



BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ

T.C.

BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANA BİLİM DALI

**TIBBİ GÖRÜNTÜLERDE SINIFLANDIRMA BAŞARISININ
ARTTIRILMASI İÇİN ÖN İŞLEM VE MODEL
PARAMETRELERİNİN SEZGİSEL OPTİMİZASYONU**

Furkan ATLAN

DOKTORA TEZİ

DANIŞMAN

Dr. Öğr. Üyesi İhsan PENÇE

BURDUR-2023

T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
YÖNETİM BİLİŞİM SİSTEMLERİ ANA BİLİM DALI

TIBBİ GÖRÜNTÜLERDE SINIFLANDIRMA BAŞARISININ
ARTTIRILMASI İÇİN ÖN İŞLEM VE MODEL
PARAMETRELERİNİN SEZGİSEL OPTİMİZASYONU

Furkan ATLAN

DOKTORA TEZİ

DANIŞMAN

Dr. Öğr. Üyesi İhsan PENÇE

Üye: Prof. Dr. Ecir Uğur KÜÇÜKSİLLE

Üye: Doç. Dr. Emrah HANÇER

Üye: Doç. Dr. Onur SEVLİ

Üye: Dr. Öğr. Üyesi Nazan KEMALOĞLU ALAGÖZ

BURDUR-2023

T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

ETİK BEYAN

Burdur Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'ne göre hazırlamış olduğum “Tıbbi Görüntülerde Sınıflandırma Başarısının Arttırılması için Ön İşlem ve Model Parametrelerinin Sezgisel Optimizasyonu” adlı tezin hazırlanması sürecinde akademik ve etik kuralları ihlal etmediğimi, tezimin özgün olduğunu, başvurduğum kaynakları metin içinde, dipnotlarda ve kaynakçada eksiksiz ve bilimsel kurallara uygun olarak gösterdiğimi taahhüt ederim.

Furkan ATLAN

TEŞEKKÜR

Yüksek Lisans eğitiminde tanıdığım ve o günden bu yana her daim yanımda olan, desteğini hiçbir zaman esirgemeyen ve kendisinden çok şey öğrendiğim danışman hocam Dr. Öğr. Üyesi İhsan PENÇE'ye çok teşekkür ederim. Kendisiyle yolumuzun kesişmesi, hayatımın en önemli dönüm noktalarından biri olmuştur ve hep öyle kalacaktır. O, benim için düşünceli, şefkatli bir öğretici ve bir ağabey olarak kalacaktır.

Tez İzleme Komitesinde yer alan, katkıları ve yönlendirmeleri ile bu çalışmanın gelişimine yardımcı olan hocalarım Doç. Dr. Emrah Hançer'e ve Doç. Dr. Onur SEVLİ'ye çok teşekkür ederim.

Bugüne kadar beni asla yalnız bırakmayan sevgili aileme ve yaşadıklarımızı her daim özlediğim dostlarıma çok teşekkür ederim.

Bu çalışmadaki bulguların elde edilmesinde, TÜRKİYE Bilimsel ve Teknolojik Araştırma Kurumu'na (TÜBİTAK) bağlı Türk Ulusal Bilim e-Altyapısı (TRUBA) sisteminin sunmuş olduğu donanımlar için de ayrıca teşekkür ederim.

(ATLAN, Furkan, Tıbbi Görüntülerde Sınıflandırma Başarısının Arttırılması için Ön İşlem ve Model Parametrelerinin Sezgisel Optimizasyonu, Doktora Tezi, Burdur, 2023)

ÖZET

Hastalıkların tespiti, takibi ve tedavilerinin uygulanması amacıyla tıbbi görüntüleme tekniklerinden yararlanılmaktadır. Fakat tıbbi görüntüleri kullanarak tanı koyan uzmanlar da unutmama ve yorgunluk gibi insani faktörlerden etkilenmektedir. Yapay zekânın alt dalı olan derin öğrenme teknolojisi ile geliştirilen modeller, birçok hastalığın teşhisinde ve sınıflandırılmasında kullanılmaktadır. Bu çalışmada, tıbbi görüntülerin sınıflandırma başarısının artırılması için ön işleme teknikleri de kullanılarak en uygun model ve parametrelerin sezgisel optimizasyon ile belirlenmesi gerçekleştirilmiştir. Meme kanseri veri setleri (MKVS-1, MKVS-2), akciğer nodülü veri seti (ANVS), akciğer kanseri veri seti (AKVS) ve diyabetik retinopati (DR) göz hastalığının sınıflandırılması için, literatürde önemli yer tutan veri setleri kullanılmıştır. Verilere ilk olarak kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE) ön işleme tekniği uygulanmıştır. Daha sonra orijinal ve CLAHE uygulanmış veriler olarak ikiye ayrılan bu veri setlerine çeşitli filtreler uygulanmıştır. Veriler hazırlandıktan sonra ızgara arama (IA), diferansiyel evrim (DE) ve parçacık sürü optimizasyonu (PSO) yöntemleri ile ANVS üzerinde bir optimizasyon çalışması yapılmıştır. IA yöntemi ile ANVS üzerinde en yüksek doğruluk elde edildikten sonra DE ve PSO algoritmaları 10 defa çalıştırılmış ve karşılaştırma yapılmıştır. DE optimizasyonu daha başarılı bulunduktan sonra beş veri seti DE algoritması ile 10 defa çalıştırılmıştır. ANVS, MKVS-1 ve DR veri setlerinde veri artırma uygulanmamış hali ile, AKVS ve MKVS-2 veri setlerinde ise veri artırma uygulanmış hali ile DE algoritması kullanılarak 10 defa çalıştırılma sonrasında en yüksek doğruluk skorları elde edilmiştir. ANVS için 0,9903, MKVS-1 için 0,813, DR veri seti için 0,9141, AKVS için 0,95 ve MKVS-2 için 0,8807 doğruluk elde edilmiştir. Aynı veri setlerinin kullanıldığı diğer çalışmalarla yapılan kıyaslamada ANVS ve AKVS için literatüre göre daha başarılı sonuçların elde edildiği gözlenmiştir. MKVS-1 ve DR veri setlerinin doğruluk açısından literatürdeki sonuçlara çok yakın sonuçlar elde etmiş olup diğer sınıflandırma metriklerinde ise diğer çalışmalara göre daha başarılı sonuçlar elde edilmiştir.

Anahtar Kelimeler: Yapay Zekâ, Derin Öğrenme, Tıbbi Görüntü Sınıflandırması, Sezgisel Optimizasyon, Diferansiyel Evrim



ABSTRACT

Medical imaging techniques are used to detect, monitor and treat diseases. However, experts who make diagnoses using medical images are also affected by human factors such as forgetfulness and fatigue. Models developed with deep learning technology, a sub-branch of artificial intelligence, are used in the diagnosis and classification of many diseases. In this study, the most appropriate models and parameters were determined by heuristic optimization by using preprocessing techniques to increase the classification success of medical images. For the classification of breast cancer datasets (MKVS-1, MKVS-2), lung nodule dataset (ANVS), lung cancer dataset (AKVS) and diabetic retinopathy (DR) eye disease, datasets that have a significant place in the literature were used. A contrast-limited adaptive histogram equalization (CLAHE) preprocessing technique was first applied to the data. Various filters were then applied to these data sets, which were divided into original and CLAHE applied data. After the data was prepared, an optimization study was performed on ANVS with grid search (IA), differential evolution (DE) and particle swarm optimization (PSO) methods. After obtaining the highest accuracy on ANVS with the IA method, DE and PSO algorithms were run 10 times and compared. After DE optimization was found to be more successful, five data sets were run 10 times with the DE algorithm. The highest accuracy scores were obtained in its form without data augmentation in the ANVS, MKVS-1 and DR datasets, and running 10 times with the DE algorithm after in its form applying data augmentation in the AKVS and MKVS-2 datasets. Accuracy of 0,9903 for ANVS, 0,813 for MKVS-1, 0,9141 for DR data set, 0,95 for AKVS and 0,8807 for MKVS-2 was obtained. In comparison with other studies using the same data sets, it was observed that more successful results were obtained for ANVS and AKVS compared to the literature. In terms of accuracy, MKVS-1 and DR datasets obtained results that are very close to the results in the literature, and in other classification metrics, more successful results were obtained compared to other studies.

Keywords: Artificial Intelligence, Deep Learning, Medical Image Classification, Heuristic Optimization, Differential Evolution

İÇİNDEKİLER

ETİK BEYAN.....	i
TEŞEKKÜR	ii
ÖZET	iii
ABSTRACT	v
İÇİNDEKİLER.....	vi
TABLOLAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xiii
KISALTMALAR.....	xvi
GİRİŞ	1

BİRİNCİ BÖLÜM

TIBBİ GÖRÜNTÜ SINIFLANDIRMASINA DAİR KAVRAMSAL ÇERÇEVE

1.1. Yapay Zekâ	7
1.2. Makine Öğrenmesi	8
1.2.1. Denetimli Öğrenme	10
1.2.2. Denetimsiz Öğrenme	10
1.2.3. Pekiştirmeli Öğrenme	11
1.3. Derin Öğrenme.....	12
1.4. Yapay Sinir Ağları	12
1.5. Evrişimli Sinir Ağları	14
1.6. Tıp Alanında Yapay Zekâ Kullanımı	15
1.7. Tıbbi Görüntüleme	17
1.8. Tıbbi Görüntü Çeşitleri.....	18

1.8.1. Bilgisayarlı Tomografi Görüntüleri	18
1.8.2. Histopatolojik Görüntü	18
1.8.3. Tıpta Dijital Görüntüleme ve İletişim Görüntüsü	19
1.8.4. Nöro Görüntüleme Bilişim Teknolojisi Girişimi Görüntüsü	19
1.8.5. Optik Koherens Tomografi Görüntüleri	20

İKİNCİ BÖLÜM

LİTERATÜRDEKİ İLGİLİ ÇALIŞMALAR

ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOT

3.1. Veri Setleri	37
3.1.1. Akciğer Nodülü Veri Seti	37
3.1.2. Meme Kanseri Veri Seti-1	37
3.1.3. Diyabetik Retinopati Veri Seti.....	38
3.1.4. Akciğer Kanseri Veri Seti.....	38
3.1.5. Meme Kanseri Veri Seti-2.....	38
3.2. Veri Setleri Hakkında İstatistiki Bilgiler	38
3.3. Veri Ön İşleme	40
3.3.1. Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme	40
3.3.2. Veri Artırma.....	41
3.3.2.1. Yatay ve Dikey Kaydırma	42
3.3.2.2. Yatay ve Dikey Çevirme	42
3.3.2.3. Rastgele Döndürme.....	42
3.3.2.4. Rastgele Yakınlaştırma.....	42

3.3.3. Filtreler.....	42
3.3.3.1. Anizotropik Difüzyon Filtre	43
3.3.3.2. İki Taraflı Filtre.....	43
3.3.3.3. BM3D Filtre	44
3.3.3.4. Gauss Filtre.....	45
3.3.3.5. Ağırlıklandırılmış Gauss Filtre	45
3.3.3.6. Homomorfik Filtre.....	46
3.3.3.7. Ortalama Filtre.....	47
3.3.3.8. Toplam Varyasyon Filtre	47
3.3.3.9. Dalgacık Filtre.....	48
3.4. Evrişimli Sinir Ağları Modelleri	51
3.4.1. Vgg16.....	51
3.4.2. Vgg19.....	53
3.4.3. ResNet50.....	53
3.4.4. EfficientNet.....	55
3.4.5. MobileNetv2	57
3.4.6. DenseNet121	59
3.5. Sınıflandırıcılar	60
3.5.1. Destek Vektör Makinesi.....	60
3.5.2. Rassal Orman	64
3.5.3. K-En Yakın Komşu.....	64
3.5.4. XGBoost	65
3.5.5. İki Katmanlı Yapay Sinir Ağı.....	68
3.6. Optimizasyon Yöntemleri.....	68
3.6.1. Izgara Arama	68

3.6.2. Sezgisel Optimizasyon.....	68
3.6.2.1. Diferansiyel Evrim.....	69
3.6.2.2. Parçacık Sürü Optimizasyonu	70
3.7. Değerlendirme Metrikleri	72

DÖRDÜNCÜ BÖLÜM

BULGULAR VE TARTIŞMA

4.1. ANVS Üzerinde IA, DE ve PSO Yöntemlerine ait Sonuçlar	78
4.2. Tüm Veri Setlerinin DE Algoritması ile Çalıştırılması.....	83
4.2.1. ANVS'nin DE Algoritması ile Çalıştırılması.....	87
4.2.2. MKVS-1'in DE Algoritması ile Çalıştırılması.....	90
4.2.3. DR Veri Setinin DE Algoritması ile Çalıştırılması.....	92
4.2.4. AKVS'nin DE Algoritması ile Çalıştırılması.....	94
4.2.5. MKVS-2'nin DE Algoritması ile Çalıştırılması.....	96
4.3. Veri Artırma Uygulanan Veri Setlerinin DE Algoritması ile Çalıştırılması.....	98
4.3.1. Veri Artırma Uygulanmış ANVS Analizi.....	99
4.3.2. Veri Artırma Uygulanmış DR Veri Seti Analizi	101
4.3.3. Veri Artırma Uygulanmış AKVS'nin Analizi	103
4.3.4. Veri Artırma Uygulanmış MKVS-2'nin Analizi	105
4.4. Veri Artırma Öncesi ve Sonrası Sonuçların Karşılaştırılması.....	108
4.5. Literatür Karşılaştırması	109
4.5.1. ANVS için Literatür Karşılaştırması	110
4.5.2. MKVS-1 için Literatür Karşılaştırması	111
4.5.3. DR Veri Seti için Literatür Karşılaştırması	112
4.5.4. AKVS için Literatür Karşılaştırması	113

4.5.5. MKVS-2 için Literatür Karşılaştırması Sonuçları.....	114
SONUÇ	116
KAYNAKÇA.....	123
ÖZGEÇMİŞ.....	163



TABLÖLER DİZİNİ

Tablo 1. Çalışmada Kullanılan Veri Setlerine Ait İstatistikî Bilgiler	39
Tablo 2. Sınıflandırıcılara Ait Hiper Parametreler ve Açıklamaları.....	77
Tablo 3. İA, DE ve PSO Yöntemlerinde Kullanılan Parametreler.....	78
Tablo 4. İA Yöntemi ile Her Bir Modele Ait En Yüksek Doğruluk Skoru.....	79
Tablo 5. EfficientNetB0-DVM Kombinasyonu ile Elde Edilen Diğer Başarılı Sonuçlar	80
Tablo 6. DE Algoritması ile Her Bir Bağımsız Çalıştırma Sonrası Elde Edilen En İyi Sonuçlar ve Kombinasyonları	81
Tablo 7. PSO Algoritması ile Her Bir Bağımsız Çalıştırma Sonrası Elde Edilen En İyi Sonuçlar ve Kombinasyonları	82
Tablo 8. DE ve PSO Algoritmalarına Ait Sonuçların Karşılaştırılması	82
Tablo 9. Optimize Edilen Sınıflandırıcı Hiper Parametreleri ve Modeller.....	84
Tablo 10. Sonuç Kombinasyonlarına Ait Kısaltmalar	85
Tablo 11. ANVS'nin DE Algoritması ile Çalıştırılması	88
Tablo 12. MKVS-1'in DE Algoritması ile Çalıştırılması	90
Tablo 13. DR Veri Setinin DE Algoritması ile Çalıştırılması	92
Tablo 14. AKVS'nin DE Algoritması ile Çalıştırılması	94
Tablo 15. MKVS-2'nin DE Algoritması ile Çalıştırılması	96
Tablo 16. Veri Artırma Uygulanan Veri Setlerinin Öncesi ve Sonrasına Ait Eğitim Verisi Sayıları	98
Tablo 17. Veri Artırma Uygulanmış ANVS'nin DE Algoritması ile Çalıştırılması	99
Tablo 18. Veri Artırma Uygulanmış DR Veri Setinin DE Algoritması ile Çalıştırılması	101
Tablo 19. Veri Artırma Uygulanmış AKVS'nin DE Algoritması ile Çalıştırılması	103
Tablo 20. Veri Artırma Uygulanmış MKVS-2'nin DE Algoritması ile Çalıştırılması	106

Tablo 21. En Yüksek Doğruluk Skorunu Sağlayan Yöntem ve Kombinasyon Karşılaştırması	108
Tablo 22. ANVS (LUNA16) Veri Setine Ait Literatür Karşılaştırması.....	110
Tablo 23. MKVS-1 (PCam) için Literatür Karşılaştırması.....	111
Tablo 24. DR (RFMiD) Veri Setine Ait Literatür Karşılaştırması	112
Tablo 25. AKVS (TCGA-LUAD) için Literatür Karşılaştırması.....	113
Tablo 26. MKVS-2 (BreaKHis) için Literatür Karşılaştırması.....	114



ŞEKİLLER DİZİNİ

Şekil 1. Yapay Zekâ, Makin Öğrenmesi, Derin Öğrenme Arasındaki Hiyerarşik İlişki...	8
Şekil 2. Makine Öğrenmesi Stratejileri Algoritmaları	9
Şekil 3. YSA Model Mimarileri a) Klasik, b) Derin.....	13
Şekil 4. Klasik ESA Mimarisi	15
Şekil 5. Klasik Bir TAYZ Uygulamasında Bilginin Kullanımı.....	16
Şekil 6. Çalışmada Kullanılan 5 Veri Setine Ait Orijinal Görüntüler.....	39
Şekil 7. Veri Setlerine Ait Orijinal (Üstteki) ve CLAHE Uygulanmış (Altteki) Görüntüler	40
Şekil 8. Veri Artırma Tekniği Uygulanmış Görüntüler (Artırılmış-O: Artırılmış Orijinal Görüntüler; Artırılmış-C: Artırılmış CLAHE’li Görüntüler)	41
Şekil 9. ANVS Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE	49
Şekil 10. MKVS-1 Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE.....	50
Şekil 11. DR Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE.....	50
Şekil 12. AKVS Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE.....	51
Şekil 13. MKVS-2 Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE.....	51
Şekil 14. Vgg16 Mimarisi.....	52
Şekil 15. ResNet Mimarisi	53
Şekil 16. Artık Öğrenme Yapısı.....	54
Şekil 17. EfficientNet Modelinde Bileşik Katsayı ile Ölçeklendirme.....	55
Şekil 18. EfficientNet Mimarisi	56
Şekil 19. MobileNet ve MobileNetv2 Arasındaki Mimari Farklar	58
Şekil 20. DenseNet Modelinde 5 Katmanlı Dense Blok Yapısı	59
Şekil 21. DVM ile Hiper Düzlem Çizilmesi ve Sınıfların Ayrılması	62
Şekil 22. DVM’de Çekirdek Fonksiyonu Eşlemesi a) Doğrusal Olarak Ayrılamayan Veriler, b) Doğrusal Olarak Ayrılabilir Veriler	63

Şekil 23. Karmaşıklık Matrisi	73
Şekil 24. Çalışmanın Genel Akışı.....	76
Şekil 25. IA Yöntemi ile Doğruluk Skorunun Parametrelere Göre Değişimi a) Model-Sınıflandırıcı; b) Model-Sınıflandırıcı-Veri Türü	80
Şekil 26. En İyi Kombinasyonların İsimlendirilmesi için Akış Diyagramı	86
Şekil 27. ANVS için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri.....	89
Şekil 28. ANVS için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi	89
Şekil 29. MKVS-1 için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri.....	91
Şekil 30. MKVS-1 için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi	91
Şekil 31. DR Veri Seti için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri	93
Şekil 32. DR Veri Seti için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi	93
Şekil 33. AKVS için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri.....	95
Şekil 34. AKVS için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi	95
Şekil 35. MKVS-2 için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri.....	97
Şekil 36. MKVS-2 için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi	97
Şekil 37. Veri Artırma Uygulanmış ANVS için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri	100
Şekil 38. Veri Artırma Uygulanmış ANVS için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi.....	100
Şekil 39. Veri Artırma Uygulanmış DR Veri Seti için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri	102
Şekil 40. Veri Artırma Uygulanmış DR Veri Seti için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi.....	102
Şekil 41. Veri Artırma Uygulanmış AKVS için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri	104
Şekil 42. Veri Artırma Uygulanmış AKVS için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi.....	104

Şekil 43. Veri Artırma Tekniği MKVS-2 için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri	107
Şekil 44. Veri Artırma Uygulanmış MKVS-2 için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi	107



KISALTMALAR

ABSO	: Ateş Böceği Sürü Optimizasyonu
AD	: Anizotropik Difüzyon
AG	: Ağırlıklandırılmış Gauss
AHE	: Uyarlamalı Histogram Eşitleme
AKVS	: Akciğer Kanseri Veri Seti
ANVS	: Akciğer Nodülü Veri Seti
AUC	: Eğrinin Altındaki Alan
B0	: EfficientNetB0
B7	: EfficientNetB7
BDTS	: Bilgisayar Destekli Tanı Sistemleri
BM3D	: 3 Boyutlu Blok Eşleştirme
BreaKHis	: Breast Cancer Histopathological Database
BT	: Bilgisayarlı Tomografi
BTO	: Biyocoğrafya Tabanlı Optimizasyon
CART	: Sınıflandırma ve Regresyon Ağaçları Yapısı
CK	: Cohen Kappa
CL	: CLAHE
CLAHE	: Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme
D121	: DenseNet121

DE	: Diferansiyel Evrim
DİA	: Derin İnanç Ağı
DICOM	: Tıpta Dijital Görüntüleme ve İletişim
DMÖ	: Diyabetik Makula Ödemi
DN	: Doğru Negatif
Doğ.	: Doğruluk
DP	: Doğru Pozitif
DR	: Diyabetik Retinopati
Duy.	: Duyarlılık
DVM	: Destek Vektör Makineleri
ESA	: Evrişimli Sinir Ağları
F1	: F1-Skor
GA	: Genetik Algoritma
GB	: Gradient Boosting
GBPO	: Güvenli Bölge Politika Optimizasyonu
HM	: Homomorfik
IA	: Izgara Arama
İKT	: İki Taraflı
KA	: Karar Ağaçları
KÇO	: Karıştırılmış Çoban Optimizasyonu

Kes.	: Kesinlik
K-EYK	: K En Yakın Komşu
KKO	: Karınca Kolonisi Optimizasyonu
KNV	: Koroid Neovaskülrasyon
LR	: Lojistik Regresyon
LUNA16	: Lung Nodule Analysis
MBConv	: Hareketli Ters Darboğaz Evrişim
MBv2	: MobileNetv2
MRG	: Manyetik Rezonans Görüntüleme
MU	: Manhattan Uzaklığı
NIFTI	: Nöro Görüntüleme Bilişim Teknolojisi Girişimi
OKT	: Optik Koherens Tomografi
Orj	: Orijinal
ÖÜ	: Öklid Uzaklığı
PCam	: Patch Camelyon
PSO	: Parçacık Sürü Optimizasyonu
R50	: ResNet50
RFMiD	: Retinal Fundus Multi-disease Image Dataset
RO	: Rassal Orman
ROC	: Alıcı İşlem Karakteristiği

TAYZ	: Tıp Alanında Yapay Zekâ
TBA	: Temel Bileşenler Analizi
TCGA-LUAD	: The Cancer Genome Atlas Lung Adenocarcinoma
TSA	: Tekrarlayan Sinir Ağları
WIS	: Slayt Resminin Tamamı
WİST	: Wilcoxon İşaretli Sıra Testi
XGB	: XGBoost
YAK	: Yapay Arı Kolonisi
YN	: Yanlış Negatif
YP	: Yanlış Negatif
YSA	: Yapay Sinir Ağları
YSDO	: Yaşam Seçimine Dayalı Optimizasyon

GİRİŞ

İnsan vücudu gibi son derece karmaşık bir sisteme ait statik ve dinamik özellikler hakkında veri elde edilmesi süreci oldukça büyük miktarda bilgi ile sonuçlanmaktadır. Uzmanlar ve araştırmacılar için bilginin daha faydalı bir teşhis yöntemi geliştirmek için bilginin hangi yollarla elde edildiği, işlenmesi ve gösterimi oldukça zor bir konudur (Hendee ve Ritenour, 2002: 1-3).

Tıbbi görüntüleme, vücudun iç yapısının incelenmesi ve müdahale edilmesi için görsel olarak ifade edilmesi ya da organların ve dokuların işlevselliklerinin görüntülenmesi olarak ifade edilmektedir (Ritter vd., 2011).

İnsan vücudu, hastalıkların tespiti, izlenmesi ve hangi tedavilerin uygulanması gerektiği ile ilgili tıbbi süreçlerin takip edilmesi amacıyla farklı görüntü tekniklerine tâbi tutulmaktadır. Bu durum, vücudun ancak farklı enerji türleri ile görüntülenmesi sayesinde gerçekleştirilmektedir. En çok kullanılan tıbbi görüntüleme tekniklerinden Manyetik Rezonans Görüntüleme (MRG) radyo frekanslarını, Bilgisayarlı Tomografi (BT) X-ışınlarını, Patoloji görünür ışığı, Ultrason yüksek frekanslı ses dalgalarını ve Nükleer Tıp Görüntüleme ise gama ışınlarını bir enerji olarak kullanmaktadır (Doi, 2007; Bushberg ve Boone, 2011: 3).

Teknoloji ve bilgisayar donanımlarındaki gelişmelere rağmen, radyolojik görüntüler radyologların analizleri doğrultusunda etiketlenirler. Bu durum, yoğunluk ve yorgunluk gibi kısıtlar sebebi ile radyologlar açısından; zaman, eğitim ve maliyet gibi kısıtlar sebebiyle de kurumlar (devlet, üniversite, hastane vb.) açısından ciddi bir yüküdür. Bu sebeple otomatik öğrenen makine öğrenmesi algoritmaları ile ilgili çalışmalar artmıştır (Shen vd., 2017; Gruetzemacher vd., 2018; Ker vd., 2019; Singh vd., 2020; Parmar vd., 2020;).

Birbirine bağlı olan birden çok yapay nöron katmanından meydana gelen sinir ağlarının verilerden öğrenmesini ifade eden derin öğrenme (Shen vd., 2017), özellikle milyonlarca farklı görüntünün etiketlenmesiyle oluşturulan ImageNet veri setindeki görüntülerin sınıflandırılması yarışması için geliştirilen AlexNet modeli (Krizhevsky vd, 2012) tekrar popüler bir hale gelmiştir (Singh vd., 2020).

Çek-senet davalarında sahte imza ayırt etmek, sokak tabelalarını okumak gibi işlevleri yerine getirmek amacıyla geliştirilen Evrişimli Sinir Ağları (ESA) (LeCun vd., 1998), çok hızlı ve güçlü bilgisayar donanımlarının üretilmesiyle beraber (Liu vd., 2012) mimarisine ait parametre sayıları arttırılarak (Krizhevsky vd, 2012) daha iyi bir hâle getirilmiştir. Görüntüdeki özniteliklerin öğrenilmesine olanak sağlayan ESA, tıbbi görüntüleme alanındaki zorluklardan etiketleme (tümörlü dokunun belirlenmesi) sorunu için zaman, maliyet ve işgücü açısından kolaylıklar sağlamaktadır.

Yine donanımların hesaplama gücünün artması ve ESA modellerinin gelişmesiyle beraber 2 boyutlu (2B) nesnelerin yanında uydu görüntüleri ve tıbbi görüntüler gibi 3 boyutlu (3B) ve 4 boyutlu (4B) görüntülerin incelenmesi, sınıflandırılması ve segmentasyonu da mümkün hâle gelmiştir (Singh vd., 2020; Landini vd., 2008). Yapısı ve formatı gereği 2B görüntülerden farklı olan 3B ya da 4B tıbbi görüntüler, ön işleme teknikleri sayesinde analiz edilmeye hazır hale getirilmektedir. Bu aşamadan sonra ise görüntü hangi amaç için kullanılmak isteniliyorsa (sınıflandırma, segmentasyon) uygun bir ESA modeli ile eğitilmektedir (Landini vd., 2008; Wang vd., 2020).

Yapay zekâ teknolojilerinin sağladığı yenilikler ile Bilgisayar Destekli Tanı Sistemleri (BDTS) (Park vd., 2009:1) özellikle patolojik ve radyolojik görüntülerdeki yanlış değerlendirmelerin önüne geçmekte ve uzmanlara doğru bir teşhis koymaları noktasında yardımcı olmaktadır.

