseNet Karmaşıklık Matrisi

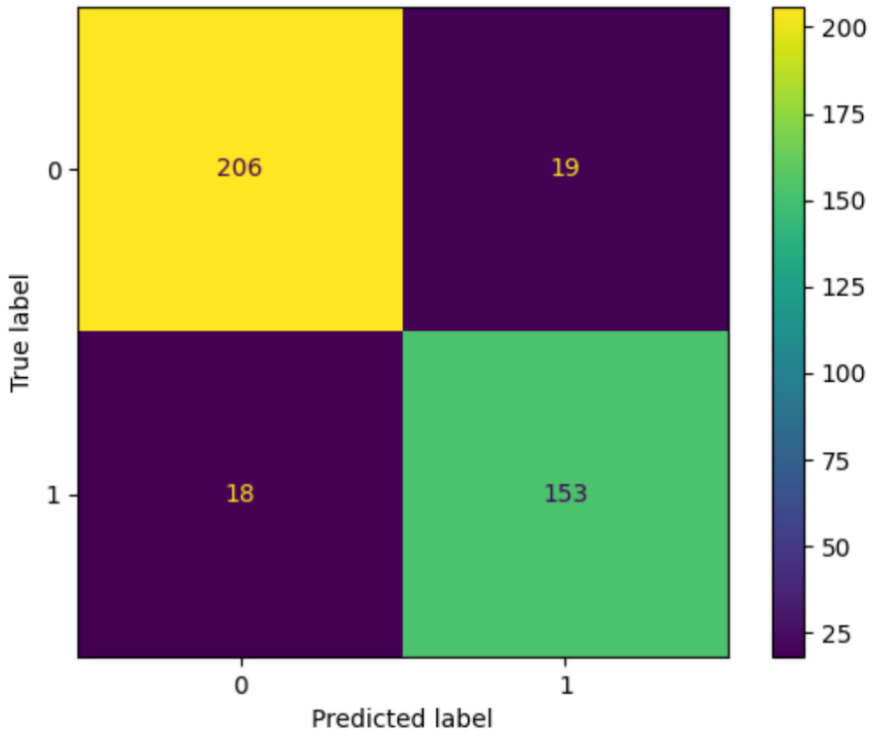
Tablo 4.18: DenseNet Optimizasyon Sonrası Model Başarım Oranları

	PRECISION	RECALL	F1-SCORE	ACCURACY
BENİGN	0,89	0,91	0,90	0,8889
MALİGNANT	0,88	0,86	0,87	0,8889

Parametre optimizasyonu öncesi elde edilen sınıflandırma sonuçları ile karşılaştırıldığında DenseNet algoritmasının %1'lik oranda iyileştirildiği görülmektedir. Varsayılan parametre değerleriyle yapılan sınıflandırmada ResNet algoritması %91'lik bir doğruluk oranına ulaşmasına rağmen test için alınan veri kümesi değerlendirildiğinde ortaya çıkan doğruluk sonucu DenseNet mimarisinin altında kalmıştır.

4.3.3. Topluluk Öğrenmesi Uygulaması ve Sonuçlar

Topluluk öğrenmesi modelinin test seti üzerinde uygulanması sonucunda ortaya çıkan karmaşıklık matrisi Şekil 4.27'de verilmiştir. Toplamda 359 adet görselden oluşan karmaşıklık matrisinde kansersiz görsellerin 206'sı doğru sınıflandırılmışken 19'unun yanlış olarak kanserli sınıflandırıldığı, kanserli görsellerden ise 153'ü doğru sınıflandırılırken 18'ini modelin kansersiz olarak sınıflandırdığı görülmektedir. Topluluk öğrenmesi yöntemi test seti üzerinde uygulanarak test edildiğinde %90 doğruluk oranı elde edilmiştir.



Şekil 4.27: Cilt Tümörü Veri Seti Oylama Yöntemi Karmaşıklık Matrisi

Tablo 4.19: Cilt Tümörü Veri Seti Oylama Yöntemi Model Başarım Oranları

	PRECISION	RECALL	F1-SCORE	ACCURACY
BENİGN	0,92	0,92	0,92	0,9066
MALİGNANT	0,89	0,89	0,89	0,9066

5. TARTIŞMA

Teknolojinin gelişmesiyle birlikte her alanda olduğu gibi sağlık alanında da sağlık çalışanlarının daha verimli çalışabilmeleri için çalışmalar yapılmaktadır. Biyomedikal alanında yapılan çalışmalar tanı ve tedavide daha hızlı sonuç alabilmek ve uzmanların hatalarını en aza indirmeyi amaçlamaktadır. Kanser hastalığı her yıl binlerce insanın hayatını kaybetmesine sebep olmakta ve yüksek tedavi masrafları sebebiyle insanları maddi ve manevi olarak çöküntüye uğratmaktadır. Bununla birlikte hastalık psikolojisi ve ölüm korkusu sebebiyle insanların yaşam standartlarını son derece kötü etkilediği bilinmektedir. Sağlık alanında yapılan çalışmalar incelendiğinde kanser hastalığına sebep olan durumların kaynağı ve erken teşhisi, üzerinde en çok çalışılan konuların başında gelmektedir. Bilindiği üzere çoğu kanser türünde erken teşhis hayat kurtarmaktadır. Bu yüzden tümörün hangi sınıfa ait olduğunu iyi analiz etmek uzmanlar için oldukça önemlidir.