2019 yılının sonlarında ortaya çıkan ve tüm dünyayı etkisi altına alan Covid19 pandemisi nedeniyle yapay zekâ teknolojilerinin ve onun alt dalları olarak nitelendirilen makine öğrenmesi ve derin öğrenme modellerinin Covid19 hastalık tespiti (Kollias vd., 2022; Tahamtan vd., 2020), diğer hastalıklarla karşılaştırılması (Malik vd., 2023; Bai vd., 2020), sınıflandırılması (Bhosale ve Patnaik, 2023; Aggarwal vd., 2022) ve hastalıklı bölgelerin segmentasyonu (Li vd., 2022; Karthik vd., 2022) gibi çalışmalarda büyük bir artış görülmüştür. Her ne kadar Covid19 pandemisi azalmış olsa da yaşanan bu durum nedeniyle tıp alanında yapay zekâ teknolojilerinin kullanılması bir milat olmuştur. Zira, pandeminin oldukça azaltılmış olmasına karşın her sene yüz binlerce insanın hayatını kaybetmesine sebep olan kanser hastalığına tam anlamıyla bir çözüm geliştirilememiştir.

Kanser, vücuttaki hücrelerin düzensiz bölünmesidir. 2020 yılı kanser istatistiklerine göre (Mattiuzzi ve Lippi, 2020:1) tüm dünyada en sık görülen kanser

türlerinde birinci sırada kadınlar için 2,3 milyon vaka sayısı ile meme kanseri ve ikinci sırada da 2,2 milyon vaka sayısı ile akciğer kanseri gelmektedir. Türkiye’de ise kadınlarda en sık görülen kanser meme kanseri ve erkeklerde en çok görülen kanser ise akciğer kanseri olarak tespit edilmiştir. Buna göre 2020 yılında Türkiye nüfusu 84,3 milyon iken 233.834 kişiye kanser teşhisi konulmuştur. Bu hastalardan 41.264’ü akciğer kanserine, 24.175’i ise meme kanserine yakalanmıştır (Özdoğan, 2023). Hem dünyada hem de Türkiye’de kanser türleri arasında ilk iki sırada meme kanseri ve akciğer kanseri bulunmasına karşın sadece sıralamada farklılıklar görülmektedir.

Kanser hastalığı, erken dönemde teşhis edilmesi ile daha az zararlı hale getirilebilir ve hastalığın ölümle sonuçlanmasının önüne geçilebilir. Bunun sağlanması da tıbbi görüntüleri kullanarak teşhis koyan uzmanların insani sebeplerden kaynaklanan (yorgunluk, unutma vb.) hatalarının en aza indirgenmesiyle mümkündür. Bu nedenle, yapay zekâ teknolojileri kullanılarak geliştirilen sınıflandırma modelleri ile ilgili çalışmalar önemli olup sayılarının artırılması gerekmektedir.

Kanser hastalığının erken dönem teşhisi için tıbbi görüntülerin sınıflandırılması çalışmalarında karşılaşılan en önemli zorluklardan biri de yeteri kadar tıbbi görüntü verisine sahip olunamamasıdır. Bu durum, geliştirilen modellerin başarı performansına olumsuz etki etmektedir. Örneğin, Covid-19 ile ilgili yapılan çalışmalarda üniversitelerin, kliniklerin ve hastanelerin veri paylaşımı sayesinde, Covid19’un zatürre veya benzer diğer hastalıklar ile karıştırılmadan doğru bir şekilde tespit edilmesi mümkün hale gelmektedir. Benzer bir durumun kanser hastalığının sınıflandırılması için de gerçekleşmesi, bu alanda geliştirilen modellerin daha başarılı olmasına ve yapılan çalışmaların da artmasına katkı sunmaktadır. Öyle ki, bazı tıbbi görüntü veri setleri halka açık platformlarda ücretsiz bir şekilde elde edilebilmektedir.

Tıbbi görüntü sınıflandırması için yeteri kadar veri olmaması ya da mevcut veriler yeterli olsa bile geliştirilen modelin sınıflandırma başarısının artırılması için veri artırma tekniğinin kullanıldığı çalışmalar da (Hussain vd., 2017: 5; Zhang vd., 2017: 4; Zhao vd., 2019: 6; Abdollahi vd., 2020: 4; Hu vd., 2021: 5) mevcuttur. Nitekim, birçok çalışmada (Mikołajczyk ve Grochowski, 2018: 4; Shorten ve Khoshgoftaar, 2019: 3; Garcea vd., 2022: 6) veriler yeterli olsa bile, geliştirilen modelin yeni verilerle test edildiği zaman hata payının en düşük seviyede tutulması için model daha eğitim aşamasında iken veri

artırma tekniği kullanılarak eğitim verileri, kullanılan tekniklerle çoğaltılır. Bu sayede, modelin bir görüntüyü aç, yakınlık seviyesi gibi farklı özelliklerle tanınması sağlanır. Bu durum, görüntünün öz niteliklerinin öğrenilmesi ile ilgilidir ve modelin daha iyi öğrenmesini sağlar. Veri artırma ön işleme tekniği sınıflandırma çalışmalarında sıklıkla kullanılır.

Sınıflandırma çalışmalarında, başarı oranının artırılması için veri artırma gibi tekniklerin yanında farklı yaklaşımlar da ele alınabilir. Sezgisel optimizasyon algoritmaları kullanılarak, kurulacak model için mevcut tüm yöntemlerin başarı açısından en yüksek veya en yükseğe yakın bir sonucun elde edilmesi sağlanabilir.

Birçok çalışma, tıbbi görüntü sınıflandırmasında en iyi sonucu bulmak ve verilerden en yüksek performansı elde etmek için ön işleme tekniklerini (Kirkerød vd., 2019: 2; Raj vd., 2020: 3; Pérez-García vd., 2021: 6; Tariq vd., 2023: 4), literatürdeki farklı modelleri (Ismael vd., 2020: 6-9; Tchito Tchappa vd., 2021; 7) ve onlara ait parametrelerin iyileştirilmesini (Parvathy vd., 2021; 127; Berral vd., 2022: 3; Iqbal vd., 2022: 7), önceden eğitilmiş modellerin kullanılmasını ve ele alınan tüm bileşenler arasında en iyi sonucu elde etmek için sezgisel optimizasyon yöntemlerinin kullanılmasını değerlendirmektedir.

Önceden eğitilmiş farklı ESA modelleri ile tıbbi görüntü sınıflandırması konusuna sahip bu çalışmada, sınıflandırma başarısının artırılması amacıyla ön işlem ihtiyacı, uygun filtrelerin ve modellerin belirlenmesi için sezgisel optimizasyondan yararlanılmıştır. Çalışmanın amacı, yararlanılan tüm bu bileşenler ile sınıflandırma doğruluğunun maksimizasyonunu gerçekleştirmektir.

Bu çalışma, konusu ve amacı itibarıyla geniş bir yelpazeyi bünyesinde barındırmaktadır. Öncelikle, çalışmada kullanılan veri setleri hem Türkiye hem de Dünya'daki en yaygın iki kanser türü olan akciğer ve meme kanseri görüntülerini barındıran koleksiyonları içermektedir. Bunun yanında, göz hastalıklarının sınıflandırılması için geliştirilen bir veri seti de çalışmaya dahil edilmiştir. İki kanser türünün yanında göz hastalıklarının sınıflandırılması ile ilgili bir veri setinin kullanılmasındaki hedef, farklı hastalık türleri için farklı görüntüleme teknikleri ile elde edilen görüntüler üzerinde, önerilen sezgisel optimizasyon temelli modelin başarısını sınamaktır.

Çalışma, geliştirilen yöntem ve elde edilen sonuçları itibari ile genel olarak üç aşamada ilerlemiştir.

Birinci aşamada, meme kanseri, akciğer kanseri ve diyabetik retinopati (DR) göz hastalığının sınıflandırılması için üç adet veri seti belirlenmiştir. Tüm veri setleri, kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE) ön işleme tekniği ile işlendikten sonra Anizotropik Difüzyon (AD), İki Taraflı (İKT), 3D Blok Eşleştirme (BM3D), Gauss, Homomorfik (HM), Ortalama, Toplam Varyasyon (TV) ve Dalgacık filtre olmak üzere sekiz gürültü giderme filtresi uygulanmıştır. Mevcut üç veri seti içerisinde veri sayısı ve görüntü boyutu açısından en kısa sürede çalışması beklenen akciğer veri seti kullanılarak Vgg16, Vgg19, ResNet50, EfficientNetB0, EfficientNetB7 modelleri ve Destek Vektör Makinesi (DVM), Rassal Orman (RO) ve Yapay Sinir Ağları (YSA) sınıflandırıcıları ile ızgara arama (IA) yöntemi kullanılarak en yüksek sınıflandırma doğruluğu sonucunu veren parametre kombinasyonu elde edilmeye çalışılmıştır. Bu işlemten sonra, sezgisel optimizasyon yöntemlerinden olan diferansiyel evrim (DE) ve Parçacık Sürü Optimizasyonu (PSO) algoritmaları kullanılarak IA yöntemi ile elde edilmiş olan en yüksek skorun bulunup bulunamayacağını öğrenilmesi için aynı veri seti bu iki algoritma ile çalıştırılmıştır. Çalışmada sezgisel optimizasyon yöntemi olarak tercih edilen DE algoritmasının sonuçları PSO ile elde edilen sonuçlar ile karşılaştırılmıştır.

İkinci aşamada, mevcut üç veri setine akciğer ve meme kanseri ile ilgili birer veri seti daha eklenmiş ve veri setlerinin toplam sayısı beş olmuştur. Çalışmada kullanılan modelleri Vgg16, Vgg19, ResNet50, EfficientNetB0, DenseNet121 ve MobileNetv2 oluştururken, sınıflandırıcıları ise DVM, RO, K En Yakın Komşu (EYK), XGBoost ve YSA oluşturmuştur. Sınıflandırıcılara ait hiper parametreler de belirlendikten sonra beş veri seti DE algoritması ile çalıştırılmıştır.

Üçüncü ve son aşamada ise beş veri setinin dördüne veri artırma işlemi uygulanarak ikinci aşamadaki modeller ve hiper parametreler değiştirilmeden çalıştırılmış ve orijinal veri sayısı ile artırılmış veriler arasında sonuç karşılaştırması yapılmıştır.

Çalışmada bu ilerleyici ve aşamalı yapının tercih edilmesinin nedeni, çalışmada kullanılan farklı hastalık türlerine ait farklı görüntüleme tekniklerinden elde edilen görüntüler için hastalık sınıflandırmasında yüksek sınıflandırma başarısı gösteren

genelleştirilebilir bir model ortaya koyulup koyulamayacağı sorusuna ait cevabın da aranmasıdır. Çalışmanın genel akışı aşağıda verilmektedir.

Birinci bölümde, çalışmada kullanılan terim ve teknolojilere dair bir kavramsal çerçeve sunulmaktadır. Yapay zekâ, makine öğrenmesi, derin öğrenme teknolojilerinin tanımı ve aralarındaki kapsam ilişkisi, ESA ve YSA temelleri gibi konular bu bölümde ele alınmaktadır.

İkinci bölümde, farklı tıbbi görüntüleri, modeller, optimizasyon yöntemleri kullanılarak yapılmış çalışmalara dair geniş bir literatür bilgisi sunulmaktadır. Kategoriler halinde verilen literatür çalışmalarının kritiği de bu bölümde yapılmaktadır.

Üçüncü bölümde, çalışmada kullanılan veri setleri ve bunlara ait bilgiler, kullanılan derin öğrenme ve sınıflandırma modelleri, ön işleme teknikleri ve çeşitli filtreler açıklanmaktadır.

Dördüncü bölümde, çalışmanın ilerleyişine uygun bir şekilde deneysel sonuçlar paylaşılmaktadır. Elde edilen sonuçlar, tablolar ve grafikler halinde sunulmaktadır. Ayrıca, elde edilen en iyi sonuçlar ile çalışmada kullanılan aynı veri setleri ile yapılmış diğer bilimsel yayınlara ait sonuçlar kıyaslanmaktadır.

Sonuç bölümünde ise, çalışmanın amacı ve elde edilen sonuçlar geniş bir çerçevede ele alınmakta, elde edilen bulguların literatüre olan katkısından bahsedilmektedir.

BİRİNCİ BÖLÜM

TIBBİ GÖRÜNTÜ SINIFLANDIRMASINA

DAİR KAVRAMSAL ÇERÇEVE

1.1. Yapay Zekâ

12. yüzyılda yaşamış Müslüman bilim adamı ve mucit El-Cezeri'nin yaptığı çalışmalar bugünkü yapay zekâ teknolojisinin atası sayılacak sibernetik bilimini inşa etmiştir (Dirik, 2020: 2). El-Cezeri zillere basan insanımsı bir robot geliştirmesi ile bilinen ilk robotik uygulamayı icat etmiştir (Hamet ve Tremblay, 2017: 36). Buna karşın aradan geçen 8 yüzyıl sonrasında yapay zekâ terimi ilk olarak McCarthy tarafından 1955 yılında kullanılmıştır (Becker, 2019: 198). Yapay zekânın bir fikir olarak modern dönemde ortaya çıkışı ise Alan Turing'in "makinelere düşünebilir mi?" isimli çalışması (Turing, 1950: 433) ile ortaya atılmıştır.

Yapay zekâ, insan gibi akıllı bir canlının yerine getirebileceği bilişsel görevlerin bir makine ya da robot gibi mekanizmalar tarafından yapılabilmesi için geliştirilen yöntemler bütünüdür (Angelov vd., 2021: 2). Yapay zekâ, kendisiyle ilişkili olarak günümüzde kullanılan birçok kavramın üstündedir. Bu durum, bir şemsiye olarak düşünülebilir. Yapay zekâ, makine öğrenmesi ve derin öğrenme gibi alt teknolojileri kapsayan geniş bir şemsiyedir.

Her ne kadar yapay zekâ, genellikle birçok alt teknoloji dalını ve farklı disiplinleri bünyesinde barındıran güçlü bir kavram olsa da bazı çalışmalarda (Page vd., 2018: 2; Corea ve Corea, 2019: 26; Spector ve Ma, 2019: 2; Ryan, 2020: 4; Saha vd., 2021; Stray, 2021: 99) birbirinden farklı iki isim olarak ikiye ayrılır. Bunlar, zayıf yapay zekâ ve güçlü yapay zekâ. Zayıf yapay zekâ, tek bir göreve odaklanmış (satranç oynamak, matematik sorusu çözmek vb.) bir yeteneğe sahip iken, güçlü yapay zekâ ise bilişsel anlamda karşılaştığı sorunlara insandan daha iyi çözümler üretecek yapay zekânın tanımıdır (Goertzel, 2007: 6).


İlk ortaya çıkışı, makinelerin de insanlar gibi düşünüp düşünemeyeceğine dair teorik bir tartışma olan yapay zekâ teknolojisi, en başlarda basit kod kuralları ile geliştirilmişti. Daha sonra bu durum uzman sistemlerin ortaya çıkmasını sağlamıştır. Ancak 1990'lı yıllardan bugüne bu teknoloji alanına ait birçok alt dallar meydana

gelmiştir (Chollet, 2021: 4). Bugün yapay zekâ hâlâ sınırları tam olarak keşfedilememiş ve her geçen gün yeni bir özelliği keşfedilen geniş bir alanı kapsamaktadır. Yapay zekâ, robotikten otonom araçlara, bilgisayarlı görüden doğal dil işlemeye, BDTS'den ilaç keşfine varıncaya dek farklı alanları ve konuları bünyesinde barındıran zengin bir kavramdır (Pannu, 2015: 80; Pena vd., 2021: 6).

Yapay zekânın 1950'lerden 1990'lı yıllara kadar gelişimi, genellikle basit sorulara basit cevaplar olarak seyretmiştir. Bu ilerleme, 1990'lı yıllardan sonra ise yapay zekânın görüntü ve nümerik verilerle çalışan ve bu verileri örüntü tanıma, sınıflandırma, yorumlama vb. farklı yeteneklere sahip olan makine öğrenmesi ve derin öğrenme gibi teknolojilerinin ortaya çıkması ile başka bir boyut kazanmıştır.

Şekil 1'de yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki hiyerarşik ilişki gösterilmektedir.

Şekil 1. Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme Arasındaki Hiyerarşik İlişki




Şekil 1'de de görüldüğü gibi, yapay zekâ makine öğrenmesi ve derin öğrenmeyi kapsayan geniş bir teknoloji alanı, makine öğrenmesi de derin öğrenmeyi kapsayan üst bir teknolojidir.

1.2. Makine Öğrenmesi

Makine öğrenmesi, eski verileri deneyimleyerek onlardan bilgi edinmeyi amaçlayan ve yeni verileri de bu tecrübeler ile yorumlayan, yapay zekânın bir alt dalıdır (Michalski vd., 2013: 2). Makine öğrenmesi, farklı öğrenme stratejileri ve bu stratejilere ait algoritmalar ve teknikler barındıran bir teknoloji dalıdır. Şekil 2'de makine öğrenmesine ait hiyerarşik bir gösterim verilmektedir.

Şekil 2. Makine Öğrenmesi Stratejileri Algoritmaları



Şekil 2’de verilen pekiştirmeli öğrenme algoritmalarından GBPO, Güvenli Bölge Politika Optimizasyonu (Trust Region Policy Optimization) algoritmasının kısaltılmış halidir.

Makine öğrenmesi dalının gelişimine zemin hazırlayan teorik arka plan: “Bir bilgisayar algoritması, ona verilen görevin ötesine geçebilir mi?” ya da “Bir bilgisayar, programcının ona verdiği kod yerine, kendi çözümlerini geliştirebilir mi?” gibi sorularla ortaya çıkmıştır (Mitchell ve Jordan, 2015: 256; Holzinger vd., 2019: 2). Makine öğrenmesinin gelişiminde, onu klasik yapay zekâdan ayıran teorik arka planın haricinde, özellikle donanım kaynaklarının da çok büyük bir etkisi olmuştur. Verileri çok hızlı bir şekilde işleyen, bunların arasındaki örüntülerin ortaya çıkarılması için kullanılan ağır matematiksel hesaplama görevlerini eksiksiz bir şekilde yerine getiren donanım kaynakları sayesinde, makine öğrenmesi algoritmaları ile ilgili yapılan çalışmalar büyük bir hız kazanmıştır (Pu vd., 2019: 3).

İlk dönem yapay zekâ çalışmalarının kodlanmasında kullanılan klasik programlama tekniğinde, bilgisayara hem soru hem de cevap verilirdi. Bilgisayarın tek yapması gereken şey, istenilen soruya uygun cevabı bulup getirmek olurdu. Ancak, makine öğrenmesinde durum epey farklıdır. Burada, bilgisayara sorular ve onun cevapları verilir. Makine, kendisine verilen bu soru ve cevapları öğrenir. Makineye, bir başka soru

sorulduğunda, önceden öğrendiği soru ve cevaplara göre kendi cevabını verir (Mueller ve Massaron, 2021: 11-13).

Makine öğrenmesi, kriz anlarında karar verme, verilerin bağlamını çözme gibi hâlâ çözüm arayan sorunlara sahip olmasının yanında günümüzde bilim, mühendislik, işletme, sağlık gibi alanlarda da sıklıkla kullanılan bir teknolojidir. Makine öğrenmesi alanına yapılan yatırımlar sayesinde güçlü matematiksel ve istatistiksel tabanlı algoritmaların geliştirilmesi ve büyük veriler içeren veri setlerindeki hesaplamaların daha az maliyetle yapılması sağlanmaktadır (Cohen, 2021: 4).

Makine öğrenmesini yapay zekâdan farklılaşp onun bir alt dalı olacak hâle gelmesini sağlayan şey, onun öğrenme stratejileridir. Günümüzde makine öğrenmesi alanında denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere genel anlamda üç temel öğrenme stratejisi bulunmaktadır (Kaplan ve Haenlein, 2019: 5).

1.2.1. Denetimli Öğrenme

Denetimli öğrenme, etiketli veriler kullanarak genellikle sınıflandırma ya da regresyon görevlerini yerine getiren ve makine öğrenmesi alanında en sık kullanılan öğrenme stratejisidir (Brei, 2020: 177). Denetimli öğrenmenin en önemli ayırt edici özelliği etiketli veriler kullanmasıdır. Etiketli veri, bir verinin ait olduğu sınıfı veya kategoriyi tanımlar. Yani, makine bu veriyi gördüğü zaman ona bu verinin ne olduğu tanıtılır. Daha sonra eğitim aşaması tamamlandığında makineye bir başka veri gösterilir ve bu verinin sınıfını doğru tahmin etmesi ya da sınıflandırması istenilir.

Denetimli öğrenmede kullanılan girdi verisi basit bir vektör olabileceği gibi bir metin, görüntü ya da zaman serisi (borsa verisi, dolar kuru vb.) de olabilir (Murphy, 2022: 2). Eğer çıktı verisi yani sonuç olarak elde edilmek istenen veri, nominal ya da kategorik bir veri ise yapılması istenen işlem sınıflandırma işlemidir ancak numerik bir reel değer ise o zaman yapılmak istenen işlem regresyon işlemi demektir (Rashidi vd., 2021: 16).

Bu çalışmada, kullanılan modeller ve veri setindeki veriler itibari ile denetimli öğrenme stratejisi kullanılmıştır.

1.2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, verilerin bir etikete sahip olmadan eğitildiği öğrenme türüdür (Pan vd., 2023: 926). Bu öğrenme stratejisi, ham veri setlerinin analizi ve

herhangi bir etikete sahip olmayan verilerin arasındaki ilişkilerin keşfedilmesini sağlar. Denetimli öğrenmede etiketli verilerin eğitilmesinden sonra hangi verinin hangi etikete sahip olduğu öğrenilirken, denetimsiz öğrenmede etiketsiz verilerin kendi özniteliklerine göre hangi gruba dahil olduğu öğrenilir (Mahesh, 2020: 382).

Denetimli öğrenmede sonuç itibari ile sınıflandırma ve regresyon olarak iki farklı kategori olduğu gibi, denetimsiz öğrenmede de kümeleme ve boyut indirgeme gibi iki farklı kategori bulunmaktadır.

Kümeleme, makine tarafından aynı özellikleri taşıdıkları düşünülen verilerin aynı homojen kümelere atanmasıdır. Kümeleme işleminde en önemli adım, farklı nesneler arasındaki mesafenin ölçülmesidir (Homod vd., 2022: 2). Bu sayede nesnelerin uzaklıklarına göre hangi kümeye dahil edileceği belirlenir. Boyut indirgeme, verilerin özniteliklerinin çok fazla olması durumunda sınırların kaybolacağı, daha fazla sınırın meydana gelebileceği tehlikelerinin önüne geçmek için mevcut özelliklerin arasından bir seçim yapma ya da bazı özelliklerin birleştirilerek yeni bir özellik kazandırılması işlevini yerine getirir (Ping vd., 2022: 3).

Özellikle büyük verinin işlenmesinde, öznitelik çıkarımında ve veri etiketlemenin neredeyse imkânsız olduğu alanlardaki ihtiyaçtan dolayı, denetimsiz öğrenme stratejisine göre geliştirilen teknikler ve bu alanlardaki çalışmalarda büyük bir artış görülmektedir (Usama vd., 2019: 65580). Denetimiz öğrenme, aynı zamanda ağ protokollerinin, ağ iletişiminin ve dağıtık karar verme mekanizmalarının geliştirilmesinde de sıklıkla başvurulan bir stratejidir (Zaadnoordijk vd., 2022: 510-511).

1.2.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, denetimli öğrenme ve denetimsiz öğrenmeden farklı bir stratejidir. Bu stratejide önemli olan verilerin etiketli ya da etiketsiz olması değil, öğrenme işlemini gerçekleştiren makinenin, elde ettiği sonuca göre cezalandırılması ya da ödüllendirilmesi konusudur (Sasakawa vd., 2008: 34).

Pekiştirmeli öğrenme, dört temel başlık ile çerçevelenmiştir. Bunlar: Ajan, ortam, ödül ve ceza. Öğrenme işlemini gerçekleştiren makine (ajan), bulunduğu ortam ile istediği sonucu maksimize edebiliyorsa bu en iyi durum olarak değerlendirilir ve bunun sonucunda ödüllendirilir. Eğer aksi bir durum söz konusu ise, ajan cezalandırılır ve bu durumda bulunduğu ortamı terk eder ve daha iyi bir durum aramaya başlar. Pekiştirmeli

öğrenme sömürü ve keşif üzerine kurulu güçlü bir stratejidir (Sutton ve Barto, 2018: 2-4; Matsuo vd., 2022: 270). Günümüzde özellikle otonom araç ve robotik çalışmalarda en sık kullanılan öğrenme stratejisidir (Li vd., 2022; He vd., 2022; Ju vd., 2022; Feng vd., 2023; Elguea-Aguinaco vd., 2023).

1.3. Derin Öğrenme

Makine öğrenmesinin görüntülerdeki nesneleri tespit etmesi, haber ve uygulamaları ilgili kullanıcılarla eşleştirmesi, yazılı bir metnin konuşmaya dönüştürülmesi gibi olağanüstü uygulamaları ortaya çıkarması, derin öğrenme teknolojisinin ortaya çıkmasıyla mümkün olmuştur (LeCun vd., 2015: 436).

Derin öğrenmeyi, makine öğrenmesinden ayıran en önemli husus onun “derinliğidir”. Burada derinlikten kasıt, girdi verilerinden öğrenilen özniteliklerin çok fazla sayıda ara katman ile ardışık bir şekilde öğrenilmesi ve işlenmesidir. Makine öğrenmesinde genellikle bir veya iki ara katman bulunduğu için ardışık temsil (her katmanda öğrenilen özniteliklerin bir sonraki katmana aktarılması) işlemi genellikle söz konusu değil iken, derin öğrenmede ardışık temsil kavramı oldukça önemlidir (Chollet, 2021: 8).

Derin öğrenmenin bu “derinliği” sayesinde yalnızca görüntüdeki temel öznitelikler değil, aynı zamanda çok hassas öznitelikler de öğrenilebilir ve bu sayede görüntü işlemedeki amaç (sınıflandırma, segmentasyon, görüntü tanıma vb.) başarıyla yerine getirilebilir (Buckner, 2019: 3).

1.4. Yapay Sinir Ağları

YSA, insan beyninin çalışma prensibi temel alınarak geliştirilmiş öğrenme ve yeni bilgiler keşfedilme gibi görevleri yerine getiren bilgisayar sistemleridir (Öztemel, 2006: 29).


Geleneksel YSA, çözülmesi gereken problemin ilgili görevlerini yerine getirmek için oluşturulmuş nöronlardan meydana gelmektedir (Celard vd., 2023: 2297). Temel olarak bir YSA modeli, nöronlardan oluşan katmanlardan oluşmaktadır. YSA’daki öğrenme iki farklı işlem ile gerçekleşir. Bunlar, ileri besleme ve geri yayılımdır.

İleri beslemede, girdi katmanından alınan veriler ara katmanlara iletilir her katman arasında ağırlıklar mevcuttur. Bu ağırlıkların değerleri ilk olarak rastgele bir şekilde

oluşturulur. Her katmandaki nöronlardaki girdiler bir sonraki katmana iletilmeden önce bu ağırlık değerleri ile çarpılır ve bir bias değerine eklenir. Elde edilen değere aktivasyon fonksiyonu uygulanır ve bu durum ağıdaki son katmana (çıkı katmanı) iletilinceye kadar devam eder (Reed ve MarksII, 1999: 31-35). Aktivasyon fonksiyonu sadece çıkı katmanında uygulanabileceği gibi ara katmanlarda da uygulanabilir. Bir YSA'nın ne kadar derin olduğu ise kaç tane ara katman kullanıldığı ile ilgilidir (Samatin Njikam, 2016: 77).

Geri yayılımda ise, ileri beslemede elde edilen çıkı ile gerçek çıkı değeri arasındaki fark, kayıp fonksiyonu ile ölçülür. Elde edilen hatayı daha da azaltmak için, ileri beslemenin aksine bu defa son katmandan ilk katmana doğru bir akış gerçekleşir (Reed ve MarksII, 1999: 53-57; Tan vd., 2019: 2-3). Burada ilk katmana gidinceye kadar, hata bütün katmanlara yayılarak ağırlıkların güncellenmesi gerçekleşir. İlk aşamada rastgele bir şekilde verilen ağırlık değerleri artık elde edilen hataya göre güncellenir (Wright vd., 2022: 551-553). Bu işlem, elde edilen hata istenen seviyeye düşürülene kadar devam eder. İleri besleme ve geri yayılım işlemleri sayesinde makine, eldeki verileri öğrenir. Bu işlem, aynı zamanda verilerin eğitilmesidir. Şekil 3'te klasik ve derin YSA model mimarileri birlikte verilmektedir.

Şekil 3. YSA Model Mimarileri a) Klasik, b) Derin



Klasik YSA ile derin YSA arasındaki fark, ara katman sayısıdır.

1.5. Evrişimli Sinir Ağları

ESA'nın ortaya çıkışı YSA'dan bağımsız tutulamaz. YSA'nın basit düzeydeki problemler için geliştirilip farklı sorunlara göre daha ileri bir seviyeye taşınmasıyla beraber, görüntü alanında da YSA tabanlı ESA modeli geliştirilmiştir. Ses tanıma için geliştirilen tek boyutlu ESA (Waibel vd., 1989), ilk defa geliştirilen çok boyutlu ESA (Zhang vd., 1988) ve el yazısı tanımak için geliştirilen ESA (LeCun vd., 1989) modelleri ile artık salt kategorik ve numerik veriler ile değil görüntü verileri ile de çalışabilen modeller geliştirilmiştir. İleri de derin öğrenme teknolojisinin temellerinin atılmasını sağlayacak LeCun ve arkadaşlarının (1989) geliştirdikleri modelle de ilk defa “evrişim” kavramı kullanılmıştır.

ESA'yı YSA'dan ayıran en önemli fark, ESA'nın özellikle görüntülerdeki örüntü tanıma işlemi için geliştirilmiş olmasıdır. Böylelikle her bir görüntü ve o görüntüye özgü öznitelikler için ESA'lar çok daha rahat bir şekilde tekrar düzenlenebilir (O'Shea ve Nash, 2015: 2-3).

Bir sinir ağı modelinin ESA olarak tanımlanabilmesi için iki katmanı bünyesinde barındırması gereklidir. Bunlar evrişim ve havuzlama katmanlarıdır.

Evrişimsel katmanda, bir kayan filtre görüntü üzerinde gezdirilir ve bu aşamada görüntünün özellikleri öğrenilir. Evrişim işleminin sonucunda bir öznitelik haritası elde edilir. İlk evrişimsel katmanlarda genellikle görüntünün basit ve temel öznitelikleri öğrenilir. İlerleyen katmanlarda ise daha spesifik özniteliklerin öğrenilmesine gayret gösterilir. Evrişimsel katmanda tıpkı YSA'daki ileri besleme aşamasında olduğu gibi skaler çarpma işlemleri yapılır (Li vd., 2021: 2-4).


Havuzlama katmanı ise sadece boyut azaltmaya yarar. Bu sayede parametrelerin de sayısı azaltılır. Bu boyut azaltma işleminde genellikle iki farklı yöntem tercih edilir. Eğer, ilgili alandaki sadece en büyük piksel değeri seçilecekse bu işleme maksimum havuzlama, ilgili alandaki piksellerin ortalaması seçilecekse ise ortalama havuzlama olarak adlandırılır (Gu vd., 2018: 357).

ESA'nın son katmanında eğer istenilirse YSA kullanılabilir. Elde edilen görüntü öznitelikleri numerik değerlere dönüştürülür ve bu değerler bir vektör haline getirilir (Basha vd., 2020: 112-113). Daha sonrasında, yapılacak işleme göre nöron sayısı

belirlenir ve çıktı katmanına bağlanır. ESA'da kullanılan bu YSA kısmı tam bağlantılı katman olarak adlandırılmaktadır.

Şekil 4'te klasik bir ESA modeli gösterilmektedir.

Şekil 4. Klasik ESA Mimarisi



Kaynak: Harrison Jr vd. 2021: 1235

1.6. Tıp Alanında Yapay Zekâ Kullanımı

Tıp alanında Yapay Zekâ (TAYZ), son 50 yıl içerisinde gelişim adına büyük bir aşama kaydetmiştir. TAYZ tabanlı uygulamalar ile sadece uzman destek algoritmaları geliştirilmemiş, aynı zamanda kişiselleştirilmiş tıp uygulamaları için de büyük bir fırsat elde edilmiştir. Günümüzde TAYZ uygulamaları sayesinde hastalıkların önceden tespiti, farklı hastalıkların birbirinden ayrılması ve sınıflandırılması, kanserli alanların segmentasyonu, tedavi edici (terapötik) yöntemlerin geliştirilmesi ve önleyici tıp alanının güçlendirilmesi gibi çalışmalar yapılmaktadır (Ruffle vd., 2019).


TAYZ ile, mekanik bir yapıya sahip bilgisayarların tıp alanında entelektüel bir yaklaşım göstererek hem mevcut sağlık hizmetlerinin yapısı hem de hekimlerin rolü radikal bir şekilde dönüştürülmüştür. Bu durumun tıptaki insan istihdamını, emeğini ve geleneksel tıp eğitimini derin bir değişime uğratacağı gibi görüşler uzun yıllar önce konuşulmaya başlanmıştır (Schwartz, 1970: 323). Yani TAYZ kullanımı sadece hastalıkların tespiti ya da hastalara ve doktorlara yardımcı olacak uygulamalar geliştirmenin de ötesinde disiplinler arası bir yaklaşımı da ifade etmektedir.

Bu durum göstermektedir ki geçmişten günümüze TAYZ kullanımının beraberinde getirdiği etik konular (hastalar hakkında karar verme durumunun psikolojik ve sosyolojik çerçevede ne kadar ele alındığı, bu durumların ne derece doğru olduğu, algoritmanın yanılması durumunda ortaya çıkacak hukuki sorumluluğun kim tarafından

üstlenileceği vb.) ve felsefi tartışmalar ve TAYZ uygulamalarının tarihsel gelişimi iç içe olmuştur.

TAYZ, genel olarak yapay zekânın ve onun alt dallarının (makine öğrenmesi, derin öğrenme, bilgisayarlı görü vb.) tıp alanında yoğunlaşmış ve uzmanlaşmış uygulamaları için geliştirilmiş bir kavramdır (Raz vd., 2022: 23). TAYZ uygulamalarının geliştirilmesinde insan faktörünün önemi oldukça büyüktür. Şekil 5'te TAYZ uygulamalarının geliştirilmesinde ilk aşamadan uzun vadeli yineleme boyunca süren yaşam döngüsü gösterilmektedir.

Şekil 5. Klasik Bir TAYZ Uygulamasında Bilginin Kullanımı



Kaynak: Raz vd., 2022: 24

Şekil 5'te verilen, bilginin bir döngü içerisinde kullanımında ilk olarak bilgi tıbbi verilerden keşfedilir. Sonrasında, yapay zekâ teknikleri ile bu bilgi bir model çerçevesi olarak düzenlenir. Elde edilen bu bilgiden sonra yapay zekâ, verilerle sürekli bir etkileşim içerisinde bu bilgilerden öğrenir. Son olarak da bilgi, sunulmak üzere bir temsil haline getirilir (Raz vd., 2022: 24-25).

Sağlık endüstrisi, donanım kaynakları ve bilişim teknolojilerindeki son gelişmeler sayesinde yapay zekâ ve onun alt dallarına ait teknolojiler son yıllarda tıp alanında çok büyük aşama kaydetmiştir (Razzak vd., 2018: 324).

TAYZ uygulamalarında ve özellikle tıbbi görüntülerin işlenmesinde geleneksel yöntem olarak, girdi verileri ile gözlem sonuçları arasındaki ilişkilerin gösterilmesinde istatistiksel yöntemler kullanılmıştır (Raz vd., 2022: 28).

Ancak, tıbbi görüntüler gibi çok katmanlı verilerde bu klasik yöntemler pek de işe yaramamaktadır. Özellikle, derin sinir ağlarının gelişmesi ile ortaya çıkan derin öğrenme teknolojisi ile yapay zekânın tıp alanında farklı branşlarda kullanımı da yaygınlaşmıştır.

Günümüzde TAYZ uygulamaları, birçok klinik veriye sahip olan ve hastalıkların teşhisi için vücudun iç yapısını görüntüleyen radyoloji alanında (Zouch vd., 2022; Ullah vd., 2023; Nadimi vd., 2023), kanser hastalığına odaklanmış ve kanserin teşhisi, tedavisi ve korunması ile ilgilenen onkoloji alanında (Steyaert vd., 2023; Tian vd., 2023; Wang vd., 2023), kalp krizi riskini aza indirmek ve kriz sonrası hastalığa tekrar yakalanmamak için önlemler geliştiren kardiyoloji alanında (Al-Issa vd., 2022; Abdellatif vd., 2022; Malakouti vd., 2023), kolonoskopik görüntülerin işlenerek hastalıkların teşhisi için araştırma yapılan gastroenteroloji alanında (Murugesan vd., 2023; Aliyi vd., 2023; Lewis vd., 2023) görme sorunları ve göz hastalıkları ile ilgilenen oftalmoloji alanında (Lin vd., 2022; Sengar vd., 2023; Jiang vd., 2023) ve daha birçok farklı tıp branşlarında hastalık öncesi erken tanı, doğru teşhis ve uygun tedavi yöntemleri geliştirilmesi için kullanılmaktadır.

Tüm bu araştırmalar, yapay zekâ teknolojisinin ilerlemesiyle ve diğer disiplinlerle bir uyum içerisinde çalışmasıyla mümkün olmuştur.

1.7. Tıbbi Görüntüleme

Tıbbi görüntüleme, hastalıkların tanımlanması için vücudun iç yapısı veya farklı organ ve dokulara ait işlevlerin görsel tasvirinin oluşmasını sağlayan yöntemler bütünüdür. Tıbbi görüntüleme, farklı teknikler ile elde edilen tıbbi görüntülerin, hastalara ait istatistiki bilgilerin ve hasta izleme durumunda kaydedilen bilgilerin tutulması için büyük veri tabanları kullanımını da sağlamaktadır (Ranschaert vd., 2019: 20).

Hastalıkların tanımlanması, uygun ve doğru tedavi yöntemlerinin keşfedilmesi, hastanın izlenmesi gibi durumlarda tıbbi görüntülerin önemi oldukça büyüktür. Kullanılan farklı enerji durumlarına göre farklı tıbbi görüntüleme teknikleri mevcuttur. Tıbbi görüntüler ile ilgili çalışmalarda tıbbi görüntülerin türüne göre farklı modeller geliştirilmesi bilinen bir durumdur. Yakınsama derecesi, ekstra ön işleme duyma

gereksinimi, görüntüye özel filtrelerin kullanılması gibi durumlar tıbbi görüntülerin türüne göre değişebilmektedir.

1.8. Tıbbi Görüntü Çeşitleri

1.8.1. Bilgisayarlı Tomografi Görüntüleri

BT, vücudun iç yapısının X-ışınları kullanılarak görüntülenmesidir. Hastanın sabit olarak dairesel bir ortamda bulunduğu esnada sabit veya hareketli cihazların X-ışınları sayesinde kemik, doku ve damarların ayrıntılı kesitlerle görüntülenmesi için kullanılır (Ginat ve Gupta, 2014: 432). Özellikle akciğer nodüllerinin tespit edilmesinde BT görüntüleme tekniği kullanılır. Bu görüntüleme tekniğinden elde edilen tıbbi görüntüler ise BT görüntüleri olarak adlandırılır. BT görüntüleri, dünyadaki en yaygın kanser türlerinin başında gelen akciğer kanserinin ve iyi huylu-kötü huylu tümörlerin tespiti ve sınıflandırılmasında sıklıkla kullanılır (Shakeel vd., 2022: 2).

Covid19 pandemisinde yapılan çalışmalar sayesinde akciğerlerin hasar alıp almadığı ile ilgili çalışmalarda, BT görüntüleme tekniği ve bu teknikten elde edilen görüntülerden sıkça yararlanılmıştır (Shyni ve Chitra, 2022: 1-2).

1.8.2. Histopatolojik Görüntü

Hastalıklar hakkında bilgi sağlayan patoloji bilimi, bir hastalık tanısı koyarken slayt (lam) camı üzerindeki bir lekeyi mikroskop kullanarak inceler (Komura ve Ishikawa, 2018: 34). Patolojik görüntülerin tam ve yüksek çözünürlüklü bir şekilde elde edilmesi ve kaydedilmesi için “whole slide image – WIS” olarak adlandırılan girişimlerde bulunulmuştur (Pantanowitz, 2010: 1). Elde edilen bu çok sayıdaki WIS görüntülerinin incelenmesi ve bilimsel bir şekilde tasnif edilmesi patologlar tarafından gerçekleştirildiği için buna yardımcı olacak yapay zekâ tabanlı modeller geliştirilmiştir.

Geçmişten bugüne tümör ve bulaşıcı hastalıklara dair birçok ciddi keşif ve inceleme, araştırmacı patologlar tarafından yapılmıştır. Tümörlerin derecelendirilmesi, meme ve prostat kanserlerinde hastalığın seyrine dair tahminlerde bulunulması gibi kanserlerin morfolojik özelliklerinin değerlendirilmesinde patolojik görüntülerin önemi oldukça büyüktür (Komura ve Ishikawa, 2018: 35). Ayrıca, kadınlarda en sık görülen meme kanseri ile ilgili çalışmalarda da histopatolojik görüntüler kullanılmaktadır (Aswathy ve Jagannath, 2017: 74).

1.8.3. Tıpta Dijital Görüntüleme ve İletişim Görüntüsü

Tıpta Dijital Görüntüleme ve İletişim (DICOM), tıbbi görüntüleme alanında bilgi işleme, depolama, yazdırma ve iletme standardıdır. DICOM sadece bir görüntü çeşidi ve dosya formatından ibaret olmayıp aynı zamanda bir ağ iletişim protokolünden de meydana gelmektedir. DICOM yapısında yer alan bu iletişim protokolü, sistemler arasında bir iletişim kurmak için TCP/IP kullanan bir uygulama protokolüdür (Varma, 2012: 5; Dicom library, 2023).

DICOM formatının getirdiği yenilik, görüntü verilerinin görüntüyü meydana getiren prosedürden bağımsız olarak ele alınamayacağını tespit etmesidir. Yani, üst bilgilerden ayrı ve bağımsız bir şekilde değerlendirilen bir görüntü verisi anlamlı değildir. DICOM, görüntü verilerini ve üst bilgileri “.dcm” uzantılı bir DICOM dosyasında birleştirir. DICOM başlığı dosya yapısı içerisinde görüntü verilerini, bu verilerin elde edilmesini sağlayan edinme protokolünü, tarama parametrelerini ve görüntünün elde edilmesindeki tüm sürece dair prosedür bilgisini eksiksiz bir biçimde içermektedir. Ayrıca, DICOM başlığı hastaya ait yaş, isim, cinsiyet, boy, kilo gibi bilgileri de içermektedir. Bu nedenle DICOM başlığının sabit bir boyutu yoktur. Çünkü koşullara bağlı olarak değişkenlik gösterebilmektedir (Larobina ve Murino, 2014: 204; Tsalaftas ve Metallidis, 2011: 238-240).

DICOM, piksel verilerini tam sayı türünde depolamaktadır. Her ne kadar üst bilgileri ondalık veri türünde depolama yeteneği olsa da piksel verilerinde ondalık veriyi kullanamamaktadır. DICOM formatı, DICOM formatlı olmayan bir belgenin DICOM dosyasında kullanılmasına izin veren bir mekanizma sayesinde sıkıştırılmış görüntü verilerini de desteklemektedir (Larobina ve Murino, 2014: 204). DICOM aslında bir formattan öte bir standarttır. Çünkü bir format ve iletişim protokolünden meydana gelmektedir. DICOM standardı geniş çaplı olarak 23 bölümden meydana gelmektedir (Musta vd., 2008: 40).

1.8.4. Nöro Görüntüleme Bilişim Teknolojisi Girişimi Görüntüsü

Nöro Görüntüleme Bilişim Teknolojisi Girişimi (NIFTI) formatı, bir başka tıbbi görüntü formatı olan Analyze formatının eksikliklerini tamamlamak amacıyla 2000’li yılların başında Ulusal Sağlık Enstitüsü bünyesinden kurulan bir ekip tarafından nöro görüntüleme için oluşturulmuş bir formattır (Nimh, 2020). NIFTI, Analyze formatının

gözden geçirilmiş bir versiyonu olarak düşünülebilir. Şöyle ki, beynin çalışması esnasında sol-sağ belirsizliğinin görüntüye yansımaları engellemek için Analyze 7.5 dosyasının başlığındaki kısımda az kullanılan ya da hiç kullanılmamış alanlar NIFTI tarafından doldurulur. NIFTI, veri türü bilgisi olarak Analyze formatının kullanamadığı 16-bit işaretli veri türünü de desteklemektedir. NIFTI, her ne kadar üst bilgilerin ve görüntü verilerinin ayrı iki dosyada tutulmasına izin verse de bu iki (.hdr ve .img uzantılı) dosyayı “.nii” uzantılı tek bir dosya içerisinde depolar. Bu iki dosya boyutu 348 Bayt olup NIFTI, bu boyutun 16’nın bir katı olmasını sağlamak ve gerektiğinde ek üst bilgileri tutmak için mevcut boyuta 4 Bayt daha ekleyip 352 Baytlık bir (.nii uzantılı) dosya oluşturmaktadır (Li vd., 2016: 48-49, Whitcher vd., 2011: 2-5).

NIFTI formatı, nöro görüntüleme alanında çok popüler yazılımlar tarafından (FSL (Jenkinson vd., 2012), AFNI (Cox, 2012), SPM (Ashburner, 2012)) Analyze formatının yerini almıştır. Daha büyük bir veri kümesinin yönetimini sağlamak için NIFTI’nin yeni sürümü NIFTI-2 2011 yılında tanıtılmıştır (Nimh, 2020). NIFTI-2 ile görüntü matrisinin boyutları 16 bit yerine 64 bit tamsayı ile kodlanmış ve NIFTI’nin ilk sürümünde 32.767 boyut sınırına sahip olma kısıtlaması ortadan kaldırılmıştır (Larobina ve Murino, 2014: 203). NIFTI-2 NIFTI-1’in iyi olan birçok özelliğini korumakla birlikte başlık dosyası 544 Bayt olarak gelmektedir (Braider, 2023).

DICOM ve NIFTI, yapıları itibarıyla diğer görüntü türlerinden farklıdır. Çünkü bu iki görüntü türü aynı zamanda tıbbi görüntülemede kullanılan bir görüntü formatıdır. DICOM ve NIFTI görüntü formatlarına sahip tıbbi görüntüler, birbirleri arasında da dönüştürülebilir ve işlenecek bir görüntü haline getirilebilir. Özellikle beyin ve akciğer görüntüleri yüksek çözünürlüklü bir şekilde elde edilirken DICOM ve NIFTI görüntü formatlarına sahip bir şekilde dijital olarak kaydedilebilirler.

1.8.5. Optik Koherens Tomografi Görüntüleri

Optik Koherens Tomografi (OKT), analiz edilen nesneden alınan sinyal ve yerel bir referanstan elde edilen sinyalin aralarındaki girişim baz alınarak geliştirilmiş olan bir optik görüntüleme teknolojisidir. Optik görüntülemede mikroskop ile görüntülemenin eksikliği sayılabilecek gerçek zamanlı 2B yüksek çözünürlüklü görüntü elde edilmesini sağlar (Podoleanu, 2012).

Görme duyusu ve onun sinir cerrahisi ile ilgilenen bilim dalı olan oftalmolojide, görmeye dayalı hastalıklar OKT görüntüleme tekniği ile teşhis edilmektedir. OKT, klinik ortamında göz retinasını yüksek çözünürlüklü görüntülemek için gerekli olan lazerin fiyatının pahalı olmasından dolayı benzer görevi yerine getirebilecek diyet lazerlerin kullanılmasını öneren Huang ve arkadaşları tarafından 1991 yılında geliştirilmiş bir görüntüleme teknolojisidir (Mumcuoğlu vd., 2008: 169). Günümüzde göz hastalıklarının tespit edilmesinde ve göz dokuları ile katmanlarının incelenmesinde en yaygın kullanılan görüntüleme tekniği OKT'dir. OKT görüntülemede herhangi bir kesme ya da delinme işlemi olmaz. Göz retinasının katmanlarının görüntülenmesinde ve gözdeki tabakaların retina içi morfolojisi hakkında bilgi edinilmesinde büyük ölçüde OKT görüntüleme teknolojisinden faydalanılmaktadır (Alqudah, 2020: 41).

İKİNCİ BÖLÜM

LİTERATÜRDEKİ İLGİLİ ÇALIŞMALAR

Tıbbi görüntülerin sınıflandırılması veya işlenmesi ile ilgili çok geniş bir literatür mevcuttur. Bu çalışmanın genel akışı içerisinde, tıbbi görüntülerin sınıflandırılması ile ilgili çalışmalar ele alınırken önceden eğitilmiş modeller, kullanılan farklı tıbbi görüntüler ve sezgisel optimizasyon yöntemlerinin kullanıldığı çalışmaların özellikle üzerinde durulmuştur. Aşağıda verilmekte olan literatürdeki çalışmalarda da aynı sıra izlenme ve özellikle son literatüre dikkat çekilmektedir.

Fang (2018), BT akciğer görüntülerini kullanarak yaptığı akciğer kanseri sınıflandırma çalışmasında ince ayarlı GoogLeNet modeli ile 0,81 doğruluk, 0,84 hassaslık ve 0,78 özgüllük sonucunu elde etmiştir. Da Nóbrega vd. (2018), LIDC/IDRI veri setindeki BT akciğer görüntüleri ile akciğer nodülü sınıflandırması yapmışlardır. Öznitelik çıkarıcısı olarak ESA, Vgg16, Vgg19, MobileNet, ResNet50 gibi birçok modelin kullanıldığı çalışmada, ESA-ResNet50 modeli ve DVM sınıflandırıcısı kombinasyonu sayesinde 0,8841 doğruluk skoru ve 0,9319 AUC skoru sonucu elde etmişlerdir. Wang vd. (2019), BT akciğer görüntüleri ile kanser sınıflandırması yaptıkları çalışmada ince ayarlı Inceptionv3 ve derin ESA modellerini kullanmışlardır. Inceptionv3 modeli 0,8510 doğruluk, 0,7778 özgüllük ve 0,9541 duyarlılık skoru sonuçları ile derin ESA modeline göre daha başarılı bulunmuştur. Pham (2020), 141 akciğer kanseri hastasından elde edilen 271 adet BT görüntüsünü kullanarak, iyi huylu ve metastatik dokuların sınıflandırması için önceden eğitilmiş ResNet101 derin öğrenme modeli sayesinde %90 doğruluk, %84 hassaslık ve %96 özgüllük metrikleri sonuçlarını elde etmiştir. Mohammed ve Çinar (2021), erken evrede akciğer kanserinin teşhisi için akciğer nodülleri görüntülerini kullanarak yaptıkları çalışmada birden fazla önceden eğitilmiş model kullanmıştır. Sınıflandırma başarısı olarak %94,1 doğruluk, %94,1 hassaslık, %94,1 özgüllük ve %94,1 F1 skoru sonucunu elde etmişlerdir. İbrahim vd. (2021), akciğer kanserini Covid-19 ve zatürre hastalıklarından ayırabilmek için göğüs röntgeni ve BT görüntülerini kullandıkları çalışmada, 4 farklı derin öğrenme yöntemi kullanmıştır. Vgg19 modeline ait %98,05 doğruluk, %98,24 F1 skoru, %98,43 kesinlik metriği sonuçları ile en iyi sınıflandırma sonucuna ulaşılmıştır. Chaunzwa vd. (2021), BT görüntülerini kullanarak küçük hücreli akciğer kanseri sınıflandırmasına dair Vgg16

modelini kullandıkları çalışmada, %68,6 doğruluk, %82,9 özgüllük, %37,5 hassaslık ve 0,709 Eğrinin Altındaki Alan (AUC) metrik sonuçlarını elde etmişlerdir. Shandilya ve Nayak (2022), akciğer kanserinin sınıflandırılması için 3 farklı doku örneğine ait 15.000 görüntü kullandıkları çalışmada, 7 adet önceden eğitilmiş derin öğrenme modeli arasında kıyaslama yapmıştır. ResNet101 modeli ile %98,67 doğruluk değerini elde ederek en iyi sınıflandırma sonucuna ulaşmışlardır. Harsono vd. (2022), ResNet mimarisini kullanarak geliştirdikleri 3B ESA modeli ile BT akciğer görüntülerini kullanarak akciğer kanseri sınıflandırması yapmışlardır. Çalışmada, 0,8090 AUC ve 0,9198 duyarlılık skoru sonucunu elde etmişlerdir. Malik ve Anees (2022), akciğer kanseri, Covid19 ve zatürre hastalıklarının sınıflandırılması için Vgg16, Vgg19, ResNet50 ve Inception-v3 modellerini kullandıkları çalışmada, çoklu sınıflandırma için %97,35 doğruluk skoru ile Vgg16 modelinin sınıflandırmada en iyi başarıyı ortaya koyduğunu belirtmişlerdir. Humayun vd. (2022), “IQ-OTH/NCCD” veri setindeki BT akciğer görüntülerini kullanarak akciğer kanseri sınıflandırması yapmışlardır. Vgg16, Vgg19 ve Xception modellerini kullandıkları çalışmada en iyi sınıflandırma doğruluğunu 0,9883 skoru ile Vgg16 modeli ile elde etmişlerdir. Salama vd. (2022), göğüs röntgen görüntüleri ile iyi huylu-kötü huylu akciğer kanseri sınıflandırması için ResNet50 modeli kullandıkları çalışmada, %98,91 doğruluk, %98,95 AUC, %97,72 kesinlik ve %97,89 F1 skoru sonucunu elde etmişlerdir. Raza vd. (2023), EfficientNet modeli ile halka açık “IQ-OTH/NCCD” veri setindeki BT akciğer görüntülerini iyi huylu-kötü huylu kanser sınıflandırması için kullanmışlardır. Sınıflandırma sonucu olarak %99,10 doğruluk ve 0,97 AUC skorunu elde etmişlerdir. Atiya vd. (2023), akciğer kanseri sınıflandırması için Vgg16, Inception-v3 ve ResNet50 modellerini kullandıkları çalışmada, ResNet50 modeli ile %94 doğruluk skoru elde etmişlerdir. Saravanan vd. (2023), iyi huylu-kötü huylu akciğer kanseri sınıflandırması için Vgg16 modelini kullandıkları çalışmada, %86,06 kesinlik, %97,14 hassaslık, %81,92 özgüllük ve %91,27 F1 skor sonucuna ulaşmışlardır. Bishnoi ve Goel (2023), LIDC/IDRI veri setindeki 19,419 adet BT akciğer görüntüsü ile akciğer kanseri sınıflandırması yaptıkları çalışmada ağırlıklandırılmış derin Vgg modeli olarak adlandırdıkları bir yöntem geliştirmişlerdir. Çalışmada, 0,932 doğruluk, 0,85 Cohen Kappa, 0,93 kesinlik, 0,93 duyarlılık ve 0,93 F1 skoru sonuçlarını elde etmişlerdir.