Çalışmanın birinci veri seti kümesini oluşturan beyin tümörü teşhisi ve sınıflandırılması için CNN mimarilerinden ResNet, VGG, DenseNet ve SqueezeNet olmak üzere 4 farklı yapay sinir ağı ile sınıflandırma yapılmıştır. Veri seti üzerinde sınıflandırma yapılırken üç farklı yöntem uygulanmıştır. Sırasıyla veri seti kümesi klasik makine öğrenmesi yöntemiyle sınıflandırılmış, sonrasında özellik aktarımı yapılarak seçilen dört yapay sinir ağı ile sınıflandırma yapılmış, tüm metrik ve doğruluk değerleri hesaplanmıştır. Daha sonrasında parametre optimizasyonu yapılarak en iyi sonucu veren CNN modelleri tekrar sınıflandırılmış ve parametre öncesi ve sonrası tüm sonuçlar karşılaştırılmıştır. Son olarak topluluk öğrenmesi tekniklerinden faydalanılarak hibrit bir model geliştirilmiş ve sert oylama yöntemiyle en yüksek başarım ve doğruluk oranları bulunmuştur.

Klasik makine öğrenmesi ile yapılan sınıflandırma sonucunda DenseNet ağından özellik çıkartımı ve sınıflandırılmasında en iyi sonucu SVM sınıflandırıcısı %85 oranında doğruluk yüzdesiyle vermiştir. Bu sınıflandırma yönteminde modellerin dörtlü olarak bir araya getirilerek yeni özellik kümesi elde edilmesi ve sınıflandırılması sonucunda LDA sınıflandırıcısı %83'lük bir başarım doğruluk oranı yakalamıştır.

Varsayılan parametre değerleriyle yapılan sınıflandırmada dört mimarinin oluşturdukları modeller ve doğruluk oranları göz önüne alındığında ResNet mimarisinin %99'luk bir doğruluk oranına ulaştığı görülmüştür. Parametre fonksiyonlarının uygun şekilde optimize edilerek değiştirilmesi ve test setine tekrar uygulanması sonucunda bulgular kısmında verilen karmaşıklık matrisinde de görüldüğü gibi ResNet %100'lük bir başarım sağlamıştır. Bu veri

seti için ve yaptığımız parametre değişiklikleri ile birlikte ResNet modeli literatürde yapılan çalışmalar göz önüne alındığında beyin tümörü veri kümesinde ilk defa bu kadar yüksek başarım oranına ulaştığı görülmektedir. Son olarak veri kümesine uygulanan topluluk öğrenmesi tekniklerinden oylama yöntemi uygulanarak bunun sonucunda %99'luk bir başarım oranı sağlanmıştır.

Çalışmanın ikinci veri seti kümesinde göğüs tümörü teşhisi ve sınıflandırılması için ilk olarak klasik makine öğrenmesi sınıflandırıcılarıyla uygulama yapılmıştır. Yapılan çalışma sonucunda VGG mimarisinden çıkartılan özellik kümesinin sınıflandırılmasında verilen en yüksek doğruluk oranı %60 oranla SVM modeline aittir. Burada özellik çıkartıcıların dörtlü olarak bir araya getirilmesi sonucu oluşan yeni mimariden çıkartılan özellik kümesinin tekrar sınıflandırılması sonucu en yüksek doğruluk oranına %54 ile NB modeli ulaşmıştır. Beyin tümörü veri setiyle karşılaştırıldığında bu oranlar klasik makine öğrenmesi sınıflandırıcıları için oldukça düşük görünmektedir.
Başlangıç olarak kabul edilen parametre değerleriyle yapılan ve dört farklı CNN mimarisi ile ayrı ayrı sınıflandırılan veri kümesinin doğruluk oranlarına bakıldığında en yüksek başarım yüzdesine ResNet mimarisi %86'lık doğruluk oranıyla ulaşmasına rağmen test doğruluğu için yapılan uygulamada DenseNet mimarisi %88'lik başarım oranına ulaşmıştır. Parametre optimizasyonu sonrasında bazı parametre değerleri değiştirilerek tekrar yapılan sınıflandırmada DenseNet mimarisinin %88'lik test doğruluğu ve %95'lik değerlendirme doğruluğuna ulaştığı görülmektedir. Burada uygulanan parametre optimizasyonunun sınıflandırma modeli üzerinde ciddi bir fark yaratmadığı görülmektedir.
Son olarak veri kümesine uygulanan topluluk öğrenmesi tekniklerinden oylama yöntemi sonucunda %81'luk bir başarım oranı sağlanmıştır. Beyin tümörü teşhisi ve sınıflandırılmasında aynı yapay mimariler ve benzer modeller kullanılmasına rağmen burada bulunan doğruluk oranları daha düşük bulunmaktadır.