Chennamsetty vd. (2018), histopatolojik görüntüler ile üç farklı meme kanseri türünü sınıflandırdıkları çalışmada önceden eğitilmiş dört farklı derin öğrenme modeli

kullanmışlardır. Sınıflandırma doğruluğunu %83 ile DenseNet161 modeli elde etmiştir. Ferreira vd. (2018), meme kanseri sınıflandırması için “ICIAR 2018” veri setini kullandıkları çalışmada, Inception Resnet-v2 modeli ile 0,76 doğruluk skoru elde etmişlerdir. Nawaz vd. (2018), meme kanseri sınıflandırması için histopatolojik görüntülere “Stain Normalizasyonu” uyguladıkları ve AlexNet modeli kullandıkları çalışmada %81,25 sınıflandırma doğruluğu elde etmişlerdir. Vesal vd. (2018), BACH 2018 veri setindeki histopatolojik görüntüler ile meme kanseri sınıflandırması yaptıkları çalışmada ResNet50 ve Inceptionv3 modellerini kullanarak en yüksek sınıflandırma doğruluğu sonucunu elde etmeye çalışmışlardır. Inceptionv3 modeli 0,9708 doğruluk sonucu ile en iyi sonucu vermiştir. Khan vd. (2019), topluluk öğrenme yöntemi ile GoogLeNet, VggNet ve ResNet modellerini kullanarak ultrason görüntüleri ile meme kanseri sınıflandırması yapmışlardır. Doğruluk skoru olarak GoogLeNet 0,93, VggNet 0,96 ve ResNet 0,96 sonuçlarını elde ederken, topluluk öğrenme yöntemi ile bu oran 0,9752’ye yükselmiştir. Yang vd. (2019), BACH veri setindeki histopatolojik görüntüler ile meme kanseri sınıflandırması yaptıkları çalışmada, ResNet101, ResNet152 ve DenseNet161 modellerini kullanmışlardır. 100 test görüntüsü kullanılan çalışmada %90 sınıflandırma doğruluğu sonucuna ulaşmışlardır. Hameed vd. (2020), Vgg16 modeli ile meme kanseri sınıflandırması yaptıkları çalışmada %95,29 doğruluk ve %95,29 F1 skoru sonucu elde etmişlerdir. Seemendra vd. (2020), Vgg19, MobileNet ve DenseNet modellerini kullanarak meme kanseri sınıflandırması yaptıkları çalışmada, ince ayarlama tekniği ile doğruluk skorunu artırmayı denemişlerdir. Çalışmada, Vgg19 modeli ile 0,9305 hassaslık ve 0,9446 kesinlik skoru elde edilirken, DenseNet modeli ile 0,8679 doğruluk skoru sonucu elde edilmiştir. Gour vd. (2020), histopatolojik görüntüler ile meme sınıflandırması için yedi farklı derin öğrenme modeli kullandıkları çalışmada, tüm bu modelleri birleştirerek “ResHist” adı verilen bir yaklaşım önermiştir. Geliştirilen bu model ile %84,34 doğruluk ve %90,49 F1 skor sonucunu elde etmişlerdir. Sharma ve Mehra (2020), öznetelik çıkarıcısı olarak Vgg16 modeli ve sınıflandırıcısı olarak DVM kullandıkları çalışmada, %92,23 doğruluk skoru elde etmişlerdir. Saxena vd. (2020), önceden eğitilmiş derin öğrenme modelleri ve DVM sınıflandırıcısı kullandıkları çalışmada AlexNet modeli ile %91,44 ortalama doğruluk sonucuna ulaşmışlardır. Albashish vd. (2021), Vgg16 modeli ile meme kanseri sınıflandırması yaptıkları çalışmada, %89,83 sınıflandırma doğruluğu elde etmişlerdir. Boumaraf vd. (2021),

ResNet18 modeli ile meme kanseri sınıflandırması yaptıkları çalışmada, %92,03 doğruluk, %91,39 kesinlik, %90,28 hassaslık skoru elde etmişlerdir. Sharma ve Kumar (2022), Xception modeli ile histopatolojik görüntülerin iyi huylu-kötü huylu kanser sınıflandırmasında %95,37 sınıflandırma doğruluğu skoruna ulaşmışlardır. Sharma vd. (2022), histopatolojik görüntüler ile meme kanseri sınıflandırması yaptıkları çalışmada klasik ESA modeli kullanarak 0,918 doğruluk, 0,86 kesinlik, 0,92 duyarlılık ve 0,884 AUC skoru sonucu elde etmişlerdir. Aljuaid vd. (2022), histopatolojik görüntüler ile meme kanseri sınıflandırması için ResNet, Inceptionv3 ve ShuffleNet modellerini kullanmışlardır. ResNet modeli 0,9781 doğruluk, 0,9765 kesinlik, 0,9765 hassaslık ve 0,9731 özgüllük skorları ile en iyi sonuçları elde etmiştir. Srikantamurthy vd. (2023), histopatolojik görüntülerle meme kanseri sınıflandırması için ESA-LSTM tabanlı model kullanarak gerçekleştirdikleri çalışmada %92,51 doğruluk, %92 kesinlik ve %93 duyarlılık skoru sonuçlarını elde etmişlerdir. Taheri ve Golrizkhatami (2023), farklı yakınsama düzeyindeki histopatolojik görüntüler ile meme kanseri sınıflandırması için DenseNet201 modelini kullanmışlardır. Sonuç olarak %91,73 ortalama doğruluk sonucunu elde etmişlerdir. Mahmud vd. (2023), ResNet50, ResNet101, Vgg16 ve Vgg19 modellerini kullanarak histopatolojik görüntülerle meme kanseri sınıflandırması yapmışlardır. Kullanılan modeller arasında en iyi sonucu, %90,2 doğruluk ve %90 AUC skoru ile ResNet50 modeli elde etmiştir.

Yang vd. (2018), retinal göz hastalıkları sınıflandırması için YSA ve DVM kullandıkları çalışmada, %89,73 sınıflandırma doğruluğu elde etmişlerdir. Chan vd. (2018), OKT görüntüleme tekniği ile elde edilen görüntüleri kullanarak DVM modeli ile işledikleri görüntülerde %93,75 doğruluk sonucuna ulaşmışlardır. Gupta vd. (2019), IDRID veri setindeki OKT görüntüleri ile DR göz hastalığı sınıflandırması yaptıkları çalışmada öznelik çıkarıcısı olarak Vgg19 modelini ve DVM, K-EYK, Lojistik Regresyon (LR) sınıflandırıcılarını kullanmışlardır. Sınıflandırma başarısı açısından LR sınıflandırıcısının daha başarılı bulunduğu çalışmada 0,809 duyarlılık, 0,82 F1 skor, 0,8428 kesinlik, 0,9345 doğruluk ve 0,959 AUC skoru sonuçları elde edilmiştir. Bhowmik vd. (2019), OKT görüntüleri ile koroid neovaskülrasyon (KNV), diyabetik makula ödemi (DMÖ) ve drusen gibi göz hastalıkları sınıflandırması için Vgg16 modeli kullanarak %94 sınıflandırma doğruluğu elde etmişlerdir. Thota ve Reddy (2020), EYEPACS veri setindeki görüntüleri kullanarak DR göz hastalığı sınıflandırması için Vgg16 modelini

kullanmışlardır. Sınıflandırma sonucu olarak 0,74 doğruluk, 0,80 duyarlılık, 0,65 özgüllük ve 0,80 AUC skoru sonucunu elde etmişlerdir. Sarki vd. (2020), retinal göz hastalıkları sınıflandırması için Vgg16 modeli kullandıkları çalışmada %88,3 sınıflandırma doğruluğu sonucu elde etmişlerdir. Berrimi ve Moussaoui (2020), KNV, DMÖ ve drusen gibi başlıca retinal hastalıkların bulunduğu OKT görüntüleri ile sınıflandırma yaptıkları çalışmada Vgg16 ve modifiye edilmiş Vgg16 modellerini kullanmışlardır. Klasik Vgg16 ve modifiye edilmiş Vgg16 modelleri için sırasıyla %53, %93,5 sınıflandırma doğruluğu başarıları elde etmişlerdir. Martinez-Murcia vd. (2021), Messidor veri setindeki görüntüleri kullanarak DR göz hastalığı sınıflandırması yaptıkları çalışmada Vgg16, Vgg19, AlexNet ve ResNet50 modellerini kullanmışlardır. Sınıflandırma başarıları için AUC skorunu baz aldıkları çalışmada 0.93 AUC skoru ile en iyi sonucu ResNet50 modeli elde etmiştir. Sugeno vd. (2021), DIARETDB1 veri setindeki görüntüleri kullanarak DR göz hastalığı sınıflandırması yapmışlardır. ResNet50, Vgg16 ve EfficientNetB3 modellerinin kullanıldığı çalışmada 0,846 doğruluk, 0,994 duyarlılık ve 0,990 özgüllük skoru ile en iyi sonuç ResNet50 modeli ile elde edilmiştir. Gangwar ve Ravi (2021), Messidor-1 ve APTOS veri setlerindeki görüntüleri kullanarak DR göz hastalığı sınıflandırması yapmışlardır. Inception-ResNetv2 hibrid modeli kullandıkları çalışmada doğruluk skoru olarak Messidor-1 veri seti için 0,7223 ve APTOS veri seti için 0,8218 sonucunu elde etmişlerdir. Luo vd. (2021), retinal göz hastalıkları sınıflandırması için EfficientNetB3 modeli kullandıkları çalışmada, glokom hastalığının sınıflandırması için %84,73 doğruluk, %88,05 duyarlılık, %75,6 kesinlik, 0,5698 kappa ve 0,8119 AUC skoru sonuçlarını elde etmişlerdir. Attota vd. (2022), DR göz hastalığı sınıflandırması için EYEPACS veri setindeki görüntüleri kullandıkları çalışmada Inceptionv3, ResNet50v2 ve EfficientNetB7 modelleri ile topluluk öğrenmesi yöntemine dayalı bir model önermişlerdir. Sınıflandırma doğruluğu olarak EfficientNetB7, ResNet50v2 ve Inceptionv3 modellerinin sırasıyla 0,7378, 0,7989 ve 0,8133 sonuçlarını elde etmesine karşın, önerilen bu yöntem ile 0,9413 doğruluk skoru elde edilmiştir. Ou vd. (2022), ResNet50 modeli kullanarak retinal göz hastalıkları sınıflandırması için geliştirdikleri yöntem ile 0,892 F1 skor, 0,535 kappa ve 0,912 AUC skoru sonuçlarını elde etmişlerdir. Cui vd. (2023), ResNet50, DenseNet121, Vgg19 ve EfficientNetB0 modelleri ile retinal göz hastalıkları sınıflandırması yaptıkları çalışmada, ResNet50 modelinin sağladığı %92,91 sınıflandırma doğruluğu sonucunu elde

etmişlerdir. Jiواني vd. (2023), DR göz hastalığının sınıflandırması için IDRİD veri setindeki görüntüleri kullandıkları çalışmada, Vgg16 ve Inceptionv3 modelleri arasında bir kıyaslama yapmışlardır. Vgg16 modelinin 0,776 ve Inceptionv3 modelinin 0,757 doğruluk skoru elde ettiği çalışmada Vgg16 modeli daha başarılı bulunmuştur. Kasım (2023), DR göz hastalığının sınıflandırması için DDR ve APTOS veri setlerini kullandığı çalışmada MobileNet modeli ile DDR veri seti için 0,906 ve APTOS veri seti için 0.8935 doğruluk skoru sonucunu elde etmiştir. Hassan vd. (2023), OKT görüntüleri ile retinal göz hastalıkları sınıflandırması çalışmasında ResNet50 modeli ile doğruluk, F1 skor, kesinlik, duyarlılık metrikleri için sırasıyla 0,9747, 0,9788, 0,9615 ve 0,9836 sonuçlarını elde etmişlerdir.

Önceden eğitilmiş modeller kullanılarak kanser, hastalık sınıflandırması yapılan çalışmalarda genellikle birden fazla derin öğrenme modeli kullanılarak kıyaslama yapıldığı görülmektedir. Bu tarz çalışmalarda, çalışmanın genel akışı modeller üzerinden yürütüldüğü için ön işleme teknikleri, veri artırma, filtre kullanılması gibi sınıflandırma başarısının artırılmasını hedefleyen bileşenler göz ardı edilmektedir. Ayrıca, çalışmada kullanılan model veya modellerin aynı hastalık türüne ait farklı veri setleri üzerinde bir sınaması yapılmadığı gözlenmektedir. Her ne kadar ele alınan sorun, olabildiğince spesifik bir alana çekilerek sınıflandırma başarısının üzerinde durulmuş olsa da geliştirilen yöntemlerin genelleştirilebilir olmaması ciddi bir dezavantaj olarak kabul edilebilir. Önceden eğitilmiş modellerin “transfer öğrenme” tekniği ile kullanılırken, ince ayarlanmış modellerin daha başarılı sonuçlar verdiği görülmüştür. İnce ayarlama sayesinde modelin öznelilik çıkarma yeteneği korunurken, mevcut veri seti üzerindeki görevi için yeni bir öğrenme sağlanmış olur. Bu durum, zaman maliyeti açısından da önemlidir. Transfer öğrenme yöntemi ile önceden eğitilmiş modellerin kullanılmasında öznelilik çıkarma işlemi kadar sınıflandırma işlemi yani özneliliklerin birer vektör haline getirilip YSA modeline bağlanması da önemli bir yer tutmaktadır. Bu nedenle, sadece eğitilmiş modeller ile hem öznelilik çıkarma hem de sınıflandırma işlemi yapan çalışmaların, başarılı sonuçlar üretmediği görülmektedir. Öte yandan, öznelilik çıkarıcısı olarak güçlü derin öğrenme modellerinin ve sınıflandırıcı olarak da DVM, RO, LR, K-EYK gibi sınıflandırıcıların tercih edildiği çalışmalarda elde edilen sonuçlar, YSA sınıflandırıcısının kullanıldığı çalışmalara göre daha başarılı sonuçlar elde etmiştir. Bu durum, bu çalışmada tercih edilen model-sınıflandırıcı yaklaşımının doğruluğunu da ispat

eder niteliktedir. Bunun yanı sıra, bilinen sınıflandırıcıların aksine, birden fazla derin öğrenme modelinin bir araya getirilerek oluşturulan “topluluk öğrenimi” yönteminde elde edilen sonuçların, bu modellerin her birinin tek başına kullanılmasıyla elde edilen sonuçlardan daha başarılı olduğu gözlenmiştir. Neticede, popüler ve güçlü derin öğrenme modellerinin hem öznitelik çıkarıcısı olarak hem de YSA sınıflandırıcısı olarak kullanıldığı çalışmalarda elde edilen sonuçlar yetersiz bulunmuştur.

Montazeri vd. (2015), sezgisel optimizasyon yöntemlerinden olan genetik algoritma (GA) kullanarak akciğer kanseri sınıflandırması için öznitelik seçimi yaparak gerçekleştirdikleri çalışmada %80,63 sınıflandırma doğruluğu başarıları elde etmişlerdir. Aziz vd. (2018), akciğer kanseri sınıflandırması için YSA ile birlikte bağımsız bileşenler analizi (BBA) ve yapay arı kolonisi (YAK) algoritması kullandıkları çalışmada, %94,78 sınıflandırma doğruluğu sonucuna ulaşmışlardır. Prabukumar vd. (2019), ELCAP veri setindeki BT akciğer görüntülerini kullanarak akciğer kanseri sınıflandırması yapmışlardır. Guguk Kuşu Arama Optimizasyonu ile 26 öznitelik seçimi yaptıkları çalışmada DVM sınıflandırıcısı ile %96,51 doğruluk, %97,23 hassaslık, %97,79 özgüllük skoru sonucuna ulaşmışlardır. Ke vd. (2019), X-ray görüntüleri ile akciğer hastalıklarının tespit edilmesi için YSA ve Ant-lion (Mirjalili, 2015a) Moth-Flame (Mirjalili, 2015b) sezgisel algoritmaları kullandıkları çalışmada ortalama olarak %79,06 doğruluk, %84,22 duyarlılık, %66,7 özgüllük ve %85,94 kesinlik sonuçlarını elde etmişlerdir. Park ve Monahan (2019), göğüs X-ray görüntüleri kullanarak akciğer kanseri sınıflandırması için GA ile Sinir Mimarisi Araması (SMA) modelini optimize ettikleri çalışmada %97,15 sınıflandırma doğruluğu elde etmişlerdir. Yu vd. (2020), akciğer sınıflandırması gerçekleştirmek için Uyarlanabilir Hiyerarşik Sezgisel Matematiksel Model optimizasyon algoritması ile YSA modeli kullandıkları çalışmada, %96,67 sınıflandırma doğruluğu skoru elde etmişlerdir. Maulidina vd. (2021), BT akciğer görüntüleri ile akciğer kanseri sınıflandırması yapmak için PSO ve GA optimizasyon yöntemleri ile DMV sınıflandırıcısında hiper parametre optimizasyonu gerçekleştirmişlerdir. Çalışmada, %97,96 doğruluk, %97,66 F1 skor, %98,82 duyarlılık ve %98,46 kesinlik skoru sonucunu elde etmişlerdir. Meleki vd. (2021), GA ile K-EYK sınıflandırıcısını optimize ederek geliştirdikleri öznitelik seçici modeli sayesinde %99,80 sınıflandırma doğru başarıları elde etmişlerdir. Priya vd. (2021), literatürde “LIDC-IDRI” olarak adlandırılan veri setindeki görüntüleri kullanarak Derin İnanç Ağı (DİA) modelini Karşıtlık Temelli Pity

Böcek Algoritması kullanarak optimize ettikleri çalışmada, %97,92 sınıflandırma doğruluğu, %97,24 kesinlik ve %96,86 duyarlılık sonucu elde etmişlerdir. Ajai ve Anitha (2022), BT akciğer görüntülerini kullanarak kanser sınıflandırması yaptıkları çalışmada ESA modelini Karıştırılmış Çoban Optimizasyonu (KÇO) yöntemi ile optimize etmişlerdir. %90 eğitim, %10 test verisi kullandıkları çalışmada derin YSA ve optimize edilmemiş ESA modeli ile yaptıkları sonuç karşılaştırmasında 0,896 doğruluk, 0,897 hassaslık, 0,845 özgüllük skoru sonuçları ile en iyi sonucu KÇO yöntemi ile optimize edilen ESA modeli vermiştir. Pethuraj vd. (2022), Kelebek Optimizasyon Algoritması Tabanlı K-Ortalamlar Kümeleme Algoritması ile akciğer görüntülerini bölütledikten sonra oto kodlayıcı tabanlı Tekrarlayan Sinir Ağları (TSA) modeli ile akciğer kanseri sınıflandırması gerçekleştiren bir model önermiştir. Sınıflandırma sonucu olarak %99,1 doğruluk, %97,3 kesinlik, %95,3 hassaslık skorlarını elde etmişlerdir. Mohamed vd. (2023), IQ-OTH/NCCD veri setindeki BT akciğer görüntüleri ile akciğer kanseri sınıflandırması yaptıkları çalışmada Ebola Optimizasyon yöntemi ile ESA modelini optimize ederek yeni bir yöntem geliştirmişlerdir. GA optimizasyon yöntemi ile optimize edilmiş ESA ve klasik ESA modellerinin de kullanıldığı çalışmada Ebola Optimizasyon yöntemi 0,9321 doğruluk ve 0,9021 özgüllük skoru ile en başarılı sonuçları veren yöntem olarak bulunmuştur. Nandipati ve Devarakonda (2023), BT akciğer görüntüleri ile akciğer kanseri sınıflandırması yaptıkları çalışmada öznelik çıkarıcısı olarak Vgg19 ve ESA modelini hibrid bir şekilde kullanıp, öznelik seçiminde ise Hızlandırılmış Sarmalayıcı Tabanlı İkili Arı Kolonisi algoritması ile optimize etmişlerdir. Geliştirilen bu yöntem ile %98,34 doğruluk, %97,96 kesinlik, %98,72 duyarlılık ve %98,32 F1 skor sonuçlarını elde etmişlerdir. Prasad vd. (2023), LIDC/IDRI ve “chest X-ray” veri setindeki görüntüleri kullanarak akciğer kanseri sınıflandırması yaptıkları çalışmada öznelik çıkarıcısı olarak kullandıkları ESA-LSTM modelini Martı Algoritması ile Benekli Sırtlan Optimizasyonu yöntemini hibrid bir şekilde kullanarak optimize etmişlerdir. Çalışmada geliştirdikleri yöntem ile LIDC/IDRI veri seti için %99,6 doğruluk, %99,14 kesinlik, %99,3 özgüllük, %99,8 hassaslık, “chest X-ray” veri seti için %99,7 doğruluk, %97,5 kesinlik, %97,8 özgüllük ve %99,62 hassaslık sonuçlarını elde etmişlerdir. Saranya ve Asha (2023), akciğer görüntülerindeki öznelik seçimi için doğrusal diskriminant analizini Kuantum Parçacık Sürü Optimizasyonu algoritması ile optimize ettikten sonra sınıflandırma

aşamasında ağırlıklı gradyan güçlendirme modelini kullanan bir çalışma yapmışlardır. Geliştirilen bu model ile %99,12 sınıflandırma doğruluğu sonucunu elde etmişlerdir.

Sayed ve Hassanien (2017), histopatolojik görüntülerde mitoz tespiti ve sınıflandırması için öznitelik seçiminde güve alevi optimizasyon yöntemini kullanan bir model önermişlerdir. Elde edilen öznitelikler, sınıflandırma ve regresyon ağacına aktarılmıştır. Önerilen bu yaklaşım sonucu olarak %92,99 doğruluk, %66,03 hassaslık, %95,73 kesinlik ve %65,42 F skor oranları elde edilmiştir. Punitha vd. (2019), WBCD veri setindeki görüntüler ile meme kanseri sınıflandırması yapmak için Akıllı YAK ve Geliştirilmiş Monarşi Kelebek Optimizasyonu yöntemi ile YSA modelini optimize eden bir model geliştirmişlerdir. Meme kanseri sınıflandırması için iki optimizasyonu yönteminin hibrit bir şekilde kullanılmasını sağlayan bu model ile %97,53 doğruluk, %96,75 hassaslık ve %97,04 özgüllük skoru sonucu elde edilmiştir. Pal ve Saraswat (2019), literatürde “blue histology” ve “ADL histopatoloji” veri setleri olarak bilinen görüntüleri kullanarak hastalık sınıflandırması için öznitelik seçiminde Biyocoğrafya Tabanlı Optimizasyon (BTO) algoritması ve sınıflandırıcı olarak DVM’nin kullanılmasını önerdikleri çalışmada, blue histology veri seti için %69,21 ve ADL histopatoloji veri seti için %87 sınıflandırma doğruluğu sonucuna ulaşmışlardır. Mittal ve Saraswat (2019), histopatolojik görüntülerde doku sınıflandırması için yerçekimsel arama algoritması ve DVM sınıflandırıcısı kullandıkları modelde, %51,6 doğruluk, %51,55 hassaslık, %50,33 kesinlik ve %59,85 F ölçütü skoru elde etmişlerdir. Rezaee vd. (2020), MIAS veri setindeki görüntüleri kullanarak meme kanseri sınıflandırması yaptıkları çalışmada K-Ortalamlar yöntemi ile kanserli bölgeyi öncelikli olacak şekilde kümeleyip, Pseudo-Zernike momentlerini kullanarak öznitelik çıkarımı yapan ve Karıştırılmış Kurbağa Sıçrama algoritması tabanlı ANFIS sınıflandırıcısı ile optimize eden bir yöntem geliştirmişlerdir. Meme kanseri için önerilen bu yöntem ile %82 doğruluk ve %85 AUC skoru sonucunu elde etmişlerdir. Thawkar vd. (2021), DDSM veri setindeki görüntüleri kullanarak meme kanseri sınıflandırması yapmak için öznitelik seçici olarak Kelebek Optimizasyonu ve Karınca Aslan Optimizasyonu yöntemlerini hibrit bir şekilde kullanıp, DVM, ANFIS ve YSA sınıflandırıcıları arasında karşılaştırma yaptıkları bir model önermişlerdir. Kullanılan sınıflandırıcılar arasında %98,50 doğruluk, %98,23 kesinlik ve %98,80 duyarlılık skoru ile en başarılı sonucu ANFIS elde etmiştir. Saraswat vd. (2021) geliştirilmiş BTO algoritması ile öznitelik seçici ve sınıflandırıcı olarak DVM kullanılan

bir model önermişlerdir. BACH veri setindeki histopatolojik görüntüleri kullanarak kanser sınıflandırması yaptıkları çalışmada %74,25 sınıflandırma doğruluğu sonucu elde etmişlerdir. Houssein vd. (2022), CBIS-DDSM veri setindeki görüntüleri kullanarak meme kanseri sınıflandırması yaptıkları çalışmada ResNet50 modelini Geliştirilmiş Deniz Yırtıcıları Optimizasyon yöntemi ile optimize etmişlerdir. Meme kanseri için önerilen bu yöntem ile %98,32 doğruluk, %96,61 hassaslık, %98,56 özgüllük, %98,68 kesinlik, %97,65 F skor ve %97,88 AUC skoru sonucunu elde etmişlerdir. Oyelade ve Ezugwu (2022), MIAS veri setindeki görüntüleri kullanarak meme kanseri sınıflandırması için ESA modelinin GA ve Yaşam Seçimine Dayalı Optimizasyon (YSDO), Balina Optimizasyon algoritması, Çoklu Evren Optimizasyonu gibi optimizasyon yöntemleri ile optimize etmiştir. Çalışmada elde edilen bulgulara göre 0.96 doğruluk, %96 kesinlik, %96 duyarlılık ve %98 F1 skoru ile en başarılı sonucu YSDO yöntemi vermiştir. Pramanik vd. (2023), DDSM veri setindeki görüntüleri kullanarak meme kanseri sınıflandırması için öznetelik çıkarıcısı olarak Vgg16 modeli, öznetelik seçimi için Sosyal Kayak Sürücüsü optimizasyonunun ve sınıflandırıcı olarak da K-EYK yönteminin kullanıldığı bir model önermişlerdir. Meme kanseri sınıflandırması için geliştirilen bu yöntem ile %96,07 doğruluk, %96,30 kesinlik ve %99,28 duyarlılık skoru sonucunu elde etmişlerdir. Vijh vd. (2023), Aslan Optimizasyonu ve Kedi Sürü Algoritması gibi iki meta sezgisel optimizasyon yöntemi hibrit bir şekilde kullanıp YSA modeli ile histopatolojik görüntülerin meme kanseri sınıflandırmasını yaptıkları çalışmada %71,4 doğruluk, %93,12 kesinlik ve %93,23 duyarlılık skorlarını elde etmişlerdir. Atban vd. (2023), histopatolojik görüntüler ile meme kanseri sınıflandırması için ResNet18 modelinin PSO, Atom Arama Optimizasyonu ve Denge Optimizasyonu (DEO) algoritmaları ile optimize edilmesini ve sınıflandırıcı olarak da DVM ve K-EYK sınıflandırıcılarını kullandıkları bir karşılaştırmalı bir yöntem geliştirmişlerdir. Meme kanseri için geliştirilen bu karşılaştırmalı optimizasyon yönteminde %97,73 doğruluk, %97,75 kesinlik, %97,75 duyarlılık ve %97,75 F1 skoru ile en yüksek sonucu DEO yöntemi ve DVM sınıflandırıcısı kombinasyonu vermiştir. Bhausaheb ve Kashyap (2023), histopatolojik görüntüler kullanarak meme kanseri sınıflandırması için karıştırılmış çoban geyiği avı optimizasyonu ile YSA modeli kullanan bir model önermişlerdir. Sınıflandırma sonucu olarak %89,27 doğruluk, %81,41 duyarlılık, %86,34 kesinlik ve %77,20 özgüllük oranlarını elde etmişlerdir. Chakravarthy vd. (2023), MIAS

veri setindeki görüntüleri kullanarak meme kanseri sınıflandırması yaptıkları çalışmada ağırlıklandırılmış K-EYK modelini Karga Arama Optimizasyonu ile optimize eden bir yaklaşım önermişlerdir. Geliştirilen bu yöntem ile %84,35 doğruluk, %87,5 kesinlik ve %82 F1 skor sonucunu elde etmişlerdir. Kumbhare vd. (2023), DDSM veri setindeki görüntüleri kullanarak meme kanseri sınıflandırması gerçekleştirmek için Bölgesel temelli Geliştirilmiş TSA modelini hibrid Ejder Binici Optimizasyonu algoritması ile optimize eden bir model önermişlerdir. Geliştirdikleri bu yöntem ile %95,73 doğruluk, %95,75 hassaslık, %95,70 özgüllük, %95,78 kesinlik ve %95,76 F1 skor sonucunu elde etmişlerdir.

Hire ve Shinde (2018), DRIVE ve CHASE veri setlerindeki görüntüleri kullanarak DR göz hastalığı sınıflandırması için K-EYK modelini Karınca Kolonisi Optimizasyonu (KKO) yöntemi ile optimize eden bir algoritma geliştirmişlerdir. DR ve normal olarak ayrı bir şekilde sınıflandırdıkları sonuçlara göre ortalama metrik skorları, DRIVE veri seti için 0,9184 doğruluk, 0,918 özgüllük, 0,90 hassaslık, CHASE veri seti için 0,8810 doğruluk, 0,8714 özgüllük ve 0,785 hassaslık skoru sonucunu elde etmişlerdir. Karthikeyan ve Alli (2018), DR göz hastalığı sınıflandırması için öznitelik çıkarma ve sınıflandırma işleminde kullanılan DVM modelini Ateş Böceği Sürü Optimizasyonu (ABSO) algoritması ve GA ile optimize eden hibrit bir yöntem geliştirmişlerdir. Hiper parametre optimizasyonunun sınıflandırma başarısı üzerindeki etkisine dikkat çeken bu çalışmada hiper parametre optimizasyonu olmadan 0,9315 doğruluk, 0,9167 hassaslık, 0,9592 özgüllük ve 0,9259 F skor sonucu elde edilmiştir. ABSO algoritması ile hiper parametre optimizasyonu yapıldığında 0,9726 doğruluk, 0,9583 hassaslık, 0,98 özgüllük ve 0,9812 F skor sonucunu elde etmişlerdir. Herliana vd. (2018), YSA modelini PSO yöntemi ile optimize ederek DR göz hastalığı sınıflandırması yaptıkları çalışmada %76,11 doğruluk, %83,81 kesinlik, %69,22 duyarlılık ve %82,7 AUC skoru sonucu elde etmişlerdir. Loheswaran (2020), DR göz hastalığı sınıflandırması için TSA modelinin Geliştirilmiş KKO algoritması ile optimize edildiği bir model önermişlerdir. Önerilen bu model ile 0,9315 doğruluk skoru elde edilmiştir. Roshini vd. (2020), DR göz hastalığı sınıflandırması için öznitelik seçiminde derin ESA modelini uygunluğa dayalı Tavuk Sürü Optimizasyonu yöntemi ile optimize eden bir model önermişlerdir. Geliştirilen bu yöntem ile 0,9333 doğruluk, 0,875 özgüllük ve 0,9333 F1 skor sonucunu elde etmişlerdir. Jadhav vd. (2021), DIARETDB1 veri setindeki görüntüleri kullanarak DR göz hastalığı

sınıflandırması için Geliştirilmiş Vites ve Direksiyon Tabanlı Sürücü Optimizasyonu yöntemi ile DİA modelinin öznelilik çıkarışı olarak kullanıldığı ve optimize edildiği bir yöntem önermişlerdir. Çalışmada kullanılan yöntem ile 0,9318 doğruluk, 0,8636 hassaslık, 0,9546 özgüllük, 0,8636 kesinlik ve 0,8636 F1 skor sonucunu elde etmişlerdir. Nayak vd. (2021), GA ve DVM sınıflandırıcı kullandıkları çalışmada %98,04 doğruluk, %97,49 duyarlılık, %98,81 özgüllük ve %98,31 F1 skor sonucunu elde etmişlerdir. Dayana ve Emmanuel (2022), DR DIABETDR0 ve DIABETDR1 veri setindeki görüntüleri kullanarak öznelilik ve sınıflandırma aşamasında optimizasyon yöntemi kullandıkları bir model geliştirmişlerdir. Öznelilik çıkarma ve seçme aşamasında derin YSA modelini, sınıflandırma aşamasında ise yığınlanmış oto kodlayıcı modelini Kronolojik Tunikat Sürü Algoritması ile optimize eden bu çalışmada birçok sınıflandırma metriği kullanılmıştır. Geliştirilen bu yöntem ile DIARETDB0 veri seti için %95,9 ortalama doğruluk, %88,07 hassaslık, %96,80 özgüllük, %85,26 F1 skor, DIARETDB1 veri seti için %95,48 ortalama doğruluk, %93,29 hassaslık, %91,89 özgüllük ve %90,53 F1 skor sonuçlarını elde etmişlerdir. Reddy ve Gurralla (2022), OKT görüntüleri ile göz hastalıkları sınıflandırması için sezgisel optimizasyon algoritması ve öznelilik çıkarıcı olarak kullanılan modifiye edilmiş geyik avı optimizasyon algoritması ile ESA modeli kullanarak sınıflandırma sonucu olarak %98,67 ortalama doğruluk skoru elde etmişlerdir. Pugal Priya vd. (2022), DR göz hastalığı sınıflandırması için kırmızı tilki optimizasyon algoritması ile LSTM modeli kullandıkları çalışmada %97,92 kesinlik, %96,89 hassaslık, %96,78 duyarlılık, %98,45 özgüllük ve %97,93 F skoru sonucuna ulaşmışlardır. Xavier (2023), glokom göz hastalığı tespiti ve sınıflandırması için geliştirilmiş yağmur optimizasyon algoritması ile DenseNet ve MobileNet modellerini optimize ettiği çalışmada, %96,3 doğruluk, %96,43 duyarlılık, %96,27 özgüllük ve %90 kesinlik oranı sonuçları elde etmiştir. Ramesh ve Sathiamoorthy (2023), DR göz hastalığı sınıflandırması için öznelilik seçiminde DenseNet169 modeli, optimizasyon sürecinde ise beyin fırtınası optimizasyonu kullandıkları çalışmada sınıflandırma sonucu olarak %99,23 doğruluk, %94,92 duyarlılık ve %99,4 özgüllük değerleri elde etmişlerdir. Bansode vd. (2023), HR veri setindeki görüntüleri kullanarak DR göz hastalığı sınıflandırması yapmak için LSTM modelini Köpek Balığı Kokusu ve Jaya Optimizasyon algoritması gibi iki farklı optimizasyon yöntemini hibrid bir şekilde kullandıkları bir model önermişlerdir. Geliştirilen bu yöntem ile %67,44 doğruluk, %96,09 hassaslık,

%44,5 özgülük, %58,64 kesinlik ve %72,83 F1 skoru sonucunu elde etmişlerdir. Chandran vd. (2023), DR göz hastalığı sınıflandırması için IDRİD ve Messidor veri setlerindeki görüntüleri kullandıkları çalışmada özniteliklerin elde edilmesi için pencere uyarlamalı algoritma tabanlı öznitelik çıkarma tekniğini kullanmışlardır. Bu öznitelikler, Capuchin Arama Optimizasyonu ile optimize edilmiş otomatik metrik grafik sinir ağı modeli ile işlenmiş ve sınıflandırılmıştır. Önerilen bu yöntem ile IDRİD veri seti için %99 doğruluk, %95 F skor, Messidor veri seti için %96 doğruluk, %96 F skor sonuçları elde edilmiştir. Gorde ve Gurjar (2023), DR göz hastalığı sınıflandırması için IDRİD veri setindeki görüntüleri kullandıkları çalışmada DenseNet169 ve Inceptionv3 modellerini PSO, YAKA, KKO optimizasyon yöntemleri ile optimize edip en yüksek sınıflandırma doğruluğunu sağlayan kombinasyonu bulmaya çalışmışlardır. Çalışmada, Inceptionv3 modeli KKO optimizasyonu ile kullanıldığında %98,14, DenseNet169 modeli YAKA optimizasyonu ile kullanıldığında %96,29 doğruluk skoru ile bu modeller için en yüksek skoru elde etmiştir. Khaparde vd. (2023), DR göz hastalığı sınıflandırması için DIABETDR1 veri setindeki görüntüleri kullandıkları çalışmada öznitelik çıkarma ve sınıflandırma işlemi için 3B ESA ve ikili dikkat TSA modelini hibrid bir şekilde kullanan ve Spiral Bakteri Kolonisi optimizasyon yöntemi ile optimize eden bir model önermişlerdir. Geliştirilen bu yöntemi LSTM, ESA, ikili dikkat TSA ve 3B ikili dikkat TSA modelleri ile kıyasladıkları çalışmada %96,62 doğruluk, %96,62 hassaslık, %96,62 özgülük, %90,52 kesinlik ve %93,47 F1 skor sonucunu elde ederek, diğer modellerden daha başarılı bir sonuç elde etmişlerdir. Krishnamoorthy vd. (2023), DR göz hastalığı sınıflandırması için Messidor-1 ve APTOS veri setindeki görüntüleri kullandıkları çalışmada öznitelik çıkarma işlemi için 1B çift yönlü tekrarlayan ESA modelini Karşıtlık Tabanlı öğrenmeye dayalı Ateş Uçucu algoritması ile optimize eden bir model geliştirmişlerdir. Önerilen bu yöntem ile APTOS veri seti için %98,34 doğruluk, %89,87 duyarlılık, %96,16 kesinlik ve %91,23 F1 skor, Messidor-1 veri seti için %97,32 doğruluk, %90,17 duyarlılık, %94,18 kesinlik ve %92,49 F1 skor sonucunu elde etmişlerdir.

Sezgisel optimizasyon ile farklı tıbbi görüntülere ait kanser sınıflandırması çalışmalarına dair literatür incelendiğinde parametre-hiper parametre optimizasyonu yerine öznitelik seçme aşamasında bir optimizasyon işlemi yapıldığı görülmektedir. Bu durum, öznitelik seçimi için güçlü derin öğrenme modellerinin kullanılmasına

odaklanılmasını sağlar. Optimizasyon yönteminin öznitelik seçme işleminde başarılı olması durumunda sınıflandırıcı için ekstra bir tercihe gidilmesine gerek kalmamaktadır. Böylelikle, çalışmada kullanılan parametreler sadece model seçimi ve kullanılan sezgisel optimizasyon yönteminin kendi parametreleri ile sınırlı kalmaktadır. Öznitelik seçimi için sezgisel optimizasyon ile sadece modellerin kullanılması durumunda, gereksiz öznitelikler öğrenme işlemine dahil olmayacağı için hızlı bir model eğitim süreci gerçekleşebilir. Ancak, böyle bir durumda modelin geliştirilebilir olma yeteneği sorgulanır. Az sayıda parametrenin kullanıldığı böylesi çalışmalarda en azından birden fazla veri setinin kullanılması gereklidir. Bu nedenle, sınıflandırıcıların sezgisel optimizasyon yöntemi ile kullanılması, elde edilen sonuçların geçerliliği ve güvenilirliği açısından daha doğru bir tercih olacaktır. Her ne kadar, kanser sınıflandırması için sezgisel optimizasyon yöntemlerini kullanan çalışmalarda yüksek doğruluk skorları elde edilmiş olsa da, birden fazla veri seti kullanılmadığı için ne kadar geliştirilebilir oldukları konusu tartışmalıdır. Çünkü, sezgisel optimizasyon yöntemi kullanmadan sadece önceden eğitilmiş modeller ile yapılan çalışmalara bakıldığında hem kullanılan model sayısının hem de aynı veri türündeki veri seti sayısının daha fazla olduğu görülmektedir. Sezgisel optimizasyon yönteminin, çalışma süresi, daha az parametre ile daha yüksek doğruluk skoru elde etme gibi avantajları görülse de geliştirilebilir model, hiper parametre optimizasyonu söz konusu olduğunda parametre fazlalığı, donanım gücü gereksinimi gibi konularda da ciddi bir dezavantaja sahip olduğu görülmektedir. Ayrıca, sadece öznitelik seçimi için sezgisel optimizasyon kullanılan çalışmalarda Temel Bileşenler Analizi (TBA) yöntemi ile bir karşılaştırma yapılabilir. Bu karşılaştırma ile hem ele alınan sınıflandırma metriği skoru hem de çalışma süresi açısından hangisinin daha avantajlı olduğu görülebilir. Bunların yanında, iki sezgisel optimizasyon algoritmasının hibrit bir şekilde kullanıldığı ya da birden fazla sezgisel optimizasyon yönteminin kullanılıp, aralarında en iyi sonucu veren yöntemin belirlendiği çalışmalar da dikkat çekmektedir. Bu tarz çalışmalarda genellikle, öznitelik çıkarıcısı olarak tek bir modelin kullanılması, en yüksek skorun elde edilmesinde hangi sezgisel yöntemin başarılı olacağına dair kullanılan yöntemler arasında bir karşılaştırma yapılmaktadır. Dolayısıyla bu durum, kendi içerisinde bir sağlama işlevi görüp, çalışmanın geçerliliği ve güvenilirliği açısından önemli bir kazanım olarak kabul edilmektedir. Genel olarak, tıbbi görüntü sınıflandırması yapılan çalışmalarda sezgisel

optimizasyon yöntemleri, mevcut parametreler içerisinde en başarılı sonucun elde edilmesi için güçlü bir yaklaşımdır. Sezgisel optimizasyon ile kullanılan parametrelerin (model, sınıflandırıcı ve hiper parametreler) sayısı ve değerleri doğru bir şekilde belirlendiğinde mümkün olan en kısa sürede en iyiye yakın bir sonucu elde etmesi beklenmektedir. Az sayıda parametre ile başarılı sonuçların elde edilmesi durumunda geçerli ve güvenilir bir sonuç olarak kabul edilebilmesi için birden fazla veri setinin kullanılması, modelin içerisinde çapraz doğrulama tekniğinin kullanılması, istatistiksel testlerin yapılması gibi ekstra düzenlemeler düşünülebilir. Bunun yerine, karşılaştırmalı sonuçlar elde edilmesi açısından birden fazla model, sınıflandırıcı ve bunlara bağlı olarak hiper parametrelerin kullanılmasının daha uygun olacağı düşünülmektedir. Literatürdeki çalışmalarda bu durum ciddi bir eksiklik olarak görülmektedir. Ancak bunun yanında, birden fazla sezgisel optimizasyon yönteminin kullanılıp bir karşılaştırma yapıldığı ya da iki sezgisel optimizasyon yönteminin hibrid bir şekilde kullanılarak yeni stratejilerin geliştirilmesi gibi durumlar bunun dışında görülmektedir. Son olarak, yalnızca bir sezgisel optimizasyon yöntemi ile öznitelik çıkarmak için bir derin öğrenmenin kullanıldığı çalışmaların, boyut azaltma işlevini yerine getiren diğer yöntemlerden (TBA) farkı ve farklı veri setlerine uygulanması konusundaki çekimserlik, en önemli eksiklikler olarak ifade edilebilir.

ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOT

3.1. Veri Setleri

Çalışmada toplamda 5 adet veri seti kullanılmıştır. Bu veri setlerinin ikisi akciğer kanserinin sınıflandırmasına yönelik, ikisi meme kanserinin sınıflandırmasına yönelik ve bir veri seti de OKT görüntüleri ile DR göz hastalığının sınıflandırmasına yönelik oluşturulmuş veri setleridir.

3.1.1. Akciğer Nodülü Veri Seti

Akciğer nodülü, geçirilen bir enfeksiyon hastalığı sonrasında akciğer üzerinde kalan ve 3 santimetre çapından büyük lekelerdir (Loverdos vd., 2019: 227). İyi huylu ve kötü huylu nodüller olmak üzere ikiye ayrılmaktadır. Akciğer nodülü veri seti (ANVS) bünyesinde bulunan BT akciğer nodülü görüntüleri ile iyi huylu kötü huylu akciğer tümörü sınıflandırması yapılmaktadır. ANVS kaggle platformundan elde edilebilmektedir (<https://www.kaggle.com/kmader/>).

Bu çalışmada kullanılan ANVS, LUNA16 yarışması için hazırlanan görüntülerden oluşmaktadır. LUNA16, akciğer nodüllerinin segmentasyonu ve sınıflandırması için hazırlanmış BT akciğer görüntülerinin kullanıldığı bir organizasyonun 2016 yılındaki yarışmasıdır (<https://luna16.grand-challenge.org/>).

3.1.2. Meme Kanseri Veri Seti-1

Meme Kanseri Veri Seti-1 (MKVS-1), histopatolojik görüntüler ile meme kanseri sınıflandırması yapılması için oluşturulmuş bir veri setidir. Bu veri setindeki veriler ile kanser-normal sınıflandırması yapılmaktadır. MKVS-1'deki histopatolojik görüntüler, 2018-2019 yılları arasında Patch Camelyon (PCam) veri setinde elde edilen verilerden oluşmaktadır. PCam veri seti, çok farklı versiyonları bulunan ve veri sayıları ile görüntülerin boyutlarının değişkenlik gösterdiği bir veri setidir. Bu çalışmada, 20 bin örneğe yakın bir değerle temsil edilen (20K) versiyonu kullanılmıştır. Bu veri seti, kaggle platformundan elde edilebilmektedir (<https://www.kaggle.com/competitions/histopathologic-cancer-detection>).

3.1.3. Diyabetik Retinopati Veri Seti

DR veri seti, DR göz hastalığının sınıflandırması için OKT görüntülerini kullanan bir veri setidir. Literatürde “RFMiD” veri seti olarak adlandırılmaktadır. Çoklu göz hastalığı sınıflandırmasına dair veriler içeren bu veri setindeki DR ve normal etiketli veriler ile ikili sınıflandırma yapılmıştır. DR veri seti, kaggle platformundan elde edilebilmektedir (<https://www.kaggle.com/datasets/andrewmvd/retinal-disease-classification>).

3.1.4. Akciğer Kanseri Veri Seti

Akciğer kanseri veri seti (AKVS), BT görüntüleme tekniği ile elde edilen, DICOM tıbbi görüntü formatı ile kaydedilmiş ve akciğer kanseri sınıflandırması için oluşturulmuş veri setidir. AKVS, literatürde “The Cancer Genome Atlas Lung Adenocarcinoma (TCGA-LUAD)” olarak adlandırılmaktadır. ANVS’den farkı, her iki akciğerin mide ile geniş bir şekilde görüntülenmiş ve hasta kayıtlarına ait bilgileri içermiş olmasıdır. Ayrıca, DICOM görüntü formatı ile kaydedilmesine rağmen sonrasında NIFTI formatına dönüştürülmüştür. AKVS, kaggle platformundan elde edilebilmektedir (<https://www.kaggle.com/datasets/kmader/siim-medical-images>).

3.1.5. Meme Kanseri Veri Seti-2

Meme Kanseri Veri Seti-2 (MKVS-2), literatürde “BreaKHis” veri seti olarak bilinen ve farklı yakınsama oranlarına göre bir araya getirilmiş histopatolojik görüntüler ile meme kanseri sınıflandırması yapılmasını sağlayan bir veri setidir. Bu veri seti, kaggle platformundan elde edilmiş olup (<https://www.kaggle.com/datasets/forderation/breakhis-400x>), 400x yakınsama oranına sahip histopatolojik görüntüler içermektedir.


3.2. Veri Setleri Hakkında İstatistikî Bilgiler

Çalışmada DR ve MKVS-2 veri setleri haricindeki diğer veri setleri %80 eğitim, %20 test verisi olarak ayrılmıştır. DR ve MKVS-2 ise yükleyen kişi-organizasyonların belirlediği halka açık bir şekilde kullanım politikaları gereği eğitim-test verisi oranı, yükleyen kişinin belirlediği orana göre kullanılmıştır. Tablo 1’de çalışmada kullanılan 5 veri setine ait istatistikî bilgiler verilmektedir.

Tablo 1. Çalışmada Kullanılan Veri Setlerine Ait İstatistiki Bilgiler

Veri Seti	Eğitim Verisi	Test Verisi	Toplam Veri	Etiket Sayısı	
				0	1
ANVS	5352	1339	6691	4165	2526
MKVS-1	15616	3904	19520	9760	9760
DR	2560	640	3200	2531	669
AKVS	80	20	100	50	50
MKVS-2	1148	545	1693	547	1146

Tablo 1’de verilen veri setleri hakkındaki istatistiki bilgilerde etiket sayısı ile kastedilen, ikili sınıflandırmada kullanılan “normal”-“iyi huylu”-“kanser değil” (0 etiketi), “hasta”-“kötü huylu”-“kanser” (1 etiketi) tanımlamalarıdır. İlaveten, Tablo 1’deki istatistikler, 5 veri setinin de veri artırma tekniği uygulanmamış hali yani orijinal haline ait bilgilerdir. Şekil 6’da 5 veri setine ait ve her iki etikete de sahip örnek görüntüler verilmektedir.

Şekil 6. Çalışmada Kullanılan 5 Veri Setine Ait Orijinal Görüntüler

3.3. Veri Ön İşleme

Görüntüdeki istenmeyen durumların giderilmesi ve etkili sonuçlar elde etmek amacıyla uygulanan yöntemler bütünü olarak değerlendirilebilir (Mishra vd., 2020: 1-2).


3.3.1. Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme

Uyarlanabilir Histogram Eşitleme (AHE), görüntünün parçalara bölünerek her bir parçanın histogram eşitlemesinin ayrı ayrı yapıldığı tekniktir (Zhu ve Huang, 2008). Eğer görüntü üzerinde gürültü yoksa, bu yerel ve küçük parçalı histogram eşitlemeler oldukça başarılı bir şekilde yapılacaktır. Bu açıdan AHE, görüntü içerisindeki yerel kontrastın geliştirilmesi açısından daha elverişlidir (Mungra vd., 2022).

CLAHE, AHE'nin gürültülü görüntülerdeki başarısının artırılması için geliştirilmiş bir tekniktir. CLAHE'de, görüntü histogram eşitleme için küçük parçalara ayrıldıktan sonra bu parçalardan herhangi birisi belirtilen kontrast sınırından üst bir değere sahipse bu pikseller kırpılarak histogram eşitleme işlemi uygulanmadan diğer parçalara eşit bir biçimde dağıtılır (Pour vd., 2020: 3).

Şekil 7'de 5 veri setinde yer alan CLAHE uygulanmış görüntüler verilmektedir.

Şekil 7. Veri Setlerine Ait Orijinal (Üstteki) ve CLAHE Uygulanmış (Alttaki) Görüntüler




3.3.2. Veri Artırma

Veri artırma, mevcut verilerin kullanılması ile üretilen yapay verilerdir (Liu vd., 2020). Veri artırma, farklı teknikler ve dönüşümler kullanarak eğitim verileri üzerinde uygulanır ve bu sayede hem verilerin çeşitliliği sağlanmış olur hem de modelin öğrenme yeteneğinin sağlamlığı artırılmış olur. (Liang vd., 2023: 1).

Şekil 8’de orijinal ve CLAHE uygulanmış verilerin, çeşitli veri artırma tekniği ile çoğaltılmasına dair örnekler gösterilmektedir.

Şekil 8. Veri Artırma Tekniği Uygulanmış Görüntüler (Artırılmış-O: Artırılmış Orijinal Görüntüler; Artırılmış-C: Artırılmış CLAHE’li Görüntüler)



Etiket sayısının eşit dağılmış olması ve fazla sayıda veri bulunması nedeni ile MKVS-1’e veri artırma tekniği uygulanmamıştır.

3.3.2.1. Yatay ve Dikey Kaydırma

Bir görüntünün kaydırılması, o görüntünün boyutunun değiştirilmeden görüntüye ait tüm piksellerin yatay ya da dikey olarak tek yönlü bir şekilde hareket ettirilmesidir (Ottoni vd., 2023). Bundan dolayı bazı pikseller görüntüden kırılır ve bu piksel değerlerinden boşalan, yeni piksel değerlerinin belirlenmesi gereken bir bölge elde edilmiş olunur (Talasila vd., 2022).

3.3.2.2. Yatay ve Dikey Çevirme

Görüntü çevirmek, o görüntünün yatay (x eksen) ya da dikey (y eksen) düzeyde piksellerinin çevrilmesidir (Zhang vd., 2020: 1677).

3.3.2.3. Rastgele Döndürme

Görüntünün 0 ile 360 derece arasında belirtilen bir değerde döndürülmesidir (Alomar vd., 2023).

3.3.2.4. Rastgele Yakınlaştırma

Rastgele yakınlaştırma tekniği ile görüntünün çevresine yeni pikseller eklenerek ya da piksel değerlerinin interpolasyonu yapılarak, görüntü belli bir oranda yakınlaştırılır ya da uzaklaştırılır (Gorad ve Kotrappa, 2021: 4).

3.3.3. Filtreler

Filtreleme işlemi, yumuşatmaya da bulanıklaştırma olarak da adlandırılmaktadır. Filtre, görüntünün elde edilmesi ya da işlenmesi aşamasında oluşmuş olan istenmeyen-rastgele piksellerin yani gürültünün azaltılması ya da giderilmesi amacıyla kullanılan yöntemlerdir (Shah vd., 2022: 506).

Çalışmada kullanılan veri setleri içerisinde DR veri seti hariç diğer tüm veri setlerinde AD, BM3D, İKT, Gauss, HM, Ortalama, TV ve Dalgacık filtre olmak üzere 8 adet filtre kullanılmıştır. DR veri setinde ise bu 8 filtre ve Ağırlıklandırılmış Gauss (AG) filtresi de kullanılmıştır.

Bu durumun nedeni, göz hastalıkları sınıflandırmasında OKT görüntülerinde ağırlıklandırılmış Gauss filtresinin gözdeki damar yapısını ortaya çıkarmada daha başarılı bulunmasıdır (Jabbar vd., 2022).

3.3.3.1. Anizotropik Difüzyon Filtre

AD filtre, Perona ve Malik (1990) tarafından geliştirilen, görüntünün özelliklerini koruyarak görüntüyü pürüzsüzleştirmek ve kenarları tespit etmek için kullanılan bir filtredir.

AD filtre, Denklem 1’de verilen eşitliğin sürekli bir şekilde tekrarlanmasıyla uygulanmaktadır.

$$I_a^{t+1} \approx I_a^t + \frac{\lambda}{|n_a|} \sum_{p \in n_a} g(|\nabla I_{a,b}^t|, \gamma) \nabla I_{a,b}^t \quad (1)$$

Denklem 1’de verilen I_a^t t anındaki bir I görüntüsündeki a pikseline ait yoğunluğu, λ difüzyon hızına bağımlı bir skaler büyüklüğü, n_a a pikseline komşu olan piksel kümesini, γ pürüzsüzleştirme işlemi için gerekli olan pozitif bir sabiti, $g(\cdot)$ kenar durdurma işlevini, $\nabla I_{a,b}^t$ a pikselinden b pikseline doğru oluşan gradyanın büyüklüğüne karşılık gelmektedir (Özen ve Akşahin, 2020).

AD filtrede gürültü tahmin edildikten sonra görüntüdeki farklı yoğunluklara sahip olan bölgeler için difüzyon katsayısı ayarlanır. Daha sonra, görüntü üzerinde seçilen bir piksel ve onun komşusu olan pikseller üzerinde Denklem 1’deki formül, tekrarlanarak uygulanır. Bu sayede piksellere ait bir yoğunluk istatistiği elde edilir.

Bu aşamadan sonra difüzyon işlemi başlar. Yoğunluk hesaplaması yapıldığı için, ilgili piksel ile komşu pikseller arasında bir karşılaştırma yapılır. Pikselin kendi yoğunluğu ile çevresinin yoğunluğu arasındaki fark, pikselin kendi değerine eklenir.

İstenilen pürüzsüzleştirme sonucu elde edilene değin bu işlemler tekrarlanır.

3.3.3.2. İki Taraflı Filtre

İKT filtre, görüntüdeki gürültülerin giderilip, görüntünün yumuşatılması ve bu yapılırken de kenarların korunması için Tomasi ve Manduchi (1998) tarafından geliştirilen bir filtredir.

İKT filtre; pikseller arasındaki uzaklığın nasıl ölçüleceğine (σ_s) ve pikseller arasında yoğunluk benzerliğinin (σ_r) nasıl hesaplanacağına dair iki filtre parametresinden oluşmaktadır.

İKT filtreye ait formül Denklem 2’de verilmektedir.

$$IKT[I]_a = \frac{1}{W_a} \sum_{b \in S} G\sigma_s(|a - b|) G\sigma_r(|I_a - I_b|) I_b \quad (2)$$

İKT filtre kullanılarak bir görüntünün a pikseline ait konumundaki bir çıktının $([I]_a)$ nasıl işlendiğini gösteren Denklem 2'de; I görüntü, W_a piksellere ait ağırlık toplamının 1'e eşit olmasını sağlayan bir normalizasyon faktörünü temsil etmektedir. İKT filtrede iki adet Gauss fonksiyonu kullanılır. Bu iki Gauss fonksiyonu ile pikseller arasındaki uzaklık $(G\sigma_s(|I_a - I_b|)I_b)$ ve yoğunluk benzerliği $(G\sigma_r(|I_a - I_b|)I_b)$ hesaplanır (Ozdil ve Gunes, 2015).

Uzaklık hesaplaması yapılırken, çerçeve (S) ne kadar geniş tutulursa o kadar çok piksel kümesi işlenir. Benzerlik yoğunluğu hesaplaması yapılırken, çerçeve ne kadar geniş tutulursa yani bu iki fonksiyona ait değerler ne kadar büyük seçilirse daha fazla piksel kümesi seçilecek ve bu piksellerin arasındaki yoğunluk farkı tolere edilecektir (Bhonsle vd., 2012).

Pikseller arasındaki uzaklık ve yoğunluk benzerliği hesaplandıktan sonra bu iki fonksiyondan elde edilen değerle, pikselin ağırlıklı ortalaması hesaplanır.

3.3.3.3. BM3D Filtre

BM3D filtre, özellikle tıbbi görüntülerdeki gürültülerin giderilmesi ve video sıkıştırma işlemi için geliştirilmiş bir yöntemdir. BM3D filtresinin çalışma prensibi aşağıda beş madde olarak verilmektedir (Djurović, 2016; Djurović, 2017).

- Görüntü üzerinde benzer yamalar oluşturmak için piksel değerleri incelenir ve belirli katsayılar ile hesaplanarak eşikleme işlemi uygulanır. Katsayı değerleri, eşik değeri ile karşılaştırılır ve eşik altına kalan değerler sıfıra eşitlenir.
- Birbirine benzer yamalar, 3B bloklara yerleştirilir ve genellikle 3B ayrık doğrusal dönüşüm işlemine tâbi tutulur. Sonrasında, dönüşüm katsayıları arasında da bir eşikleme işlemi yapılır. Eşik altına kalan değerler çıkarılır.
- 3B dönüşüm katsayıları Wiener filtresi ile filtrelendir ve geçici olarak filtrelenmiş bloklar elde edilir.
- Filtrelenmiş olan yamalara ters 3B dönüşüm işlemi uygulanır.

- Son olarak, filtrelenen yamalar orijinal görüntünün tahmini oluşturmak için bir araya getirilir.