Çalışmanın üçüncü ve son veri seti kümesini oluşturan cilt tümörü tespiti ve sınıflandırılmasında uygulanan klasik makine öğrenmesi yönteminde en yüksek sınıflandırma doğruluğuna SqueezeNet mimarisi ve SVM sınıflandırıcı %84'lük bir başarı oranıyla ulaşmıştır. Burada dört modelin birleştirilerek hibrit bir şekilde uygulanan sınıflandırma sonucunda ise SVM sınıflandırıcı %82'lik bir doğruluk oranına ulaşmıştır. Varsayılan parametre değerleriyle uygulanan ve dört farklı CNN mimarisine özellik çıkartma işlemi uygulanarak oluşturulan modelin ikinci uygulama kısmında ResNet mimarisi %91'lik bir

başarım oranına ulaşmıştır. Test doğruluğu göz önüne alındığında DenseNet mimarisi %88'lik başarım oranına ulaşmış ve değerlendirme doğruluğunda %92'lik bir doğruluk oranı yakalamıştır. Parametre optimizasyonu yapılarak mevcut parametre değerlerinin optimize edilmesi ve tekrar özellik çıkartımı ve sınıflandırma işlemleri yapıldığında DenseNet mimarisinin yine %88'lik bir doğruluk oranı yakalığı görülmektedir. Burada parametre optimizasyonu öncesi ve sonrası çok büyük bir değişim görülmemiştir. Bununla birlikte topluluk öğrenmesi teknikleri uygulanarak yapılan sert oylama tekniği sonucunda modelin %90'lık bir doğruluk oranı yakaladığı görülmektedir.

Literatürde uygulanan benzer çalışmalar başarım oranları, yapay sinir ağı mimarilerinin kullanımı ve parametre fonksiyonları göz önüne alındığında özellikle beyin tümörü tespitinde ResNet mimarisiyle ulaşılan %100'lük doğruluk oranına yakın hiçbir çalışma görülmemektedir. Burada mevcut parametre değerlerinin uzman görüşüne göre düzenlenmesi, veri özellik çıkartımı sırasında verilerin etiketlenmesi ve özelliklerin sınıflandırıcıya doğru transferi oldukça önemlidir. Sınıflandırma problemlerinde sınıf sayısının artmasıyla doğruluk oranlarında düşüşler görülmektedir. Çalışmada beyin ve göğüs tümörü sınıflandırılmasında benzer sınıf sayısı olmasına rağmen, cilt tümörü veri seti iki sınıfa ayrılmıştır. Buradaki sonuçların topluluk öğrenmesi yöntemiyle en yüksek başarım oranını yakalaması her veri seti için geçerli bir sonuç değildir. Yüksek doğruluk oranlarına ulaşmak için önemli olan veri kümesini oluşturan görüntülerden yapılan özellik çıkarımının ne kadar doğru yapıldığıdır. Beyin tümörü veri kümesinde oluşturulan modelde %100 başarı gösteren bir yapay sinir ağının aynı başarıyı farklı bir tümör veri kümesinde ya da farklı alanda yapılan bir sınıflandırma probleminde göstermesi beklenemez. Her veri kümesinin kendine has özellikleri ve yapay sinir ağlarını oluşturan modellerin tüm katmanlarının farklı özellikleri bulunmaktadır. Tüm bu modeller, yöntemler ve algoritmalar uygun şartlar ve veri kümeleriyle daha iyi bir şekilde geliştirilebilmeye açıktır.

6. SONUÇ VE ÖNERİLER

Tez çalışması olarak uygulanan bu çalışmada yapay zekâ teknolojilerinin alt dalı olarak kabul edilen makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak farklı veri setlerinde uygulanmak üzere teşhis ve sınıflandırma algoritması geliştirilmiştir. Son yıllarda sağlık alanında uygulanan teknolojik gelişmeler sağlık çalışanlarına tanı ve tedavi konusunda oldukça yardımcı olmaktadır. Bu alanda yapılan çalışmalar sayesinde bilgisayar sistemlerinden maksimum düzeyde faydalanılarak insan kaynaklı hataların minimuma indirilmesi amaçlanmaktadır. Sağlık alanında en çok ihtiyaç duyulan konu ölümcül hastalıkların erken teşhisi ve tedavisi alanındadır. Bu yüzden özellikle kanserde erken teşhis hayati öneme sahiptir. Tedavi süresini takip etmek ve tedaviden sonra oluşabilecek komplikasyonları önlemek için tümörlü bölgenin doğru teşhisi ve izlenmesi oldukça önemlidir.

Çalışmada üç farklı hastalığa ait farklı sınıf ve görüntülerden oluşan veri setlerinin sınıflandırılması ve tespitinin yüksek başarı yüzdeleri ile uygulandığı gözlemlenmiştir. Tüm veri kümeleri, klasik makine öğrenmesi sınıflandırıcıları, CNN modelleri ve topluluk öğrenmesi yöntemleriyle hibrit modeller geliştirilerek sınıflandırılmış, her modelin veri kümesine bağlı olarak farklı başarım oranları gösterdiği gözlemlenmiştir. Elde ettiğimiz sonuçları göz önüne alırsak CNN modelleri oluşturulurken, makine öğrenmesi algoritmalarına kıyasla veri ön işleme kısmında daha az zaman harcaması modelin öğrenmesini ve başarımını daha yüksek bir oranda etkilemektedir. Ayrıca CNN ağındaki mimarilerin katmanlar arası özellik farklılıkları görüntü işleme problemlerinde daha iyi sonuçlar göstermektedir. Bu yüzden tüm veri setlerinde CNN modelleri, makine öğrenmesi algoritmalarına göre daha yüksek başarı yüzdelerine ulaşmıştır.

Geleneksel makine öğrenmesi sınıflandırıcılarının en yüksek başarım oranı beyin tümörü veri setinde olmuştur. Bu sınıflandırıcıların bir araya geldikleri model yapısı ve katmanların görüntü işleme problemlerinde görüntü boyutları, renk pikselleri ya da uyguladıkları filtrelerde yüksek doğrulukta özellik çıkarımı yapamadıkları görülmüştür.