3.3.3.4. Gauss Filtre

Gauss filtre, görüntü ve sinyal işlemede gürültü gidermeyi sağlayan düşük geçişli bir filtredir. Gürültü giderme işlemini Gauss fonksiyonunu (normal dağılım) kullanarak gerçekleştirir. Denklem 3'te Gauss fonksiyonu verilmektedir.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3)$$

Denklem 3'te verilen, x yatay eksenindeki uzaklık, y dikey eksenindeki uzaklık, σ standart sapma ve e doğal logaritma tabanı değerlerini temsil etmektedir.

Gauss filtresinde standart sapma ve filtre işlemi için kullanılacak matris boyutu, iki önemli parametredir. Matris boyutu, çerçeve içine alınacak piksel kümesini; standart sapma ise düzgünlüğü-keskinliği belirler. Standart sapma değeri ile piksellerin ağırlıkları hesaplanır. Filtre matrisi ile merkezdeki en yüksek ağırlığa sahip piksele göre çevredeki pikseller daha az ağırlığa sahip olacak bir şekilde ayarlanır ve düzgünleştirme işlemi gerçekleştirilir (Ito ve Xiong, 2000; Suryanarayana vd., 2021).

3.3.3.5. Ağırlıklandırılmış Gauss Filtre

AG filtre, iki görüntünün ağırlıklandırılarak birleştirilmesine olanak sağlar. Bu filtrenin parametreleri sırasıyla; birinci görüntü, alfa değeri, ikinci görüntü, beta değeri, pozitif sabit katsayı değeri (Opencv, 2023).

Denklem 4'te AG filtreye ait formülasyon verilmektedir.

$$g(x) = \alpha \cdot I_0 + \beta \cdot I_1 + \gamma \quad (4)$$

Denklem 4'te verilen; α alfa değeri, I_0 birinci görüntü, I_1 ikinci görüntü, β beta değeri ve γ pozitif sabit katsayı değeridir.

AG filtre uygulanırken, birinci görüntü orijinal görüntü olarak seçilmiş olup, ikinci görüntü ise Gauss filtresi uygulanmış görüntü olarak seçilmiştir.

3.3.3.6. Homomorfik Filtre

HM filtre, özellikle düşük kontrastlı tıbbi görüntülerin düzgünleştirmesini görüntüdeki aydınlatma ve yansıtma bileşenlerini kullanarak gerçekleştirir (Ramos-Soto vd., 2021).

Denklem 5'te HM filtrenin görüntüleri iki bileşenli olarak ele almasına dair formülasyon verilmektedir.

$$f(x, y) = i(x, y) \cdot r(x, y) \quad (5)$$

Denklem 5'te verilen $f(x, y)$ görüntü, $i(x, y)$ aydınlatma, $r(x, y)$ ise yansıtma bileşenleridir.

Aydınlatma işlevi, düzgünleştirmeyi; yansıtma işlevi ise kenar belirlemesini ve sınırların korunmasını ifade eder. Aydınlatma bileşeni düşük frekanslı olduğu için pek değişmez. Ancak, yansıtma bileşeni yüksek frekanslı olduğu için çok fazla değişim gösterir. Bu nedenle, aydınlatma ve yansıtma bileşenlerinin ayrılması için logaritmik dönüşüm uygulanır. Bu işleme ait formülasyon Denklem 6'da verilmektedir.

$$\ln(f(x, y)) = \ln(i(x, y)) + \ln(r(x, y)) \quad (6)$$

Sonrasında, frekans bileşenlerine ayrılması için her iki bileşene de Fourier Dönüşümü uygulanır. Denklem 7'de Fourier Dönüşümünün uygulanmasına dair formülasyon verilmektedir.

$$\begin{aligned} FT(\ln(f(x, y))) &= FT(\ln(i(x, y))) + FT(\ln(r(x, y))) \\ \Leftrightarrow FT_f(u, v) &= FT_i(u, v) + FT_r(u, v) \end{aligned} \quad (7)$$

Bu işlemten sonra, özellikle yansıtma bileşeninden gelen yüksek frekansların engellenmesi için düşük geçişli bir filtrele ($H(u, v)$) uygulanır. Filtre uygulanmış görüntüye ($S(u, v)$) ait formülasyon, Denklem 8'de verilmektedir.

$$S(u, v) = H(u, v) FT_f(u, v) = H(u, v) FT_i(u, v) + H(u, v) FT_r(u, v) \quad (8)$$

Elde edilen filtrelenmiş görüntüye Ters Fourier Dönüşümü (TFT) uygulanarak, görüntü frekans alanından tekrar uzaysal alana dönüştürülür. Bu işleme ait formülasyon Denklem 9'da verilmektedir.

$$S(u, v) = TFT(H(u, v) FT_i(u, v)) + TFT(H(u, v) FT_r(u, v)) \quad (9)$$

Son olarak, frekanslarına ayrılan görüntüye üstel fonksiyon uygulanır ve görüntü modifiye edilmiş aydınlatma ve yansıtma bileşenleri ile tekrar oluşturulur. Üstel fonksiyon uygulanmış görüntüye ait formülasyon Denklem 10'da verilmektedir (Yugander vd., 2020; Al Sabbahi ve Tekli, 2022).

$$E(x, y) = \exp[s(x, y)] = \exp[h_i(x, y)] \exp[h_r(x, y)] \quad (10)$$

Denklem 10'da verilen $E(x, y) = \exp[s(x, y)]$ üstel fonksiyon uygulanmış $S(u, v)$, $h_i(x, y) = TFT(H(u, v) FT_i(u, v))$ ve $h_r(x, y) = TFT(H(u, v) FT_r(u, v))$ işlemlerine karşılık gelmektedir. Bu ifadeler, denklemlerdeki bileşenlerin kısaltmaları olarak yazılmıştır.

3.3.3.7. Ortalama Filtre

Görüntüde genellikle kare matris ile alıcı alandaki piksel değerleri filtre matrisindeki değerleri çarpılır ve elde edilen sonuç, matrisin boyutuna bölünerek yeni piksel değeri belirlenir (Gupta, 2011). Bu işlem, filtre matrisinin görüntüdeki her bir piksel üzerinde kaydırılmasına kadar devam eder.

Ortalama filtreye ait formülasyon, Denklem 11'de verilmektedir.

$$\hat{f}(x, y) = \frac{1}{mn} \sum_{(s,t) \in S_{xy}} g(s, t) \quad (11)$$

Denklem 11'de verilen; S_{xy} m x n boyutundaki bir görüntünün x ve y noktasındaki piksel kümesini, $g(s, t)$ filtre matrisindeki s ve t koordinatlarındaki piksel değerlerini yani bozuk görüntünün ortalamasını temsil etmektedir (Janani ve Jebakumar, 2023).

3.3.3.8. Toplam Varyasyon Filtre

TV filtre, Rudin vd. tarafından (1992), görüntüdeki yüksek varyasyonu en aza indirmek ve kenarları korumak için geliştirilmiş bir yöntemdir.

Bir sinyale ait toplam değişim yani toplam varyasyon, sinyalin diğer sinyaller arasında ne kadar değiştiğini ölçer; $1 \leq n \leq N$ şartı ile bir N noktası sinyali olan $x(n)$ 'nin toplam değişimi Denklem 12'deki gibi hesaplanır (Selesnick ve Bayram, 2010).

$$TV(x) = \sum_{n=2}^N |x(n) - x(n-1)| \quad (12)$$

Daha kısa bir şekilde ifade edilecek olursa eğer, x 'in toplam değişimi Denklem 13'teki gibi de yazılabilir.

$$TV(x) = \|Dx\|_1 \quad (13)$$

Bir x görüntüsünün bozulduğu, gürültü karıştırıldığı varsayıldığında, temizlenmiş bir x görüntüsünün oluşturulabilmesi için amaç fonksiyonunu en düşük seviyeye indiren x sinyalinin elde edilmesi gerekir. TV gürültü giderme formülü, Denklem 14'te verilmektedir.

$$J(x) = \|y - x\|_2^2 + \lambda \|Dx\|_1 \quad (14)$$

Denklem 14'te verilen; y bozulmuş görüntü, x orijinal görüntü, λ düzeltirme parametresidir. Düzeltirme parametresi, yumuşatmanın ne denli kullanılacağını belirler. Bozulma büyükse eğer, daha büyük bir değer alması gerekir (Selesnick ve Bayram, 2010).

TV filtreleme işleminde önce gradyan hesaplanır. İlgili pikselin etrafındaki piksellerin değer farklarının kombinasyonu hesaplanır ve elde edilen değer, o pikselin gradyanı olur. Böylelikle, görüntüdeki kenarlar ve geçişler bulunmaya çalışılır (De Santis vd., 2022).

Sonrasında, düzeltirme işlemi ile gradyan değerleri birleştirilir. Bu sayede hem kenarlar korunmuş olur hem de düz bölgeler düzeltilir. Düzeltirme işlemi sayesinde gradyandaki büyük değerler bastırılır ve gürültülerin büyük bir kısmı giderilir. Düzeltirme işlemi sonrasında gradyanın tersi hesaplanarak bir nevi geri dönüştürme işlemi yapılır. Son olarak, düzeltilmiş gradyan ile orijinal görüntü birleştirilir (Roonizi ve Selesnick, 2022).

3.3.3.9. Dalgacık Filtre

Dalgacık, karmaşık sinyallerin temel fonksiyonların toplamalarına ayrıştırılmasına yarar. Ayrıca, öteleme ve genişleme yolu ile tek bir $\psi_{(a,b)}(t)$ fonksiyonunda elde edilirler (Sagiroglu ve Besdok, 2012; Qiu vd., 2006). Denklem 15'te dalgacığın elde edildiği fonksiyon verilmektedir.

$$\psi_{(a,b)}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (15)$$

Denklem 15’te verilen; a ölçeklendirme parametresi, b zaman yerleştirme parametresi ve $\psi(t)$ ise ana dalgacık şeklinde isimlendirilmektedir.


Sonlu enerji sinyali olan $x(t)$ ’nin, analiz edilen $\psi(t)$ dalgacığı ile dalgacık dönüşümü ancak $x(t)$ ’nin ölçeklendirilmiş ve eşlenik dalgacık ile evrişim işleminden ibarettir. Bu durum, Denklem 16’da verilmektedir.

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (16)$$


Denklem 16’da verilen dalgacık dönüşümü ($W(a, b)$), her a ölçeğindeki b ötelemesinin fonksiyonları olarak düşünülebilir. Bu durum, Denklem 16’daki eşitliğin, dalgacık analizinin bir zaman-frekans analizine karşılık geldiğini göstermektedir (Qiu vd., 2006). Görüntü filtrelemede Dalgacık filtrenin kullanımı, görüntünün farklı ölçeklerdeki detaylarını ve benzer bileşenlerini yakalamak içindir. Dalgacık dönüşümünü kullanan Dalgacık filtre, görüntünün farklı ölçeklerdeki dalgacık katsayılarını elde ederek görüntüdeki gürültüleri gidermeyi amaçlar. Dalgacık katsayıları elde edildikten sonra ters dönüşüm işlemi ile orijinal görüntüyü tahmin etmek için kullanılır.

Şekil 9-13’te sırasıyla ANVS, MKVS-1, DR, AKVS ve MKVS-2 veri setlerine ait orijinal ve CLAHE uygulanmış görüntülerin çeşitli filtre uygulanmış halleri verilmektedir.


Şekil 9. ANVS Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE




Şekil 10. MKVS-1 Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE




Şekil 11. DR Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE



Şekil 12. AKVS Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE



Şekil 13. MKVS-2 Verilerine Filtre Uygulanması a) Orijinal, b) CLAHE



3.4. Evrişimli Sinir Ağları Modelleri


Çalışmanın bu bölümünde, veri setlerindeki görüntülerin özneteliklerinin çıkartılmasında kullanılan önceden eğitilmiş ESA modelleri tanıtılmaktadır.

3.4.1. Vgg16

Vgg16, Simonyan ve Zisserman (2014) tarafından geliştirilmiş bir ESA modelidir. Görüntü sınıflandırma için kullanılan ImageNet veri seti üzerindeki başarısından dolayı

popüler bir görüntü sınıflandırma modelidir. Vgg16'nın mimarisi Şekil 14'te verilmektedir.

Şekil 14. Vgg16 Mimarisi



Kaynak: Mascarenhas ve Agarwal, 2021

Vgg16 mimarisinde girdi olarak 224x224'lük bir 3 kanallı kırmızı-yeşil-mavi (RGB) görüntü 2 defa evrişim işlemine tabi tutulur. Vgg16'nın en özgün özelliği de girişteki bu üst üste yapılan 2 evrişim işlemidir. Vgg16'da evrişim işleminden sonra aktivasyon olarak "Rectified Linear Unit (ReLU)" aktivasyon fonksiyonu kullanılır. Daha sonra maksimum ortaklama ile görüntü boyutu 112x112'ye düşürülür. Sonra yeniden 2 evrişim işlemi ve bir maksimum ortaklama işlemi yapılır ve görüntü boyutu 56x56'ya düşürülür. Daha sonra 3 evrişim işlemi ve bir maksimum ortaklama ile görüntü boyutu 28x28'e indirgenir. 3 evrişim ve maksimum ortaklama sonrasında girdi görüntüsünün boyutu 14x14'e düşürülür.

Son olarak 3 evrişim ve bir maksimum ortaklama ile görüntü boyutu 7x7'ye indirgenir ve tam bağlantı katmanına iletilir. 3 katmanlı yapay sinir ağları ile işlendikten sonra çıktı olarak 1000 sınıflı bir ağ elde edilir. Sınıflandırma işlemi için softmax fonksiyonu kullanılır (Simonyan ve Zisserman, 2014).

Vgg16 modelindeki Vgg ifadesi, Oxford Üniversitesindeki "Visual Geometry Group"; 16 sayısı da mimaride 13 adet evrişim katmanı ve 3 adet tam bağlantı katmanı olmak üzere toplam 16 katmanlı bir yapı kullanılmasından kaynaklanır. Vgg16 modelinde yaklaşık olarak 138 milyon parametre kullanılır.

3.4.2. Vgg19


Vgg19 modelinin Vgg16 modelinden tek farkı, bu modelin daha derin olması yani daha fazla evrişim katmanına sahip olmasıdır. Vgg16 modelinde 16 katman varken, Vgg19 modelinde ise 19 katman bulunmaktadır.

3.4.3. ResNet50

ESA'ların gittikçe daha derin bir hale bürünmesi, beraberinde bazı zorlukları da getirmiştir. Ağın derinliği arttıkça doğruluk değeri belirli bir düzeye kadar yükselir ancak bir süre sonra düşmeye başlar. Bu sadece aşırı uydurma sorununa yol açmaz ve yüksek bir eğitim hatasına da neden olur.

Türkçede “Artık Ağ” anlamına gelen “Residual Network” ifadesinin kısaltması olan ResNet, aynı katman sayısına sahip düz ağlara göre daha yüksek başarı sonucu elde etmeyi başarmış bir derin ESA modelidir (He vd., 2016). ResNet’in mimari yapısının anlaşılması için düz ve artık ağ kavramlarının açıklanmasında fayda görülmektedir. ResNet mimarisi, Şekil 15’te gösterilmektedir.

Şekil 15. ResNet Mimarisi



Kaynak: He vd., 2016

Düz ağ, Vgg modelinden esinlenerek oluşturulmuştur. Evrişim işleminin gerçekleştiği katmanlarda genellikle 3x3'lük filtre matrisleri kullanılmıştır. Ayrıca bu katmanlarda geçerli iki kural mevcuttur. Bunlar:

- Aynı boyutta bir çıktı özelliği haritası elde etmek için katmanlar da aynı filtre sayısına sahiptir.

- Özellik matrisinin boyutu yarıya indirgendiğinde, zaman karmaşıklığı dolayısıyla filtre sayısı da iki katı olarak artırılır.


ResNet'in özelliği ise Vgg modeline göre daha az sayıda filtre kullanması ve daha düşük bir zaman karmaşıklığına sahip olmasıdır (He vd., 2016).

Artık ağ, düz ağlara karşılık gelen bir ağ yapısıdır. Farklı olarak bu ağları artık bir yapıya dönüştüren kısa yollar ekler ve bunu her iki katmanda bir gerçekleştirir. Bu kısayol, atlama bağlantısı olarak da adlandırılır. Şekil 15'te görüldüğü gibi giriş ve çıkış aynı boyutta iken (Şekil 15'te düz ResNet mimarisindeki düz çizgiler) $F(x[w]+x)$ kimlik kısa yolu (iki katmanda bir eklenen artık blok) kullanılır. Boyutlar arttığında ise (Şekil 15'te ResNet mimarisindeki kısa çizgi yolu) iki duruma dikkat edilir. Bunlar:

- Boyutun artırılması için ekstra sıfır girişi yapılır, herhangi bir parametre kullanılmaz (atlama bağlantısı).
- Projeksiyon yöntemi olarak adlandırılan ikinci yöntem ise girişe 1×1 'lik evrişim katmanları ekleyerek, bunu boyut eşleştirme için kullanır. Burada, ilk durumun aksine ek bir parametre kullanılır (He vd., 2016).

Şekil 16'da ise bu durumu detaylıca açıklayan artık öğrenme yapısı gösterilmektedir.

Şekil 16. Artık Öğrenme Yapısı



Kaynak: He vd., 2016

ResNet'in altında yatan temel felsefe, herhangi bir öğrenme olmaması durumunda önceki katmanda öğrenilen bilginin sonraki katmana girdi olarak verilmesidir.

ResNet modeli; ResNet18, ResNet34, ResNet50, ResNet50v2 gibi modellerin kendisinden türetildiği bir ana model işlevi görür. En önemli özelliği de atlama

bağlantıları sayesinde eğitim sırasında öğrenme bilgisinin kaybolma sorununun önüne geçilmesidir (Kapoor vd., 2023).

ResNet50 modeli, 49 evrişim katmanı ve 1 tam bağlantı katmanından oluşan 50 katmanlı yapıya sahip, ResNet derin öğrenme modeli ailesi içerisinde yer alan bir modeldir.

ResNet50 modelinin, ResNet modelinin tanıtıldığı ResNet34 modeli (He vd., 2016) mimarisine göre en önemli farkı, katman sayısı arttığı için önceki modelde iki katman arasında kullanılan atlama bağlantısı, ResNet50 modelinde üç katman arasında kullanılmaktadır.


3.4.4. EfficientNet

EfficientNet, Tan ve Le (2019) tarafından geliştirilen ve ölçeklemeye dayanan etkili ve güçlü bir ESA modelidir. EfficientNet modeli de tıpkı ResNet gibi alt türevleri (farklı katmanları) olan modellere liderlik eden bir ana modeldir. EfficientNetB0'dan EfficientNetB7 versiyonuna kadar uzanan sekiz farklı model barındıran temel bir ağıdır.

EfficientNet, bir görüntünün derinlik, genişlik ve çözünürlüğünü eşit şekilde ölçeklemek için bileşik bir katsayı tekniği uygulayan bir ESA modelidir.

Bileşik katsayı işleminden sonra görüntü daha derin, daha geniş ve daha yüksek çözünürlüğe sahip bir hale getirilir. Bu durum, Şekil 17'de gösterilmektedir.

Şekil 17. EfficientNet Modelinde Bileşik Katsayı ile Ölçeklendirme



Kaynak: Tan ve Le, 2019


EfficientNet modeli, görüntüleri rastgele ölçekleyen bir standart sinir ağıları uygulamasına karşın bu ölçekleme işlemini önceden ayarlanmış bir parametre ile otomatikleştirmeyi öngören bir ESA mimarisi inşa etmektedir.

EfficientNet'in, ölçeklendirme ayarlamasından sonra en güçlü yanı ise ilk aşamada kullandıkları evrişim katmanından sonra hareketli ters darboğaz evrişim blokları (MBConv)'nı kullanmasıdır. MBConv katmanı, donanım kaynaklarını daha az kullanmak ve evrişim işlemlerindeki parametre sayısını azaltmak için geliştirilmiştir (Ebenezer vd., 2022). Bu sayede daha etkili işlemler çok daha az kaynakla yapılabilir.

MBConv blokları, ilk aşamada 1x1'lik bir evrişim ile görüntünün kanallarını genişletir. Sonrasında onu 1x1'lik bir evrişim ile tekrar eski haline getirir. Bu darboğaz işlemi sayesinde hem temsil gücü korunur hem de öğrenme işlemi daha verimli hale gelir (Zheng vd., 2023).

Şekil 18'de EfficientNet modelinde kullanılan temel mimari gösterilmektedir.

Şekil 18. EfficientNet Mimarisi



Kaynak: Ahmed ve Sabab, 2022

EfficientNet modellerinde B0'dan B7'ye kadar, her bir versiyonda parametre sayısı ve hesaplama maliyeti artar. Bu sekiz modelin tamamı da EfficientNet olarak adlandırılır.

3.4.5. MobileNetv2

MobileNet, Howard vd. (2017) tarafından geliştirilen düşük güç tüketimi ve daha az işlemci kaynağı kullanan, diğer birçok derin öğrenme modeline göre daha “hafif” sayılacak bir ESA modelidir.

MobileNet, klasik evrişim katmanları yerine derinlemesine ayrılabilir evrişim yapısı kullanması itibari ile diğer modellerden çok daha az ağırlık ile sınıflandırma, görüntü tanıma vb. görevleri yerine getirebilir.


Derinlemesine ayrılabilir evrişim, iki katmandan oluşan bir yapıdır. Bunlar: derinlemesine evrişim ve noktasal evrişim katmanlarıdır. İlk olarak derinlemesine evrişim katmanında görüntünün her bir giriş kanalı için ayrı bir evrişim filtresi uygulanır. Yani 3x3'lük bir evrişim işlemi gerçekleştirilir. Bu sayede, ağırlık sayısı azaltılır ve hesaplama maliyeti de en aza indirgenir. Daha sonra noktasal evrişim katmanında her bir öznitelik haritasındaki pikseller için ayrı ayrı 1x1'lik evrişim işlemi uygulanır. Bu işlem ile hem kanallara arasındaki bilgiler birbirine karıştırılır hem de öznitelik haritasının boyutu ayarlanır (Sae-Lim vd., 2019; Sinha ve El-Sharkawy, 2019). Derinlemesine ayrılabilir evrişim sayesinde klasik evrişim katmanlarının aksine çok daha az ağırlıklar ve daha düşük güç tüketimi ile başarılı sonuçlar elde edilebilir. MobileNet'in kullandığı derinlemesine ayrılabilir evrişim katmanı ile klasik evrişim katmanının arasındaki en önemli fark, MobileNet'in evrişim işlemini ikiye ayırarak, evrişimi 3x3'lük derinlemesine evrişim katmanı ve 1x1'lik noktasal evrişim katmanı olarak iki ayırmasıdır.

MobileNetv2 modeli, Sandler vd. (2018) tarafından MobileNet modelinin güncellenmiş ve bir dizi yenilik getirilmiş versiyonudur. MobileNetv2 modeli ile gelen en önemli iki yeni özellik ters çevrilmiş artık bloklar ve doğrusal darboğazlar yapısıdır.

MobileNet modelinde görüntüye ilk evrişim katmanı olan derinlemesine evrişimde 3x3'lük evrişim ve ikinci evrişim katmanı olan noktasal evrişimde (evr) de 1x1'lik evrişim uygulanıp ReLU6 aktivasyon fonksiyonundan geçirilmektedir. ReLU6'nın ReLU aktivasyon fonksiyonuna göre farkı 0 ile 6 arasındaki değerleri almasıdır. Yani aktivasyon 0 ile 6 arasında olduğu sürece doğrusaldır.

MobileNet ile MobileNetv2 arasındaki mimari fark, Şekil 19'da gösterilmektedir.

Şekil 19. MobileNet ve MobileNetv2 Arasındaki Mimari Farklar



Kaynak: Sandler vd., 2018

Şekil 19’da verilen “adım” parametresi filtre matrisinin evrişim işleminde kaç piksel kaydırılacağını belirler.

MobileNetv2 modelinde ise girdi görüntüsü ilk olarak 1x1’lik evrişim işleminden geçirilir. Bu durum MobileNetv2 ile gelen ters çevrilmiş artık blok olarak adlandırılır. Bu yapı ile öznetelik haritası genişletilir ve modelin derinliği artırılır. Bu sayede daha fazla öznetelik çıkarılır ve model daha fazla bilgiyi temsil edebilir. Sonraki iki katman, MobileNet modelindeki ile aynıdır. Ayrıca bu durumun tam tersi de söz konusudur. Önce 1x1 ile öznetelik haritası sıkıştırılır sonra 3x3 evrişim ile genişletilir ve sonraki 1x1 evrişim ile tekrar bir sıkıştırma işlemi yapılır. Bu durum, ters çevrilmiş artık blok yapısını ortaya koymaktadır (Sandler vd., 2018).

Doğrusal darboğazlar, MobileNetv2 modelindeki ardışık evrişim işlemlerinin yapılmasına olanak sağlayan ve bu evrişim işlemin çıktısının sıkıştırılarak modelin daha az parametreye ve daha güçlü genelleme yapma yeteneğine sahip olmasını sağlayan bir kavramdır. Şekil 19’da MobileNetv2 modelindeki en üstteki katman olan “ekle” katmanı, atlama bağlantılarının bağlandığı ve sıkıştırıldığı katmandır. Tüm bu işlemler, MobileNetv2 modelinde doğrusal darboğaz yapısının işleyişini göstermektedir (Zhang vd., 2022).

3.4.6. DenseNet121


DenseNet, Türkçede Yoğun Bağlı Evrişimsel Ağlar anlamına gelmektedir. Huang vd. (2017) tarafından geliştirilmiş bir ESA modelidir.

DenseNet, katmanlar arasındaki bilgi akışının ilk katmandan son katmana kadar sırayla olması fikrine karşın, her katmanın kendinden sonraki tüm katmanlara öğrendiği bilgiyi yani gradyanı aktarması fikrini savunmaktadır. DenseNet mimarisindeki evrişim katmanları arasındaki bilgi akışı ne normal evrişim modellerindeki gibi yukarıdan aşağıya sıralı bir şekildedir ne de ResNet ana modelindeki gibi her iki katmanda bir atlama bağlantısı ile sonraki katmana gradyan aktarılması şeklindedir.

DenseNet, modellerin derinliği arttığında yaşanacak bir bilgi kaybının yani gradyan kaybının önüne geçebilmek için katmanlar arasındaki bilgi akışının birbirini takip eden katmanlar arasında sıralı bir şekilde sağlanması yerine, her katmanın öğrendiği bilgiyi kendinden sonraki tüm katmanlara olduğu gibi aktarması düşüncesine öncelik vermektedir. Bu sayede daha fazla bağlantı, dolayısıyla daha yoğun bağlantılar meydana gelir.

Şekil 20’de DenseNet mimarisindeki katmanlar arası bilgi akışı verilmektedir.

Şekil 20. DenseNet Modelinde 5 Katmanlı Dense Blok Yapısı



Kaynak: Huang vd., (2017)

DenseNet modelinde Şekil 20’deki gibi tam aktarmalı ve yoğun öğrenme yapısı, yoğun bağlantılar olarak adlandırılmaktadır. Yoğun bağlantı yapısını sağlayan ve birlikte kullanılan katmanlar da yoğun bloklar olarak tanımlanmaktadır. Yoğun blok mimarisinin sonunda ise filtrelerden öğrenilen ve çıkarılan öznetelik haritasının boyutunu azaltmaya

yarayan geiř katmanı yapısı mevcuttur. Geiř katmanı ile znitelik haritasının boyutu azaltılarak derinlik artışı kontrol altında tutulur. Bu durum, modelin ğrenmesini daha etkili ve hızlı yapar (Huang vd., 2017).

DenseNet ana modelinin bu kadar ok baėlantısı olmasına raėmen geleneksel evriřim modellerinden daha hızlı olmasının nedeni, bu baėlantılar ve aktarım sayesinde bir sonraki katmanın yapacaėı iřin daha az olmasından kaynaklanır.

DenseNet121 modeli, DenseNet ana modelinin 121 katmanlı yapısıdır.

3.5. Sınıflandırıcılar

alıřmada kullanılan modeller ile znitelik haritaları elde edildikten sonra bunların ikili bir řekilde (kanser-kanser deėil vb.) sınıflandırılması iin literatürdeki nemli sınıflandırma modelleri kullanılmıřtır.

3.5.1. Destek Vektör Makinesi

DVM, sınıflandırma ve regresyon grevleri iin geliřtirilmiř olan denetimli makine ğrenmesi algoritmalarıdır. Sınıflandırmada DVM'nin iřlevi, veriler arasında en uygun ayırım noktasını bulup onları en az sınıflandırma hatası ile sınıflandırmaktır (Prajapati ve Patle, 2010).

1990'lı yılların ortasındaki DVM felsefesi, Vapnik vd. (1995) tarafından ortaya atılmıřtır. Buna gre DVM, YSA modellerinin bir matematiksel uzantısı olarak kabul edilmektedir. DVM, doėrusal ya da doėrusal olmayan verileri ok boyutlu uzaya dnüştürp daha yksek boyutlarda bir hiper dzlem (sınıfları ayıran sınır) yapısı meydana getirerek sınıflandırma grevini gerekleřtirir. Bu aıdan dřnldėnde, DVM bir optimal hiper dzlem arayışında olan matematiksel bir model olarak tanımlanabilir (Ghosh vd., 2019).

DVM, giriř vektrn yksek boyutlu bir uzaya eřlemeden nce ayırma iřini maksimuma ıkaracak bir hiper dzlem oluřturur. Daha sonra bu hiper dzeleme paralel biimde iki hiper dzlem daha oluřturur. Burada ama, ortada kalan ve ilk bařta oluřturulan ana hiper dzlemdeki kenar bořluėunu en yksek seviyeye ıkarmaktır. Bu sayede DVM, ok daha dřk sınıflandırma hatası altında genelleme yapabilir (Sheykhmousa vd., 2020).

Veriler arasında bir hiper düzlemin oluşturulması için N adet, $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ veri noktasından oluşan eğitim verilerinde; $y_n = \{1, -1\}$ değerlerine karşılık gelen ikili sınıf etiketi, n örnek sayısı ve her x_n p boyutlu bir vektör, yani girdi verileridir.

Verilerin, hiper düzlem aracılığıyla görüntülenebilmesi yani verilerin ayrılabilmesi için Denklem 17'deki eşitlik kullanılır.

$$w \cdot x + b = 0 \quad (17)$$

Burada, w p boyutlu vektör ve b bir skalerdir. w vektörü, hiper düzleme dik olup, b skalerinin eklenmesi de kenar boşluğunu artırmaya yöneliktir. Çünkü, b skalerinin olmadığı bir senaryoda hiper düzlem orijinden geçmeye zorlanır ki bu durum kenar boşluğunun kısıtlanmasına ve daraltılmasına neden olur. Maksimum kenar boşluğu elde edilmesi için hiper düzleme paralel hiper düzlemler çizilmesi de gereklidir. Bunlar Denklem 18-19'da verilmektedir.

$$w \cdot x + b = +1 \quad (18)$$

$$w \cdot x + b = -1 \quad (19)$$

Eğer veriler doğrusal bir şekilde ayrılabilirse, oluşturulacak paralel hiper düzlemler rahatça seçilebilir ve kenar boşluğu da maksimum seviyeye çıkarılabilir. Hiper düzlem arasındaki mesafe $2/|w|$ olarak hesaplanır. Bu durumda $|w|$ değeri minimize edilmelidir (Chandra ve Bedi, 2021). Bunun için, hiper düzlemin Denklem 20-21'deki eşitsizlikleri yerine getirmesi gerekir.

$$w \cdot x_i + b \geq +1 \text{ eğer } y_i = +1 \quad (20)$$


$$w \cdot x_i + b < -1 \text{ eğer } y_i = -1 \quad (21)$$

Denklem 20-21'deki eşitsizlikler Denklem 22'deki gibi yazılabilir.

$$y_i(w \cdot x_i + b) \geq +1, i = 1, 2, \dots, N \quad (22)$$

Şekil 21'de DVM'de hiper düzlem çizilmesine ve sınıfların ayrılmasına dair bir örnek verilmektedir.


Şekil 21. DVM ile Hiper Düzlem Çizilmesi ve Sınıfların Ayrılması



Şekil 21’de, paralel hiper düzlemlerin üzerine denk gelen ya da ona en yakın ona veriler destek vektörleri olarak adlandırılır. Destek vektörleri, kenar boşluklarının hesaplanmasında karar sınırını belirleyen önemli bileşenlerdir. Yine Şekil 21’de görüldüğü gibi yanlış sınıflandırılmış bir veri de bulunmaktadır. Bu durum, DVM yapısı içerisinde yumuşak kenar boşluğu ayarlama olarak adlandırılır. Yumuşak kenar boşluğu, kenar boşluğunun geniş tutularak bazı verilerin yanlış hesaplanmasına olanak sağlayan bir kavramdır. Bu sayede hem kenar boşluğu dar tutulmaz hem de aşırı öğrenmenin yani verileri öğrenmek yerine onları ezberleme sorununun önüne geçilmiş olunur (Hekmatmanesh vd., 2020).

DVM sınıflandırıcısının son adımı ise gerçekte tek boyutlu olsa bile, verilerin çok boyutlu uzaya taşınmasını sağlayan çekirdek fonksiyonunun uygulandığı adımdır. Çekirdek fonksiyon, bir nevi matematiksel bir hile işlevi görerek verilerin daha yüksek boyutlu bir uzaya yansıtılmasını sağlar. Şekil 22’de DVM sisteminde çekirdek fonksiyonun verileri nasıl eşlediğine dair bir örnek gösterilmektedir.

Şekil 22. DVM’de Çekirdek Fonksiyonu Eşlemesi a) Doğrusal Olarak Ayrılamayan Veriler, b) Doğrusal Olarak Ayrılabilir Veriler



Şekil 22’de verilen ve tek boyutlu verileri 2B uzaya taşımak için kullanılan ϕ simgesi, çekirdek fonksiyonu temsil eder ve çekirdek fonksiyonu ($K(x_1, x_2)$) genellikle Denklem 23’teki gibi gösterilir.

$$\langle x_1 \cdot x_2 \rangle \leftarrow K(x_1, x_2) = \langle \phi(x_1) \cdot \phi(x_2) \rangle \quad (23)$$

Genel olarak DVM’de kullanılan dört farklı çekirdek fonksiyonu bulunmaktadır.

Denklem 24-27’de sırasıyla doğrusal çekirdek, polinomsal çekirdek, radyal temelli çekirdek ve sigmoid çekirdek fonksiyonlarına ait eşitlikler verilmektedir (Chandra ve Bedi, 2021; Prajapati ve Patle, 2010).

$$K(x, x_i) = x \cdot x^T \quad (24)$$

Denklem 24’te verilen x^T , girdi matrisi olan x ’in transpozudur.

$$K(x, x_i) = (1 + x \cdot x_i^T)^d \quad (25)$$

Denklem 25’te verilen polinomsal çekirdek fonksiyonu, düşük boyutlu bir uzayda girdinin çıktıya bağımlı olduğu doğrusal olmayan durumlar için kullanılır; d polinomun derecesini belirtir.

$$K(x, x_i) = e^{-\gamma \|x - x_i\|^2} \quad (26)$$

Denklem 26’da verilen radyal temelli çekirdek fonksiyonu, en sık kullanılan fonksiyonlardan olup, γ parametresi çekirdeğin yayılmasını ayarlamak için kullanılır ve 0’dan büyüktür.

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + c) \quad (27)$$

Denklem 27’de verilen sigmoid çekirdek fonksiyonu, hiperbolik tanjant fonksiyonu olup, γ ve c çekirdek parametreleridir.

DVM’deki çekirdek fonksiyonları farklı veri setleri için sınırlı olduklarından dolayı, ele alınan soruna uygun çekirdek fonksiyonları tercih edilmektedir.

3.5.2. Rassal Orman

Sınıflandırma ve regresyon problemleri için geliştirilmiş bir makine öğrenmesi algoritması olan RO, bir başka makine öğrenme algoritması olan Karar Ağaçları (KA) modelinin bir topluluk yöntemi olarak çalışır (Shaikhina vd., 2019).

KA, veri setinin özelliklerini göre karar veren bir ağaç yapısı oluşturur. Bu yapıda ilk düğüm, kök düğüm olarak başlar ve tüm veri seti bu kök düğümde temsil edilir. Daha sonra veri setindeki özellikleri temsil eden alt düğümler oluşturulur ve bu sayede özellikler bölünebildiği kadar alt düğümlere bölünür. Yaprak düğümler, KA modelinin en ucunda yani sonunda yer alır ve buralarda sonuçları temsil eden çıktı değerleri bulunur. Yaprak düğümler, veri setinin alt sınırına ulaşıldığı zaman hangi sınıfın ya da hangi regresyon tahmininin verileceğini belirtmek için kullanılır (Song ve Ying, 2015).

RO, birden fazla KA yapısını kullanan bir topluluk mantığına göre çalışır. Buna göre, eğitim verisi içerisinde rastgele bir şekilde veriler seçilerek farklı KA yapıları oluşturulur. Bu işlem, rastgele örneklem seçimi olarak (boosting) adlandırılır. Daha sonra veri setinin öz niteliklerinden bazıları da rastgele bir şekilde seçilerek, oluşturulmuş olan farklı KA modellerinin öz niteliklere göre alt dallara bölünmesi için kullanılır. Bu işleme de rastgele özellik seçimi adı verilir. Bu sayede, her ağaç grubunun farklı öz nitelikleri tahmin etmeye çalışmasıyla birlikte özgün ve güçlü bir model elde edilmeye çalışılır. Sınıflandırma problemleri için sonuç tahmini yapılacağı zaman farklı ağaçların tahminleri karşılaştırılır ve oylama yöntemi ile en iyi sonucu veren ağacın tahmini kabul edilir (Amini ve Shalbaf, 2022).

3.5.3. K-En Yakın Komşu

K-EYK, bir veri noktasını etiketlemek ya da tahmin üretmek için çevresindeki “k” adet en yakın komşuyu kullanma prensibine göre geliştirilmiş bir makine öğrenmesi algoritmasıdır.

K-EYK, verilerin özniteliklerine ait farkları hesaplayarak buna göre onlar arasındaki mesafeyi bulur ve verileri bu şekilde konumlandırır. K-EYK yönteminde, veri noktaları arasındaki benzerlik ya da uzaklık hesaplanırken genellikle Manhattan uzaklığı (MU) ya da Öklid uzaklığı (ÖU) gibi metrikler kullanılır (Uddin vd., 2022).

Denklem 28-29’da sırasıyla MU ve ÖU metrikleri verilmektedir.

$$MU(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (28)$$

$$\text{ÖU}(x, y) = \sqrt{\sum_{i=1}^n |x_i - y_i|^2} \quad (29)$$

Denklem 28-29’da verilen x ve y , birbirleri arasındaki yakınlık ölçülmek istenen farklı öznitelikleri temsil eden vektörlerdir.

K-EYK algoritmasındaki en önemli parametrelerden biri de “ k ” değeridir. Bu değer, komşuların sayısını ifade etmektedir. Bu değer belirlenmesinde deneme-yanılma yöntemi kullanılacağı gibi çapraz doğrulama yöntemi de kullanılabilir. Küçük bir “ k ” değeri, değişkenlik açısından modeli daha hassas bir hale getirebileceği gibi, büyük bir “ k ” değeri de modeli daha genelleştirilebilir bir hale getirip ayrıntılara dikkat edilmesinin önüne geçer (Abu Alfeilat vd., 2019).

Yeni bir değere ait etiket ya da tahmin öğrenmek istenildiğinde, veri noktasında yer alan “ k ” adet komşu bulunduktan sonra bunlar incelenir ve bu yeni verinin ait olduğu etiket ya da tahmin edilen değeri belirlenir.

3.5.4. XGBoost

XGBoost, Chen ve Guestrin (2016) tarafından geliştirilen Gradient Boosting (GB) tabanlı bir makine öğrenmesi algoritmasıdır. GB, verilerin eğitilmesi aşamasında karar ağaçları ile zayıf tahminleyiciler isimli bir yapı oluşturur ve ilk tahmini gerçekleştirir. İlk tahmin, sınıflandırma görevinde baskın olan etiket veya regresyon görevinde ortalama değerdir. Daha sonra gerçek çıktı ile tahmini karşılaştırır ve hatayı hesaplar. Sonrasında ikinci bir karar ağacı oluşturup hatayı minimize etmeye çalışır ve bunları tekrar tekrar dener (Gumus ve Kiran, 2017).

XGBoost yönteminde her ağaç oluşturulduktan sonra bir araya getirilir ve bunlara bir ağırlık değeri atanır. Atanan bu ağırlık değerleri ile toplam tahmin hesaplanır.

XGBoost, ilk aşamada $K_E^i | i \in 1 \dots K$ şeklindeki bir dizi K düğümüne sahip bir sınıflandırma ve regresyon ağaçları yapısı (CART) adı verilen bir ağaç topluluğu yöntemi kurar. CART yöntemi ile, sınıf etiketinin son çıktısı olan $\hat{y}_i$, her k'nıncı (k^{th}) ağaç için f_k yaprak düğümündeki toplam tahmin puanına bakılarak hesaplanır (Liew vd., 2021). Bu hesaplamaya ait formülasyon, Denklem 30'da verilmektedir.

$$\hat{y}_i = \varphi(x_i) = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (30)$$

Denklem 30'da verilen; x_i eğitim seti, F bütün CART'lara ait K puanlarını temsil etmektedir.

Bu hesaplamadan sonra, sonuçların iyileştirilmesi için Denklem 31'deki düzenleme işlemi uygulanır.

$$\mathcal{L}(\varphi) = \sum_i \ell(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (31)$$

Denklem 31'deki kayıp fonksiyonu olan ℓ sayesinde gerçek etiket değerleri (y_i) ile tahmin edilen değerler ($\hat{y}_i$) arasındaki fark hesaplanır. Aşırı uydurma sorunu için model karmaşıklığı üzerine bir cezalandırma puanı (Ω) eklenir. Denklem 32'de cezalandırma fonksiyonu verilmektedir.

$$\Omega(f) = y^T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (32)$$

Denklem 32'de verilen; y ve λ parametreleri, düzenleme derecesinin kontrolünü sağlayan yapılandırılabilir parametrelerdir, T ağaç yapısındaki yapraklara karşılık gelir ve w tüm yaprakların ağırlık değerlerini tutar.

Denklem 33'te, bu aşamadan sonra yer alan sınıflandırma probleminin çözümü için kayıp fonksiyonuyla beraber GB yönteminin uygulanmasına dair formülasyon verilmektedir. Bu işlem esnasında optimizasyon, Taylor genişlemesi ile genişletilir ve bir amaç elde edilebilmesi t adımı sabit terim kaldırılır.

$$\begin{aligned}
\tilde{\mathcal{L}} &= \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \\
&= \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + yT + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \\
&= \left[\sum_{j=1}^T \left(\sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + yT
\end{aligned} \tag{33}$$

Denklem 33'te verilen $I_j = \{i | q(x_i) = j\}$ t yaprağının örneğini ifade eder. Ayrıca, birinci adım kayıp fonksiyonu g_i ve ikinci adım kayıp fonksiyonu h_i için gradyan istatistikleri sırasıyla Denklem 34-35'te verilmektedir.

$$g_i = \frac{\partial \ell(\hat{y}_i^{(t-1)}, y_i)}{\partial \hat{y}_i^{(t-1)}} \tag{34}$$

$$h_i = \frac{\partial^2 \ell(\hat{y}_i^{(t-1)}, y_i)}{\partial (\hat{y}_i^{(t-1)})^2} \tag{35}$$

Denklem 36'da j yaprağına ait en uygun ağırlık olan w_j^* ağırlığının hesaplanmasına dair formülasyon verilmektedir.

$$w_j^* = \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \tag{36}$$

Denklem 37'de bir ağaç yapısı olan q 'nın kalitesini ölçmeye yarayan ve bir puanlama fonksiyonu olan $q(x_i)$ fonksiyonunun hesaplanmasına dair formülasyon verilmektedir.

$$\tilde{\mathcal{L}}^{(t)}(q) = -\frac{1}{2} \sum_{j=1}^T T \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} + yT \tag{37}$$

Klasik bir şekilde, düğümler arasında bölme işlemi yapıldıktan sonra düğümler sol (I_L) ve sağ (I_R) olarak ayrılır. Bu bölünmüş düğümlerin örnek kümesinde puanlama uygulanıp düğümleri ölçmeye yarayan kayıp azaltılmasına dair formülasyon Denklem 38'de verilmektedir.

$$\mathcal{L}_{bölme} = \frac{1}{2} \left[\frac{(\sum_{i \in I_L} g_i)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} + \frac{(\sum_{i \in I} g_i)^2}{\sum_{i \in I} h_i + \lambda} \right] - y \quad (38)$$

Denklem 38’de verilen I , sağ ve sol düğümlerin birleşimidir ($I = I_L + I_R$) (Liew vd., 2021).

3.5.5. İki Katmanlı Yapay Sinir Ağı

Çalışmada kullanılan son sınıflandırıcı ise 2 katmanlı YSA sınıflandırıcısıdır. Transfer öğrenme yöntemi ile önceden eğitilmiş modellerin öznitelik çıkarma işleminde kullanılan katmanları dondurulur. YSA sınıflandırıcısına gelindiğinde ilk katmanda öznitelikler düzleştirilir ve ikinci katmanda da 2 nöronlu bir sınıflandırma işlemi yapılır.

3.6. Optimizasyon Yöntemleri

Optimizasyon, mevcut parametreler ile amaç fonksiyonu için en uygun sonucun elde edilmesini sağlar. Bu durum, eldeki tüm seçeneklerin manuel bir şekilde tek tek denenerek yapılacağı gibi rastgele, sezgisel şekilde bu parametrelerin eşleştirilmesi ile de olabilir.

Bu çalışmada, manuel yöntem olarak IA, sezgisel yöntem olarak da DE ve PSO algoritmaları kullanılmıştır.

3.6.1. Izgara Arama

IA, var olan bütün parametrelerin birbiri ile tek tek eşlenmesi yöntemidir.

Bu yöntem, zaman açısından oldukça maliyetli olmasına karşın mevcut ihtimallerin tamamını kullanması açısından, var olan en iyi sonucun bulunmasını sağlamaktadır.

3.6.2. Sezgisel Optimizasyon

Sezgisel optimizasyon, insan düşünme yeteneği ya da doğal süreçleri taklit ederek karmaşık problemleri çözüme kavuşturan bir yaklaşımdır (Shao vd., 2014). Bu çalışmada DE ve PSO olmak üzere iki farklı sezgisel optimizasyon algoritması kullanılmıştır.

3.6.2.1. Diferansiyel Evrim

DE, popülasyon tabanlı ve N_p bireylerden oluşan bir sezgisel optimizasyon yöntemidir. DE yapısı içerisinde her bir birey, problemin çözümüne potansiyel bir adaydır (Wang vd., 2022).

Bireyler, bir araya gelip oluşturdukları popülasyon içerisinde $V_{i,n}$ vektörü ile ifade edilir. Burada kullanılan i indeks numarası olup ($i = 1,2,3,..., N_p$), n neslin indeksine karşılık gelmektedir. DE, ardışık bir şekilde işleyen mutasyon, çaprazlama ve seçim olmak üzere üç temel işlevden oluşmaktadır (Chakraborty vd., 2023).

Mutasyon, her bir bireyin üç farklı rastgele seçilmiş bireyden sağlanan fark vektörü ile genetik olarak çeşitliliği sağlamak için yapılan işlemidir. Seçilen üç birey arasından ikisinin farkı, üçüncü bireye eklenerek mutant birey meydana getirilir. Bu işlem Denklem 39'da verilmektedir.

$$MV_{i,n} = V_{r1,n} + F \times (V_{r2,n} - V_{r3,n}) \quad (39)$$

Denklem 39'da verilen; $MV_{i,n}$ mutant vektör, i vektörün indeksi, n nesil, $r1, r2, r3 \in \{1,2,3,..., N_p\}$ olmak üzere, mutant vektör oluşturmak için rastgele seçilmiş üç birey, F ise $[0,2]$ aralığındaki ölçeklendirme faktörüdür.

Çaprazlama aşamasında, mutasyon aşamasında elde edilen mutant vektör ile gerçek popülasyondaki her bir bireyin genleri birleştirilir. Bu işlemde elde edilen vektörlere deneme vektörü denir. Bu işlemde kullanılan hesaplamaya ait formülasyon Denklem 40'da verilmektedir.

$$DV_{i,n}[j] = \begin{cases} MV_{i,n}[j] & \text{eğer } \text{rastgele}[0,1] < CR \text{ ya da } j = j_{\text{rastgele}} \\ V_{i,n}[j] & \text{değilse} \end{cases} \quad (40)$$

Denklem 40'da verilen; $DV_{i,n}$ deneme vektörünü, j bir vektördeki her parametreyi temsil etmektedir. j_{rastgele} deneme vektörüne mutant vektörden en az bir parametre geçmesini sağlamak için 1 ile N_p arasında rastgele bir şekilde seçilmiş bir tamsayı değeri, CR ise çaprazlama işleminin ne sıklıkla yapılacağını belirleyen çaprazlama oranıdır. Çaprazlama oranı ne kadar büyük olursa, çaprazlama işlemi o kadar sık yapılır. Dolayısıyla mutant vektör daha fazla sayıda bireyin genine etki eder (Lean ve Xiong, 2014).

Seilim ařaması ise mevcut vektör ile deneme vektörünün karşılaştırıldığı ve daha iyi bir uygunluk değeriine sahip olan vektörün popölasyonun üyesi olarak hayatta kaldığı bir ařamadır. Denklem 41’de maksimizasyonu amaçlayan bir ortamda seilim işlemeine dair formölasyon verilmektedir.

$$V_{i,n+1} = \begin{cases} DV_{i,n}[j] & \text{eğer } f(DV_{i,n}) > f(V_{i,n}) \\ V_{i,n}[j] & \text{değilse} \end{cases} \quad (41)$$

Denklem 41’de verilen; $DV_{i,n}$ deneme vektörü, $V_{i,n}$ popölasyon içerisindeki bir birey, $V_{i,n+1}$ bir sonraki nesilde yer alacak olan birey, $f(DV_{i,n})$ deneme vektörüne ait uygunluk değeri, $f(V_{i,n})$ ise popölasyon içerisindeki bireye ait uygunluk değeriine karşılık gelmektedir.

DE algoritması, amaç fonksiyonu için istenilen sonuç elde edilene kadar tüm bu işlemleri tekrarlar.

3.6.2.2. Parçacık Sürü Optimizasyonu

PSO, kuş sürülerinin yiyecek arayışının bir modellenmesi olarak Kennedy ve Eberhart (1995) tarafından geliştirilen popölasyon temelli bir optimizasyon algoritmasıdır (Junior ve Yen, 2019).

PSO yapısında bireylerin bir araya gelmesiyle oluşan parçacıklar arama uzayında en iyi çözümü bulmak için bir iş birliği göstererek çalışırlar. Bu parçacıkların her biri en iyi çözümün potansiyel bir adayıdır. PSO, amaç fonksiyonunu minimize ya da maksimize etmeye yarayan bir optimizasyon yöntemidir.

Parçacıkların konumları, hem geçmişteki konumlarından yani kendi tecrübelerinden hem de komşu parçacıkların konumlarından yani komşu parçacıkların geçmişteki konumlarından etkilenir. Eğer bir parçacığın komşusu tüm parçacıklar ise bu durum için PSO sistemi içerisinde global en iyi anlamına gelen “gbest” ifadesi kullanılır. Eğer bir parçacığın komşuları daha yerel ve daha sınırlı komşular ise bu durum için de yerel en iyi anlamına gelen “lbest” ifadesi kullanılır. PSO’da konum, amaç fonksiyonunu yerine getirmek için parçacıkların skorları için kullanılır ve en iyi çözüme ulaşmada oldukça önemlidir (Engelbrecht, 2013).

PSO sistemindeki her bir parçacık; parçacığın mevcut konumu (x_i), parçacığın mevcut hızı (v_i) ve parçacığın kişisel en iyi konumu (y_i) gibi üç temel özellik ile temsil edilmektedir (Omran vd., 2006).

Denklem 42’de, i parçacığının kişisel en iyi konumunun i parçacığının şu ana değin ziyaret ettiği en iyi konum, f değerinin amaç fonksiyonu olduğu bir durumda t zaman adımında bir parçacığının kişisel en iyi konumunun nasıl güncellendiği verilmektedir.

$$y_i(t+1) = \begin{cases} y_i(t) & \text{eğer } f(x_i(t+1)) \geq f(y_i(t)) \\ x_i(t+1) & \text{eğer } f(x_i(t+1)) < f(y_i(t)) \end{cases} \quad (42)$$

Eğer global en iyi parçacığın konumu $\hat{y}$ vektörü ile ifade ediliyorsa, bu durumda Denklem 43’teki formülasyon kullanılır.

$$\hat{y}(t) \in \{y_0, y_1, \dots, y_s\} = \min \{f(y_0(t)), f(y_1(t)), \dots, f(y_s(t))\} \quad (43)$$

Denklem 43’te verilen s , sürünün kendisini temsil etmekte olup, min ifadesi ise en düşük anlamına gelmektedir.

PSO sistemi içerisinde lbest modelinde ise bir sürü, parçacıkların birbiri ile örtüşen yerelliklerine yani mahallelerine bölünür. Böyle bir durumda N_j olarak adlandırılan her bir komşuluk için en iyi parçacık, $\hat{y}_j$ konumu ile belirlenir. Belirlenen bu parçacık, mevcut komşuluğun en iyi parçacığı yani amaç fonksiyonu için yerel seviyede en iyi sonuca ulaşmış parçacık olur ve Denklem 44’teki gibi tanımlanır (Omran, 2006).

$$\hat{y}_j(t+1) \in \{N_j | f(\hat{y}_j(t+1)) = \min \{f(\hat{y}_j(t))\}, \forall y_i \in N_j\} \quad (44)$$

Denklem 44’te verilen ve lbest PSO sistemi içerisinde komşuluğu ifade eden N_j ’ye dair eşitlik, Denklem 45’te verilmektedir.

$$N_j = \{y_{i-l}(t), y_{i-l+1}(t), \dots, y_{i-1}(t), y_i(t), y_{i+l}(t), \dots, y_{i+l-1}(t), y_{i+l}(t)\} \quad (45)$$

Denklem 45’te verilen lbest PSO’daki en iyi durumun elde edilmesinde kullanılan komşuluğun $l = s$ yani mahalle=sürü durumunda en iyinin bulunduğu durum olduğu görülmektedir.

PSO’daki her bir iterasyonda hız (v_i) güncellemesi, her bir j boyutu için belirtilir. Burada, $j \in 1, 2, \dots, N_d$ yani problemin boyutu kadardır. Bu nedenle $v_{i,j}$, i ’inci parçacığın

hız vektörünün j 'ninci elemanını ifade eder. Bu sayede, i parçacığının hızı Denklem 46'daki eşitlik kullanılarak güncellenir.

$$v_{i,j}(t+1) = wv_{i,j}(t) + c_1r_{1,j}(t)(y_{i,j}(t) - x_{i,j}(t)) + c_2r_{2,j}(t)(\hat{y}_{i,j}(t) - x_{i,j}(t)) \quad (46)$$

Denklem 46'da verilen; w ağırlık parametresini temsil eder ve bu parametre, parçacıkların geçmiş hızları ile mevcut hızları arasındaki dengeyi sağlar. Yüksek bir değer, ilgili parçacığın daha hızlı ilerlemesine ve daha fazla keşfetmesine olanak sağlarken, düşük bir değer de daima yerel bir alanda kalarak üretken olmamasına neden olur. r_1 ve r_2 değerleri ise 0-1 aralığında rastgele üretilen katsayılardır. Bunlarda, global en iyi ile yerel en iyi arasında parçacıkların nasıl hareket edeceklerini rastgele bir şekilde değiştirmek için kullanılır. c_1 ve c_2 katsayıları ise bilişsel ve sosyal katsayılar olup, parçacıkların geçmiş en iyi pozisyonları bilişsel ile global en iyi pozisyonlarını sosyal hangi ölçüde kullanacaklarını belirlemek için kullanılır. c_1 katsayısı, parçacığın kendi geçmiş en iyi pozisyonuna odaklanmasını sağlarken, c_2 katsayısı ise sürüdeki en iyi parçacığın konumuna odaklanmasını sağlar ki bu durum toplu bir hareket etmeyi gerektirir (Omran, 2006; Chopard vd., 2018).

Denklem 46'daki hız güncellemesinden sonra i parçacığının konumu olan x_i , Denklem 47'deki gibi güncellenir.

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (47)$$

PSO algoritmasında, hız güncellemesinin parçacığın mevcut konumuna eklenmesiyle birlikte devir tamamlanır.

3.7. Değerlendirme Metrikleri

Metrik, bir modelin performansını ölçmeye ve değerlendirmeye yarayan ölçütlerdir.

Sınıflandırma çalışmalarında kullanılan değerlendirme metrikleri genel olarak dört temel terime ait sonuçların işlenmesiyle oluşur. Bu terimler, gerçek çıktı verileri ile modelin tahmin etmiş olduğu verileri karşılamak için kullanılan Doğru Pozitif (DP), Yanlış Pozitif (YP), Doğru Negatif (DN) ve Yanlış Negatif (YN) terimleridir. Bu dört terim, karmaşıklık matrisi üzerinde gerçek ve tahmin edilmiş değerlerin birbiri ile eşleşip

eşlenmemesi durumuna göre yerleştirilir. Şekil 23'te karmaşıklık matrisine ait görünüm verilmektedir.