Beyin tümörü veri seti için hibrit olarak geliştirilen ResNet modelinde %100'lük bir başarım oranı sağlanmıştır. Bu model uygulandığı farklı veri seti kümelerinde de mükemmel bir şekilde sınıflandırma yapmaktadır. Bu durum geliştirilen modelin kusursuza yakın bir performans sergilediğini göstermektedir.

Göğüs tümörü teşhisi ve sınıflandırmasında uygulanan DenseNet modeli diğer sınıflandırıcı modellere göre yüksek başarı yüzdesine ulaşmıştır. Göğüs tümörü veri kümesinde uygulanan makine öğrenmesi ve topluluk öğrenmesi sınıflandırıcılarının başarı doğruluk oranları parametre optimizasyonu yapılan DenseNet mimarisinin oldukça altında kalmıştır.

Cilt kanseri teşhisi için uygulanan modellerin sınıflandırılmasında en başarılı doğruluk oranına topluluk öğrenmesi metoduyla uygulanan sert oylama yöntemiyle ulaşılmıştır. Bu veri seti kümesinde hem makine öğrenicileri hem de CNN algoritmasıyla geliştirilen modellerde çıkan sonuçlar birbirlerine oldukça yakındır. Sınıflandırma sonuçlarının yakın olmasının en önemli sebebi veri kümesinin iki sınıftan meydana gelmesinden dolayıdır. Literatürde yapılan çalışmalar ve uygulamalar incelendiğinde, sınıflandırmada sınıf sayısı arttıkça yapılan tahminlerin zorlaştığı ve yine görüntüler birbirine benzemedikçe doğruluk oranları ve başarı yüzdelerinin düştüğü görülmektedir. Bu yüzden sınıflandırılacak veri setinin birbiriyle benzer ilişkisi olması modelin doğruluğu açısından oldukça önemlidir. Bu tez çalışmasında üç ayrı veri kümesinde yüksek başarım yüzdelerine ulaşmamızın en büyük sebebi, veri setini oluşturan görüntülerin kendi içlerinde benzer sınıflara ayrılması ve görüntülerin renk, piksel ve boyut bakımından birbirlerine benzerlik göstermesinden kaynaklanmaktadır.

Son yıllarda her sektörde olduğu gibi artan veri miktarıyla birlikte sağlık alanında da özellikle üç boyutlu görüntüler daha profesyonel bir şekilde kullanılmaya başlanmıştır. Gelecekte birçok hastalığın önceden tespiti görüntüleme sistemleriyle çok daha basit ve güvenilir bir şekilde olacağı düşünülmektedir. Bu yüzden gelecek çalışmalarda araştırmacıların hız ve sonuç açısından CPU ve GPU yüksek model bilgisayarla çalışması önerilmektedir. Çalışmada kullanılan modeller daha gelişmiş dijital yazılım ortamlarında geliştirilebilir ve hastalık teşhisi çalışmalarına farklı bir bakış açısı getirilebilir.

KAYNAKLAR

1. Mathew, A., Amudha, P., Sivakumari, S. (2020). Deep Learning Techniques: An Overview. In International Conference on Advanced Machine Learning Technologies and Applications (pp. 599-608). Springer, Singapore.
2. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Farhan, L. (2021). Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions. Journal of Big Data, 8(1), 1-74.
3. McAndrew, A. (2004). An Introduction to Digital Image Processing with Matlab Notes for scm 2511 Image Processing. School of Computer Science and Mathematics, Victoria University of Technology, 1-43.
4. Tripathi, M. (2021). Analysis of Convolutional Neural Network Based Image Classification Techniques. Journal of Innovative Image Processing (JIIP), 3(02), 100-117.
5. Kamavisdar P., Saluja S. and Agrawal S. (2013). A Survey on Image Classification Approaches and Techniques. *International Journal of Advanced Research in Computer and Communication Engineering*, 2(1), 1005-1009.
6. Goodfellow I., Bengio, Y., and Courville, A. (2016). Deep Learning. İngiltere: MIT Press, 164-341.
7. Yamashita, R., Nishio, M., Do, R. K. G., Togashi, K. (2018). Convolutional Neural Networks: an Overview and Application in Radiology. Insights into Imaging, 9(4), 611-629.
8. https://medium.com/deep-learning-from-deepest/derin-öğrenme-ve-evrişimsel-sinir-ağlari-446dc8a8d2f
9. Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems, 25, 1097-1105.
10. Doğan, F., Türkoğlu, İ., (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, Sakarya University Journal of Computer and Information Sciences, Vol-1, Saucis-1.
11. Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2016). Deeplab: Semantic Image Segmentation with Deep Convolutional Nets Atrous Convolution and Fully Connected crfs. arXiv preprint arXiv:1606.00915.
12. Cengil, E., (2021). İki Boyutlu Sağlık, Tarım ve İş Güvenliği İmgeleri Üzerinde Sınıflandırma ve Nesne Tespiti, Doktora Tezi, Fırat Üniversitesi.
13. Simonyan, K. ve Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint arXiv:1409.1556.

14. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 770-778).
15. Bezdan, T. ve Džakula, N. B. 2019. Convolutional Neural Network Layers and Architectures. In Sinteza 2019-International Scientific Conference on Information Technology and Data Related Research, 445-451. Singidunum University.
16. More, O. 2020. Web Sitesi: https://becominghuman.ai/resnet-convolution-neural-network- e10921245d3d/, Erişim Tarihi: 27.08.2020.
17. Chollet, F. (2017). Xception: Deep Learning with Depth wise Separable Convolutions. in Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition.
18. Srinivasan, K., Garg, L., Datta, D., Alaboudi, A. A., Jhanjhi, N. Z., Agarwal, R., Thomas, A. G. (2021). Performance Comparison of Deep CNN Models for Detecting Driver's Distraction. CMC- Computers, Materials & Continua, 68(3), 4109-4124.
19. Chollet, F., "Xception: Deep Learning with Depthwise Separable Convolutions", (2017).
20. Zoph, B., Vasudevan V., Shlens J., Le Q. (2018). Learning Transferable Architectures for Scalable Image Recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
21. The CIFAR-10 Dataset. https://www.cs.toronto.edu/~kriz/cifar.html Erişim Tarihi 05.05.2022.
22. Redmon, J. ve Farhadi, A. (2018). Yolov3: An Incremental Improvement. arXiv preprint arXiv:1804.02767.
23. Liu, J., (2020). Tomato Diseases and Pests Detection Based on Improved Yolo V3 Convolutional Neural Network, Facility Horticulture Laboratory of Universities in Shandong, Weifang, China.
24. Ma, N., Zhang, X., Zheng, H. T., Sun, J. (2018). Shufflenet v2: Practical Guidelines for Efficient CNN Architecture Design. In Proceedings of the European Conference on Computer Vision (ECCV) (pp. 116-131).
25. Zhang, X., Zhou, X., Lin, M., Sun, J. (2018). Shufflenet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 6848-6856).
26. Tan, M. ve Le, Q. (2019). Efficientnet: Rethinking Model Scaling for Convolutional Neural Networks. In International Conference on Machine Learning, PMLR.
27. Ma, N., Zhang, X., Zheng, H. T., Sun, J. (2018). Shufflenet v2: Practical Guidelines for Efficient CNN Architecture Design. In Proceedings of the European Conference on Computer Vision (ECCV) (pp. 116-131).
28. Zhang, X., Zhou, X., Lin, M., Sun, J. (2018). Shufflenet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 6848-6856).
29. Graphics https://paperswithcode.com/method/shufflenet-v2-block Erişim Tarihi 06.05.2022.

30. Kumar R. Adding Binary Search Connections to Improve DenseNet Performance. 5th International Conference on Next Generation Computing Technologies. Dehradun: NGCT-2019;2019. SSRN: https://ssrn.com/abstract=3545071

31. DenseNet Architecture https://pytorch.org/hub/pytorch_vision_densenet/

32. Özyurt F., Sert E., Avcı D. An Expert System for Brain Tumor Detection: Fuzzy C-Means with Super Resolution and Convolutional Neural Network with Extreme Learning Machine, Medical Hypotheses,134,1-8, 2020.

33. F. Iandola, S. Han, M. Moskewicz, K. Ashraf, W. Dally, K. Keutzer, SqueezeNet: AlexNet-Level Accuracy with 50x Fewer Parameters and <0.5MB model size arxiv. 1602.07360 (2016).

34. SqueezeNet Architecture https://towardsdatascience.com/review-squeezenet-image-classification-e7414825581a

35. Ronneberger, O., Fischer, P. ve Brox, T. (2015). U-net: Convolutional Networks for Biomedical Image Segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention* (ss. 234–241).

36. Baştuğ Koç, A., Akgün, D. (2021). U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 407-414.

37. Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. Deep Learning Cambridge: MIT press. 1 (2): 2016.

38. Afan, H., Büyük Verilerde Finansal Tahmin, Doktora Tezi. Yıldız Teknik Üniversitesi, İstanbul, 2020.

39. Jakkula, V. (2006). Tutorial on Support Vector Machine (SVM). School of EECS,Washington State University, 37.

40. Hong, H., Pradhan, B., Bui, D. T., Xu, C., Youssef, A. M., Chen, W. (2017). Comparison of Four Kernel Functions Used in Support Vector Machines for Landslide Susceptibility Mapping: a Case Study at Suichuan Area (China). Geomatics, Natural Hazards and Risk, 8(2), 544-569.

41. Support Vector Machine https://mfatihto.medium.com/support-vector-machine-algoritması-makine-öğrenmesi-8020176898d8 Erişim Tarihi 08.05.2022.

42. Hellman, M. E., The Nearest Neighbor Classification Rule with a Reject Option. IEEE Transactions on Systems Science and Cybernetics, 6(3): 179-185, 1970.

43. Peterson, L. E., (2009). K-Nearest Neighbor Scholarpedia, 4(2), 1883.

44. Abu Alfeilat, H. A., Hassanat, A. B., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., Eyal Salman, H. S., Prasath, V. S. (2019). Effects of Distance Measure Choice on k-Nearest Neighbor Classifier Performance: a Review Big Data, 7(4), 221-248.

45. Akkus, Z., Ali, I., Sedlar, J., Kline, T. L., Agrawal, J. P., Parney, I. F., & Erickson, B. J., Predicting 1p19q Chromosomal Deletion of Low-grade Gliomas from MR Images Using Deep Learning. arXiv preprint arXiv:1611.06939, 2016.

46. Vanfretti, L., and Arava, V. N. (2020). Decision Tree-based Classification of Multiple Operating Conditions for Power System Voltage Stability Assessment. International Journal of Electrical Power & Energy Systems, 123, 10625.

47. Connelly, L., Logistic Regression, Medsurg Nursing. 29 (5): (353-354), 2020.

48. Bayes, F. R. S., an Essay Towards Solving a Problem in the Doctrine of Chances. Biometrika, 45(3-4), 296-315,1958.

49. Webb, G. I., Keogh, E., & Miikkulainen, R. (2010). Naïve Bayes. Encyclopedia of Machine Learning, 15, 713-714.

50. Bayes Classification https://coda.io/@franspadi/ec-data-mining-handbok/naive-bayes-classification-38 Erişim Tarihi 08.05.2022

51. Tharwat, A., Gaber, T., Ibrahim, A., Hassanien, A. E. (2017). Linear Discriminant Analysis: A Detailed Tutorial. AI Communications, 30(2), 169-190.

52. Sharma, S., Sharma, S., Athaiya, A. (2017). Activation Functions in Neural Networks. Towards Data Science, 6(12), 310-316.

53. Linear Functions https://ayyucekizrak.medium.com/derin-öğrenme-için-aktivasyon-fonksiyonlarının-karşılaştırılması-cee17fd1d9cd

54. Kanai, S., Fujiwara, Y., Yamanaka, Y., Adachi, S. (2018). Sigsoftmax: Reanalysis of the Softmax Bottleneck. arXiv preprint arXiv:1805.10829.

55. Agarap, A. F. (2018). Deep Learning Using Rectified Linear Units (ReLU). arXiv preprint arXiv:1803.08375.

56. Yang, Y. (2016). *Temporal Data Mining via Unsupervised Ensemble Learning*, Elsevier.

57. Manikandan, G., Karthikeyan, B., Rajendiran, P., Harish, R., Prathyusha, T., & Sethu, V. (2019). Breast Cancer Prediction Using Ensemble Techniques. *Scopus Ijphrd Cıtatıon Score*, *10*(7), 183.

58. Breiman, L., (2001), Random Forests, Machine Learning.

59. Freund, T., Schapire, R. E., (1996). Experiments with a New Boosting Algorithm, In Icml, C.96, 148-156.

60. Akcan, F., (2021). Kollektif Makine Öğrenmesi Metotları ile Göğüs Kanseri Tespiti, İstanbul Üniversitesi-Cerrahpaşa Lisansüstü Eğitim Enstitüsü.

61. Gürkahraman, K. ve Karakiş, R. (2021). Brain Tumors Classification with Deep Learning Using Data Augmentation. *Journal of the Faculty of Engineering and Architecture of Gazi University*, *36*(2), 997–1011. Doi:10.17341/gazimmfd.762056.

62. Noreen, N., Palaniappan, S., Qayyum, A., Ahmad, I., Imran, M. ve Shoaib, M. (2020). A Deep Learning Model Based on Concatenation Approach for the Diagnosis of Brain Tumor. *IEEE Access*, *8*, 55135–55144. Doi:10.1109/ACCESS.2020.2978629.

63. Kazdal, S., Dogan, B., Camurcu, A. Y., 2015. Computer-Aided Detection of Brain Tumors Using Image Processing Techniques. Signal Processing and Comm. Applications Conference (SIU): 863- 866.

64. Ramteke, R.; Monali, K.Y., Automatic Medical Image Classification and Abnormality Detection Using k-Nearest Neighbour. Int. J. Adv. Comput. Res. 2, 190, 2012.

65. Gadpayleand, P., Mahajani, P., Detection and Classification of Brain Tumor in MRI Images. Int. J. Electronic Computer Engineering. 5, 45–49, 2013.

66. Sultan, H. H., Salem, N. M. ve Al-Atabany, W. (2019). Multi-Classification of Brain Tumor Images Using Deep Neural Network. *IEEE Access*, *7*, 69215–69225. Doi:10.1109/ACCESS.2019.2919122.

67. Sobhaninia, Z., Rezaei, S., Karimi, N., Emami, A. ve Samavi, S. (2020, 4-6 Ağustos). *Brain Tumor Segmentation by Cascaded Deep Neural Networks Using Multiple Image Scales.* 28th Iranian Conference on Electrical Engineering (ICEE). Tabriz, Iran: IEEE. Doi:10.1109/ICEE50131.2020.9260876.

68. Arı A., Hanbay D., 2018. Derin Öğrenme Tabanlı Beyin Tümörü Sınıflandırma ve Tespit sistemi, Turkish Journal of Electrical Engineering & Computer Sciences: 26: 2275 – 2286.

69. Demirhan, A. and Güler İ., 2014. Sinirsel Bulanık Çıkarım Sistemi Kullanarak Beyindeki Tümör, Ödem ve Sağlıklı Dokuların Otomatik Olarak Bölütlenmesi. Signal Processing And Communications Applications Conference (SIU): 120-123.

70. Abidin, A. Z., Dar, I., D'Souza, A. M., Lin, E. P., & Wismüller, A., Investigating Quantitative Radiomics Approach for Brain Tumor Classification. In Medical Imaging 2019: Biomedical Applications in Molecular, Structural, and Functional Imaging. International Society for Optics and Photonics. 10953, 109530B, 2019.

71. George, D. N., Jehlol, H. B., Oleiwi, A. S. A., Brain Tumor Detection Using Shape Features and Machine Learning Algorithms. International Journal of Advanced Researching Computer Science and Software Engineering. 5 (10): 454-459, 2015.

72. Sajjad, M., Khan, S., Muhammad, K., Wu W., Ullah A., Baik S.W., Multi-Grade Brain Tumor Classification Using Deep CNN with Extensive Data Augmentation. Journal of Computational Science. 30, 74-82, 2019.

73. Divya, S., Padma Suresh, L. ve John, A. (2020, 18-19 Aralık). *A Deep Transfer Learning Framework for Multi Class Brain Tumor Classification Using MRI.* 2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN), 283–290. Greater Noida, India: IEEE doi:10.1109/ICACCCN51052.2020.9362908.

74. Paul, A., Chauhan, P., Sharma, H., Khosla, K., Srivastava, V. ve Kumar, A. (2022). *Classification of Brain Tumor Images Using Enhanced Deep Learning-based Methodologies.* Saraswat M., Roy S., Chowdhury C., Gandomi A.H. (Ed). International Conference on Data Science and Applications, Lecture Notes in Networks and Systems, 287, 519–532. Singapore: Springer. Doi:10.1007/978-981-16-5348-3-41.

75. Rehman, A., Naz, S., Razzak, M. I., Akram, F. ve Imran, M. (2020). A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning. *Circuits, Systems, and Signal Processing*, *39*(2), 757–775. Doi:10.1007/S00034-019-01246-3/TABLES/8

76. Eker, A. G. ve Duru, N. (2021). Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. *Acta Infologica*, *5*(2), 459–474. Doi:10.26650/acin.927561

77. Anitha, R., Raja, D. S. S., 2017. Development of Computer-Aided Approach for Brain Tumor Detection Using Random Forest Classifier. International Journal of Imaging System and Technology, 28: 48-53.

78. Akkus, Z.; Ali, I.; Sedlár, J.; Agrawal, J.P.; Parney, I.F.; Giannini, C.; Erickson, B.J. Predicting Deletion of Chromosomal Arms 1p/19q in Low- Grade Gliomas from MR Images Using Machine Intelligence. J. Digit. Imaging. 30, 469–476, 2017.

79. Alakwaa, W., Nassef, M., & Badr, A. (2017). Lung Cancer Detection and Classification with 3D Convolutional Neural Network (3D-CNN), Lung Cancer, 8(8).

80. Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. IEEE Transactions on Medical Imaging, 35(5), 1207-1216.

81. Bektaş, B., & Babur, S. (2016, October). Machine Learning Based Performance Development for Diagnosis of Breast Cancer. In Medical Technologies National Congress (TIP-Tekno), 2016 (pp. 1-4). IEEE.

82. Nayak SR, Nayak DR, Sinha U, Arora V, Pachori RB. (2021). Application of Deep Learning Techniques for Detection of COVID-19 Cases Using Chest X-ray Images: a Comprehensive Study. Biomed Signal Process Control. 64, 102365.

83. Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., Li, L. (2020). A Deep Learning System to Screen Novel Coronavirus Disease 2019 Pneumonia Engineering, 6(10), 1122-1129.

84. Hemdan, EED., Shouman M.A, Karar ME. (2020). Covidx-net: a Framework of Deep Learning Classifiers to Diagnose Covid-19 in X-ray Images Hemdan, arXiv preprint arXiv:2003.11055.

85. Dandıl, E., 2017. Implementation and Comparison of Image Segmentation Methods for Detection of Brain Tumors on MR Images. Computer Science and Engineering (UBMK), International Conference on.

86. Deperlioğlu, Ö., Köse, U. (2018, October). Diagnosis of Diabetic Retinopathy by Using Image Processing and Convolutional Neural Network. In 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) (pp. 1-5). IEEE.

87. 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.

88. 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.

89. 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.

90. Vesal, S., Ravikumar, N., Davari, A., Ellmann, S., & Maier, A. (2018). Classification of Breast Cancer Histology Images Using Transfer Learning. Paper Presented at the International Conference Image Analysis and Recognition 812-819.

91. Matsuki, Y., Nakamura, K., Watanabe, H., Aoki, T., Nakata, H., Katsuragawa, S., & Doi, K. (2002). Usefulness of an Artificial Neural Network for Differentiating Benign from Malignant Pulmonary Nodules on High-Resolution BT: Evaluation with Receiver Operating Characteristic Analysis, American Journal of Roentgenology, 178(3), 657-663.

92. Filali, Y., Ennouni, A., Sabri, M. A., Aarab, A. (2018). A Study of Lesion Skin Segmentation, Features Selection and Classification Approaches. In*2018 International Conference on Intelligent Systems and Computer Vision (ISCV)* (pp.1-7). IEEE.

93. Monika, M. K., Vignesh, N. A., Kumari, C. U., Kumar, M. N. V. S. S., Lydia, E. L. (2020). Skin Cancer Detection and Classification Using Machine Learning, *Materials Today: Proceedings*, *33*, 4266-4270.
94. Balaji, V. R., Suganthi, S. T., Rajadevi, R., Kumar, V. K., Balaji, B. S., Pandiyan, S. (2020). Skin Disease Detection and Segmentation Using Dynamic Graph Cut Algorithm and Classification Through Naive Bayes Classifier *Measurement*, *163*, 107922.
95. Kostopoulos, S. A., Asvestas, P. A., Kalatzıs, I. K., Sakellaropoulos, G. C., Sakkıs, T. H., Cavouras, D. A. and Glotsos, D. T., (2017). Adaptable Pattern Recognition System for Discriminating Melanocytic Nevi from Malignant Melanomas Using Plain Photography Images from Different Image Databases, International Journal of Medical informatics, 105: 1-10.
96. Yang, S., Oh, B., Hahm, S., Chung, K. Y. And Lee, B. U., 2017. Ridge And Furrow Pattern Classification For Acral Lentiginous Melanoma Using Dermoscopic İmages. Biomedical Signal Processing And Control, 32: 90-96.
97. Ismail, K. E., AbouRizka, M. A., Maghraby, F. A. (2020, October). Machine Learning Model for Multiclass Lesion Diagnoses. In *2020 2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)* (pp. 397-402). IEEE.
98. TAJEDDIN, N. Z. and ASL, B. M. (2018). Melanoma Recognition in Dermoscopy Images Using Lesion's Peripheral Region Information. Computer Methods and Programs in Biomedicine, 163: 143-153.
99. Barata, C., Celebi, M. E., & Marques, J. S. (2015). Improving Dermoscopy Image Classification Using Color Constancy. *IEEE Journal of Biomedical and Health Informatics*, 19(3), 1146-1152.
100. Abbas, Q., Celebi, M. E., Fondón García, I., & Rashid, M. (2011). Lesion Border Detection in Dermoscopy Images Using Dynamic Programming. *Skin Research and Technology*, 17(1), 91-100.
101. Norton, K. A., Iyatomi, H., Celebi, M. E., Ishizaki, S., Sawada, M., Suzaki, R., Ogawa, K. (2012). Three-Phase General Border Detection Method for Dermoscopy images Using Non-uniform Illumination Correction. *Skin Research and Technology*, 18(3), 290-300.
102. Hoffman, M., 2021. Beyin Yapısı ve Bölümleri. https://www.webmd.com/brain/picture- of-the-brain. Erişim tarihi: 04.04.2022.
103. Dandıl, E., (2015). MR Görüntüleri ve MR Spektroskopi Verileri ile Yapay Öğrenme Tabanlı Beyin Tümörü Tespit Yöntemi ve Uygulaması. (Doktora tezi). Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
104. Brain Tumor MRI Dataset | Kaggle. (05.05.2022). Erişim Adresi https://www.kaggle.com/masoudnickparvar/brain-tumor-mri-dataset
105. Manikandan, G., Karthikeyan, B., Rajendiran, P., Harish, R., Prathyusha, T., & Sethu, V. (2019). Breast Cancer Prediction Using Ensemble Techniques.*SCOPUS IJPHRD CITATION SCORE*, *10*(7), 183.
106. Berg, W. A. (2010). Benefits of Screening Mammography. *Jama*, *303*(2), 168-169.
107. Chest Tumor CT-Scan Dataset | Kaggle. (06.05.2022). Erişim Adresi https://www.kaggle.com/datasets/mohamedhanyyy/chest-ctscan-images

108. Richardson, M. (2003). Understanding the Structure and Function of the Skin. *Nursing times*, *99*(31), 46-48.

109. Lawton, S. (2019). Skin 1: The Structure and Functions of the Skin. *Nurs Times*, *115*, 30-33.

110. Fabbrocini G, De Vita V, Pastore F, D'Arco V, Mazzella C, Annunziata MC, Cacciapuoti S, Mauriello MC, ve diğerleri. Teledermatology: from Prevention to Diagnosis of Nonmelanoma and Melanoma Skin Cancer. International Journal of Telemedicine and Applications 2011; 2011(125762).1-5.

111. Skin Cancer: Malignant vs Benign | Kaggle. (08.05.2022). Erişim Adresi https://www.kaggle.com/datasets/fanconic/skin-cancer-malignant-vs-benign

112. Liu, Y., Zhou, Y., Wen, S., Tang, C. (2014). A Strategy on Selecting Performance Metrics for Classifier Evaluation. International Journal of Mobile Computing and Multimedia Communications (IJMCMC), 6(4), 20-35.

113. Hossin, M., ve Sulaiman, M. N. (2015). A Review on Evaluation Metrics for Data Classification Evaluations. International Journal of Data Mining & Knowledge Management Process, 5(2),1.

114. Varol Malkoçoğlu Berika A., (2020). Akut Lenfoblastik Lösemi Hücrelerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması, Yüksek Lisans, Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü

İNTİHAL RAPORU İLK SAYFASI

Mustafa Güler

ORİJİNALLİK RAPORU

%13	%10	%2	%5
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%3
2	dergipark.org.tr İnternet Kaynağı	%1
3	acikbilim.yok.gov.tr İnternet Kaynağı	%1
4	saucis.sakarya.edu.tr İnternet Kaynağı	%1
5	ayyucekizrak.medium.com İnternet Kaynağı	<%1
6	www.platanuskitap.com İnternet Kaynağı	<%1
7	du.diva-portal.org İnternet Kaynağı	<%1
8	dspace.ankara.edu.tr İnternet Kaynağı	<%1
9	www.openaccess.hacettepe.edu.tr:8080 İnternet Kaynağı	<%1

ETİK KURUL İZİN YAZISI

Uyarı: Canlı denekler üzerinde yapılan tüm araştırmalar için Etik Kurul Belgesi alınması zorunludur.

☐ **Etik Kurul izni gerekmektedir.**

☒ **Etik Kurul izni gerekmemektedir.**

Mustafa GÜLER

KURUM İZNİ YAZILARI

Uyarı: Canlı ve cansız deneklerle yapılan tüm çalışmalar için kurum izin belgelerinin eklenmesi zorunludur.

☐ **Kurum izni gerekmektedir.**

☒ **Kurum izni gerekmemektedir.**

Mustafa GÜLER