Şekil 23. Karmaşıklık Matrisi

		Tahmin Edilen Değerler	
		Negatif	Pozitif
Gerçek Değerler	Negatif	DN	YP
	Pozitif	YN	DP

Şekil 23'te verilen; DN, gerçekte negatif olan bir verinin negatif olarak tahmin edildiğini (örneğin, sağlıklı bir görüntünün sağlıklı bir görüntü olarak tahmin edilmesi); YN, gerçekte pozitif olan bir verinin negatif olarak tahmin edildiğini (kanserli bir görüntünün sağlıklı olarak tahmin edilmesi); DP, gerçekte pozitif olan bir verinin pozitif olarak tahmin edildiğini (kanserli bir görüntünün kanserli olarak tahmin edilmesi); YP, gerçekte negatif bir verinin pozitif olarak tahmin edildiğini (sağlıklı bir görüntünün kanserli olarak tahmin edilmesi) ifade etmektedir.

Sınıflandırma çalışmalarının başarısı, karmaşıklık matrisi üzerinde yer alan bu dört terimin kullanıldığı formüllerle ölçülür. Bu çalışmada performans değerlendirmesi için kullanılan doğruluk, duyarlılık, kesinlik, F1-skor, Cohen Kappa ve Alıcı İşletim Karakteristiği (ROC) eğrisi altında kalan alan (AUC) metrikleri kullanılmıştır.

Doğruluk, ölçümün gerçek veya standart değere ne kadar yakın olduğunu belirtir. Doğru tahmin edilen verilerin yüzdesini verir. Doğruluk metriği, Denklem 48'deki gibi tanımlanır.

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (48)$$

Duyarlılık, gerçek pozitif verilerin ne kadarının doğru bir şekilde tespit edildiğini, ne kadarının kaçırılmadığını ölçmeye yarar. Bu nedenle Doğru Pozitif Oranı (DPO) olarak da adlandırılır. Özellikle, YN verilerin yani gerçekte pozitif iken negatif olarak tahmin edilen verilerin önemli olduğu durumlarda kullanılır. Denklem 49'da Duyarlılık metriğine ait tanımlama verilmektedir.

$$Duyarluluk = \frac{DP}{DP + YN} \quad (49)$$

Kesinlik, pozitif olarak tahmin edilen verilerin ne kadarının gerçekte pozitif olduğunu ölçmeye yarar. Kesinlik metriği, YP verilerin yani gerçekte negatif iken pozitif olarak tahmin edilen durumların incelenmesinde kullanılır. Kesinlik metriği, Denklem 50'deki gibi tanımlanır.

$$Kesinlik = \frac{DP}{DP + YP} \quad (50)$$

F1-skor, sınıf etiketlerinin dengesiz bir dağılım gösterdiği durumlarda sıklıkla kullanılır. Hassaslık ve kesinlik metriklerinin bir birleşimidir. F1-skor, Denklem 51'deki gibi tanımlanır.

$$F1 - Skor = 2 \times \frac{Kesinlik \times Duyarluluk}{Kesinlik + Duyarluluk} \quad (51)$$

Cohen Kappa, yapılan sınıflandırmanın güvenilirliğini ölçer. Bir sınıflandırmadaki doğruluğun rastgele ya da uyum içinde başarılı bir sınıflandırma olup olmadığını ölçmeye yarar. Cohen Kappa metriği, gözlemlenen uyum ve beklenen uyum olarak adlandırılan iki temel bileşen kullanarak sınıflandırma sonucunu -1 ile 1 arasında sonuçlandırmaya yarar. 1'e yaklaştıkça uyum içinde başarılı sınıflandırma, 0'a yaklaştıkça rastgele sınıflandırma, 0'ın altına indiğinde ise zıt sınıflandırma yapıldığı anlamına gelir. Denklem 52'de Cohen Kappa metriğine ait tanımlama verilmektedir.

$$Cohen Kappa = \frac{P_o - P_e}{1 - P_e} \quad (52)$$

Denklem 52'de verilen, P_o gözlenen uyum P_e ise beklenen uyum kavramlarını temsil etmektedir.

AUC metriği, sınıflandırma modellerinin performansını grafiksel olarak gösteren ROC eğrisinin altında kalan alanı hesaplamak için kullanılır. AUC, DPO ve Yanlış Pozitif Oranı (YPO)'nın arasındaki performansı, eşik değerine göre ölçmeye yarar. AUC, modelin sınıflandırma yeteneğinin değerlendirilmesinde kullanılan genel bir ölçüttür. Denklem 53'te AUC metriğine ait tanımlama verilmektedir.

$$AUC \approx \sum_{i=1}^{n-1} \frac{1}{2} (DPO_i + DPO_{i+1}) \times (YPO_i + YPO_{i+1}) \quad (53)$$

Denklem 53'te verilen DPO, duyarlılık metriğidir. YPO ise Denklem 54'te tanımlanmaktadır.

$$YPO = \frac{YP}{YP + DN} \quad (54)$$

Wilcoxon İşaretli Sıra Testi (WİST), küçük örneklem boyutları ya da normallik varsayımının sağlanmadığı durumlarda sıralı veriler için kullanılan parametrik olmayan bir istatistiksel testtir. Bu testte işaret yönünün yanında farkların büyüklükleri de dikkate alındığından güçlü bir testtir. İstatistiksel testlerde tahmin değerleri ortalama aykırı değerlerden etkilendiği için bunun yerine tahmin değerlerini ikiye bölen medyan değeri daha doğru bilgi verir. Bu test ile medyanlar arasındaki farkın anlamlı olup olmadığı belirlenir.

WİST'te ilk olarak veriler küçükten büyüğe doğru sıralanır. Her bir çift gözlem için bir fark alınır ve bu farklar da sıralanır. Sıralanan her bir farka pozitif ya da negatif bir işaret verilir. Daha sonra, pozitif ve negatif farkların işaretleri kendi içlerinde bir sıra ile toplanır. Test istatistiğinin hesaplanması için bu fark toplamlarından en küçüğü seçilir. Eğer fark toplamı eşit ise test istatistiği sonucu sıfır olarak elde edilir. Eğer fark toplamı sıfır değilse belirli bir anlamlılık düzeyindeki kritik bir değerle karşılaştırılarak hipotez testi gerçekleştirilir. Hesaplanan test istatistiğinin kritik değerden küçük olması durumunda null hipotezi (H_0) reddedilir ve medyanlar arasındaki farkın anlamlı olduğu sonucuna varılır. Aksi durumda ise, farkın istatistiksel olarak anlamlı olmadığı (H_0) kabul edilir.

Bu çalışmada, DE algoritması ile 10 defa çalıştırılan veri setlerinden elde edilen 10 doğruluk skoru sonucuna WİST uygulanırken, kritik değer olarak $p < 0.05$ belirlenmiştir. Yani, %5 anlamlılık düzeyine göre sonuçlar test edilmiştir.

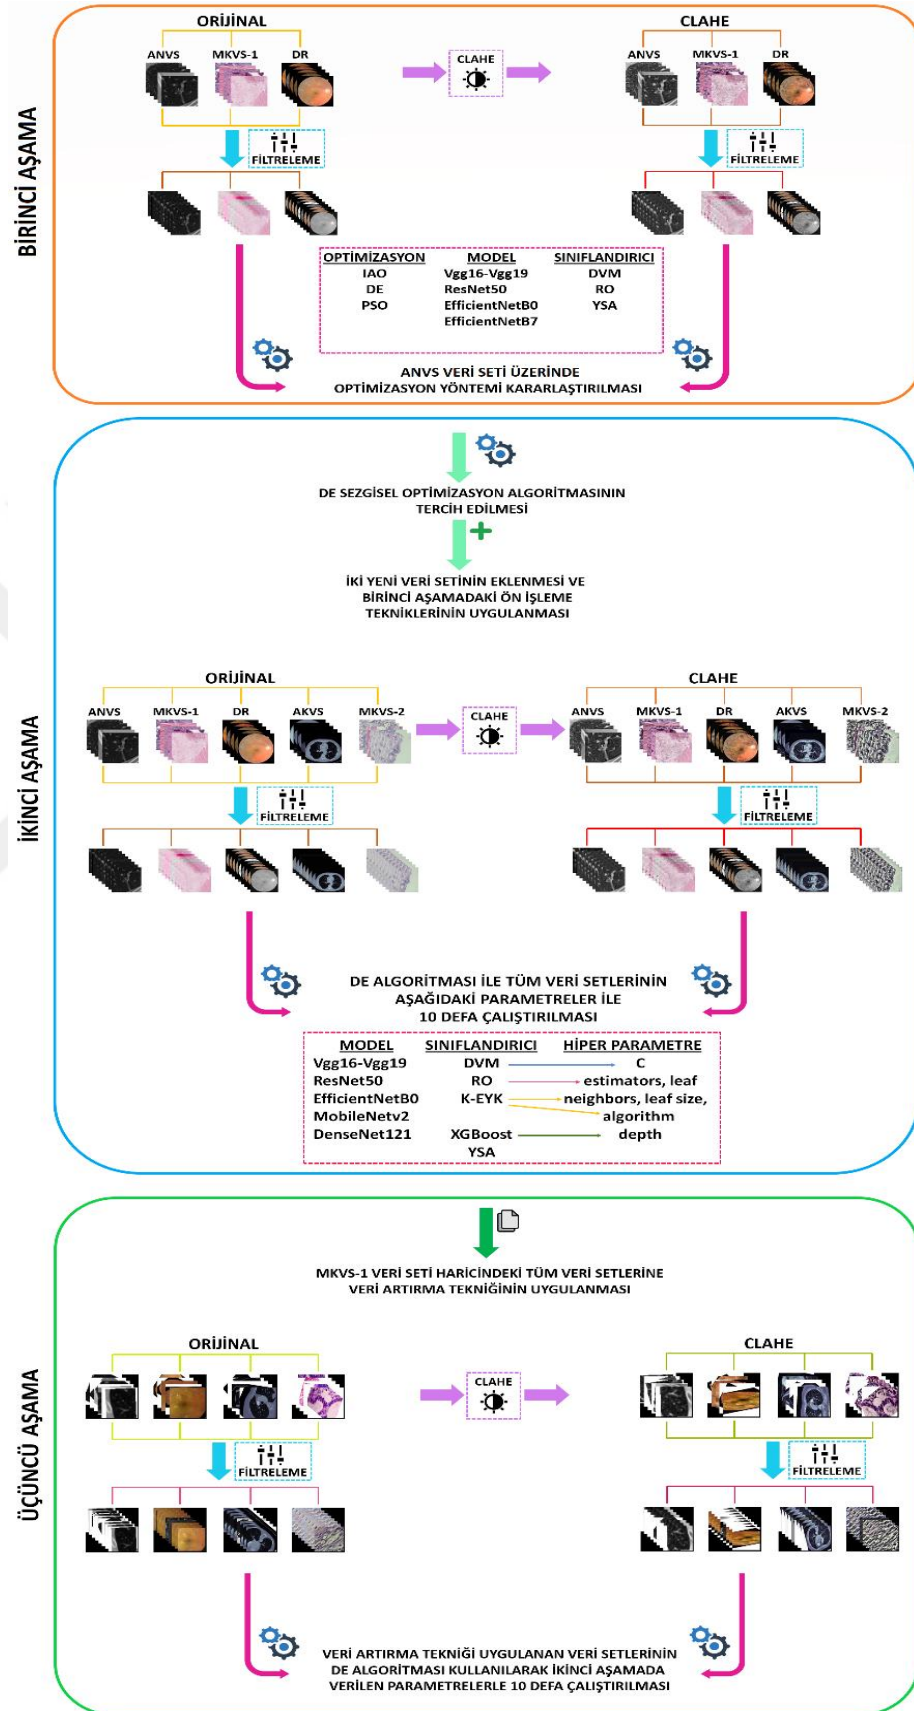
Ayrıca, sonuçların WİST ile test edilmesinde iki hipotez sınanmıştır.

H_0 : Sonuçlar ile medyan değerleri arasında anlamlı bir fark yoktur.

H_1 : Sonuçlar ile medyan değerleri arasında anlamlı bir fark vardır.

Fazla sayıda kullanılan parametrelere ait sonuçların çok sayıda metrikle ölçülmesi gerektiği düşünülmüştür. Şekil 24'te çalışmanın genel akışına dair görsel bir açıklama verilmektedir.

Şekil 24. Çalışmanın Genel Akışı



DÖRDÜNCÜ BÖLÜM

BULGULAR VE TARTIŞMA

Çalışmada elde edilen sonuçlar üç aşamada verilmekte olup, kullanılan parametrelerin ve hiper parametrelerin fazlalığından dolayı öncelikle bazı açıklamalarda bulunulması gerektiği faydalı görülmüştür.

Öncelikle, deneysel çalışmalarda hangi aşamada hangi parametrelerin ve hiper parametrelerin kullanıldığı bilgisi, çalışmanın önceki bölümlerinde (Şekil 24) verilmiştir. Dikkat edilecek olursa, hiper parametreler sadece sınıflandırıcılar için kullanılmıştır. Çalışmanın bu bölümünde hangi hiper parametrenin ne işe yaradığına dair bilgi, Tablo 2’de verilmektedir.

Tablo 2. Sınıflandırıcılara Ait Hiper Parametreler ve Açıklamaları

Sınıflandırıcı	Hiper Parametre	Açıklama
DVM	C	Hiper düzlem sınırı çizme ve aşırı uydurma arasındaki dengeyi sağlar
RO	estimators (n_estimators)	Oluşturulacak rastgele ağaç sayısıdır
	leaf (min_samples_leaf)	Aşırı uydurmayı kontrol etmeye yarar
K-EYK	neighbors (n_neighbors)	Tahmin yapılacağı zaman dikkate alınacak komşu sayısını belirtir
	algorithm	Komşu aramak için hangi algoritmanın kullanılacağını belirtir
	leaf size (leaf_size)	Veri kümesini daha küçük parçalara böler
XGBoost	depth (max_depth)	Aşırı uydurmayı kontrol etmeye yarar

Deneysel çalışmaların tamamı Python programlama dili ve onun kütüphaneleri kullanılarak gerçekleştirilmiştir. Özellikle, sınıflandırıcılar ve metrikler için scikit-learn (Scikit-learn, 2023) kütüphanesi kullanılmıştır. Tablo 2’de verilen hiper parametrelerin yanında parantez içinde yazan ifadeler, o hiper parametrenin kullanıldığı kütüphanedeki orijinal değerine karşılık gelmektedir.

İkinci olarak, özellikle sezgisel optimizasyon örneklerinin karşılaştırılması ve devamında tercih edilen DE algoritması ile amaç fonksiyonu olarak sınıflandırma başarısı için Doğruluk metriğinin maksimizasyonu amaçlanmıştır. Bütün parametreler ve onlara ait hiper parametrelerin en iyi kombinasyonu ile hedeflenen şey, Doğruluk metriğinin en yüksek skorunu elde etmektir.

Bu çalışmadaki bulguların elde edilmesinde, TÜRKİYE Bilimsel ve Teknolojik Araştırma Kurumu’na (TÜBİTAK) bağlı Türk Ulusal Bilim e-Altyapısı (TRUBA) (Truba, 2023) sisteminin sunmuş olduğu 384 GB bellek, 40 çekirdekli işlemci ve 16 GB Nvidia ekran kartı donanımları kullanılmıştır.

4.1. ANVS Üzerinde IA, DE ve PSO Yöntemlerine ait Sonuçlar

ANVS veri seti, Tablo 3’te verilen parametreler kullanılarak IA yöntemi ile 1 defa, DE ve PSO optimizasyon yöntemleri ile 10 defa çalıştırılmıştır.

Tablo 3. IA, DE ve PSO Yöntemlerinde Kullanılan Parametreler

Model	Sınıflandırıcı	Filtre
1. Vgg16 2. Vgg19 3. ResNet50 4. EfficientNetB0 5. EfficientNetB7	1. İki Katmanlı YSA (optimizer='Adam', learning_rate=0.001) 2. DVM (kernel ='linear') 3. RO (n_estimators=20)	1. AD 2. İKT 3. BM3D 4. Gauss 5. HM 6. Ortalama 7. TV 8. Dalgacık

Tablo 3’teki sınıflandırıcılar, parantez içerisinde verilen hiper parametreler ile kullanılmıştır. Filtreler ise, orijinal verilere uygulanan filtreleri (8 adet) ve CLAHE’li

verilere uygulanan filtreleri (8 adet) belirtir. Toplam 16 adet filtrelenmiş veri vardır. Ayrıca, filtre uygulanmamış orijinal veri ve filtre uygulanmamış CLAHE’li veriler de dahil edildiğinde $16+2=18$ adet farklı veri kullanılmıştır. Tüm bunlar göz önünde bulundurulduğunda bu bölümde yapılan deneysel çalışmalarda 5 model x 3 sınıflandırıcı x 18 veri türü = 270 farklı model kombinasyonu bulunmaktadır. IA yöntemi ile 270 farklı kombinasyonun tamamı çalıştırılmıştır. Her bir modelin elde ettiği en yüksek doğruluk skoru, bu skurun elde edilmesini sağlayan diğer parametreler ile Tablo 4’te verilmektedir. Bu modeller arasında elde edilen en yüksek skor ise koyu olarak belirtilmiştir.

Tablo 4. IA Yöntemi ile Her Bir Modele Ait En Yüksek Doğruluk Skoru

Model	Sınıflandırıcı	Veri Türü	Doğruluk Skoru
Vgg16	DVM	Orijinal-BM3D	0,8857
Vgg19	DVM	Orijinal	0,8865
ResNet50	RO	Orijinal-İKT	0,8678
EfficientNetB0	DVM	Orijinal-TV	0,8947
EfficientNetB7	DVM	CLAHE-Dalgacık	0,8424

Tablo 4’te verilen sonuçlar arasında en iyi sonucu 0,8947 doğruluk skoru ile EfficientnetB0 modeli, DVM sınıflandırıcısı ve TV filtre uygulanmış orijinal veri kombinasyonu vermektedir. IA yöntemi 1 defa çalıştırıldığında toplam çalışma süresi 2 gün 10 saat 45 dakika olarak ölçülmüştür.

Tablo 4’te verilen sonuçlara ilave olarak EfficientNetB0 modeli ve DVM sınıflandırıcısı kullanılarak elde edilen 0,8947 doğruluk skoruna çok yakın dört sonuç daha elde edilmiştir. Bu sonuçlar Tablo 5’te verilmektedir.


Tablo 5. EfficientNetB0-DVM Kombinasyonu ile Elde Edilen Diğer Başarılı Sonuçlar

Veri Türü	Doğruluk Skoru
Orijinal	0,8925
Orijinal-AD	0,8925
Orijinal-İKT	0,8932
Orijinal-Gauss	0,8932

Tablo 5’te verilen en iyi sonuca çok yakın bu skorlar EfficientNetB0-DVM kombinasyonu kullanan verilere aittir. Dikkat edilecek olursa ANVS veri setinde orijinal ve filtre uygulanmış orijinal veriler çok iyi sonuçlar vermiştir.

Şekil 25’te IA yöntemi ile oluşturulan bütün kombinasyonlara yani 270 modelin tamamına ait doğruluk skorunun kombinasyonlara bağlı değişimini 3B olarak gösteren bir grafik verilmektedir.

Şekil 25. IA Yöntemi ile Doğruluk Skorunun Parametrelere Göre Değişimi a) Model-Sınıflandırıcı; b) Model-Sınıflandırıcı-Veri Türü



Şekil 25’te de görüldüğü gibi en yüksek skor EfficientNetB0-DVM kombinasyonunu kullanan verilerde elde edilmiştir. Grafiğin görsel bütünlüğünün sağlanması açısından orijinal ve orijinal verilere uygulanan filtreler “Orj” kısaltması ile verilmiştir. Vgg16 ve Vgg19 modelleri genel olarak 0,86-0,88 aralığında performans göstermiştir. Yine Şekil 25’e göre 3B Doğruluk değerlerine ilişkin yüzeyin birçok yerel

maksimum noktaya sahip olduğu görülmektedir. Bu bölgelerden bazıları daha umut vaat eden bölgeler olup tüm uzayın aranması yerine buralara yoğunlaşılması uzun süren ESA eğitimlerinde zaman açısından büyük bir kazanç sağlayacaktır. Bu bölgeleri aramak ve global maksimum değere ulaşmak için ise sezgisel algoritmalarından faydalanılmaktadır.

Bu aşamadan sonra ANVS, sezgisel optimizasyon algoritmalarından DE ve PSO ile aynı parametreler kullanılarak toplam 10 defa çalıştırılmıştır. Optimize edilmesi gereken uygunluk değeri olarak doğruluk skoru belirlenmiştir. Her iki optimizasyon yöntemi, 15 popülasyon ve 10 iterasyon parametreleri ile çalıştırılmıştır. DE ve PSO algoritmalarına ait sonuçlar ve toplam zaman maliyeti (Süre) sırasıyla Tablo 6 ve Tablo 7’de verilmektedir.

Tablo 6. DE Algoritması ile Her Bir Bağımsız Çalıştırma Sonrası Elde Edilen En İyi Sonuçlar ve Kombinasyonları

Model	Sınıflandırıcı	Veri Türü	Doğruluk Skoru	Süre (Gün-Saat:Dakika)
EfficientNetB0	DVM	Orj-TV	0,8947	1-00:00
EfficientNetB0	DVM	Orj-Gauss	0,8932	1-00:00
EfficientNetB0	DVM	Orj-Gauss	0,8932	0-22:38
EfficientNetB0	DVM	Orj	0,8925	1-00:00
Vgg19	DVM	Orj	0,8865	0-14:10
Vgg19	DVM	Orj	0,8865	0-22:43
EfficientNetB0	DVM	Orj-TV	0,8947	1-00:00
Vgg19	DVM	Orj	0,8865	0-22:43
EfficientNetB0	DVM	Orj	0,8925	2-00:00
EfficientNetB0	DVM	Orj	0,8925	1-02:26

DE algoritmasının 10 defa çalıştırılmasına ait sonuçlar incelendiğinde en iyi skorun 2 defa tespit edildiğini ve algoritmanın genel olarak en iyi sonuca çok yakın sonuçları tespit ettiği görülmektedir.

Tablo 7. PSO Algoritması ile Her Bir Bağımsız Çalıştırma Sonrası Elde Edilen En İyi Sonuçlar ve Kombinasyonları

Model	Sınıflandırıcı	Veri Türü	Doğruluk Skoru	Süre (Gün-Saat:Dakika)
Vgg16	DVM	Orj-TV	0,8835	0-05:43
EfficientNetB0	DVM	Orj	0,8925	0-07:55
Vgg16	RO	Orj	0,8678	0-03:18
EfficientNetB0	YSA	Orj-İKT	0,8932	0-15:00
Vgg19	RO	Orj	0,8738	0-03:50
Vgg16	YSA	Orj	0,8745	0-06:25
EfficientNetB0	DVM	Orj-Gauss	0,8932	0-03:36
EfficientNetB0	İki Katmanlı YSA	Orj	0,8932	0-01:57
EfficientNetB0	DVM	Orj	0,8925	0-03:25
Vgg16	DVM	Orj-TV	0,8835	0-03:33

PSO sonuçlarına göre en iyi skora ulaşılmasa da genel itibari ile ona yakın bir oran etrafında sonuçlar elde edilmiştir. Tablo 8’de DE ve PSO algoritmaları ile elde edilen 10 doğruluk skoruna ait istatistiki bilgiler etrafında karşılaştırma yapılmaktadır.

Tablo 8. DE ve PSO Algoritmalarına Ait Sonuçların Karşılaştırılması

Algoritma	En yüksek	En düşük	Ortalama	Standart Sapma	Toplam Süre
DE	0,8947	0,8865	0,8913	0,0032	9-12:40
PSO	0,8932	0,8678	0,8848	0,0092	2-6:42

Tablo 8’de verilen Toplam Süre, çalışmanın önceki sonuçlarındaki sürelerin toplamına karşılık gelir ve Gün-Saat:Dakika şeklinde ifade edilmiştir.

Sezgisel yöntemlerden DE ve PSO’nun algoritmik çalışma zamanları ESA mimarilerinin eğitimi yanında oldukça kısa sürmektedir. Tablo 8’de PSO yönteminin DE’ye göre daha hızlı hesaplaması da lokal maksimuma takılıp önerilen algoritmadaki

hafıza mekanizmasını kullanması olarak değerlendirilmektedir. Bu çalışma ile önerilen hafıza mekanizması, sezgisel yöntemin aynı popülasyon elemanını üretmesi durumunda doğruluk değerini hafızadan doğrudan kullanmaktadır. Bu açıdan lokal maksimuma takılmadan ilerleme gösterip global optimumu bulabilmede PSO'ya göre daha iyi sonuçlar veren DE yöntemi daha başarılı bulunmuştur.

Tablo 8'de görüldüğü üzere, en düşük ve ortalama değerler karşılaştırıldığında da DE'nin üstünlüğü görülmektedir. Her ne kadar süre açısından dezavantajlı gibi görünse de toplam zaman maliyeti açısından IA yöntemine göre oldukça daha az kaynak harcamaktadır. Öyle ki, mevcut parametreler ve bunlardan meydana gelen 270 farklı kombinasyon, IA ile 1 defa çalıştırıldığında 2 gün 10 saat 45 dakika sürerken DE algoritmasının aynı kombinasyonu sadece 1 günde tespit edebildiği görülmektedir. En yüksek doğruluk skoru ise EfficientNetB0-DVM-Orijinal TV filtre kombinasyonu ile elde edilmiştir. Model, sınıflandırıcı ve filtrelerin artırılması durumunda DE yönteminin IA'ya göre üstünlüğünün daha da belirleyici olacağı öngörülebilmektedir.

4.2. Tüm Veri Setlerinin DE Algoritması ile Çalıştırılması

Sezgisel optimizasyon yöntemi olarak DE algoritmasının tercih edilmesi kararlaştırıldıktan sonra, ANVS, MKVS-1, DR, AKVS ve MKVS-2 veri setleri yeni sınıflandırıcı hiper parametreleri ve modeller ile 10 defa çalıştırılmıştır.

EfficientNetB7 modeli hem EfficientNetB0 modeline göre daha kötü sonuç verdiği için hem de çok uzun süre çalıştığı için modeller arasından çıkarılmış ve bunun yerine DenseNet121, MobileNetv2 modelleri eklenmiştir. Aynı şekilde sınıflandırıcı olarak da K-EYK ve XGBoost sınıflandırıcıları eklenmiş ve hem sınıflandırıcı sayısı hem de onlara ait hiper parametre sayılarında çeşitlilik sağlanmıştır. DE algoritması ile en yüksek uygunluk değeri (doğruluk skoru) elde edilmek amaçlanırken sınıflandırıcı hiper parametrelerinin optimizasyonu da sağlanmaktadır. Tablo 9'da sonraki aşamada kullanılan yeni parametre ve hiper parametreler ve bunların alacağı değerler verilmektedir

Tablo 9. Optimize Edilen Sınıflandırıcı Hiper Parametreleri ve Modeller

Model	Sınıflandırıcı ve Hiper Parametreler
1. Vgg16 2. Vgg19 3. ResNet50 4. EfficientNetB0 5. DenseNet121 6. MobileNetv2	1. DVM • $C = \{1.0, 100, 200, 300\}$ 2. RO • $n_estimators = \{10, 20, 50, 100\}$ • $min_samples_leaf = \{1, 3\}$ 3. K-EYK • $n_neighbors = \{1, 3\}$ • $algorithm = \{brute, ball-tree\}$ • $leaf_size = \{10, 40, 60, 80\}$ 4. XGBoost • $max_depth = \{12, 14, 16, 18\}$

İlk aşamada IA yöntemi ile optimizasyon yapıldığında toplam parametre sayısı 270 olarak tespit edilmişti. DE algoritmasının tercih edilmesinden sonra model ve sınıflandırıcı hiper parametrelerinde yapılan değişiklik ile; 6 model, 3 sınıflandırıcı ve bunlara ait hiper parametreler ve 18 farklı veri türü olmak üzere toplam parametre sayısı 756 olmuştur. Böyle bir kombinasyon sayısında IA yönteminin zaman açısından oldukça uzun süreceği de fark edilmektedir. Bu sebeple DE algoritmasının en yüksek doğruluk değerini veren kombinasyonun tespitinde önemli bir yer tuttuğu da görülmektedir.

DE optimizasyonu ise 15 popülasyon ve 10 iterasyon parametreleri ile çalıştırılmış olup, algoritmaya eklenen hafıza mekanizması ile üretilen bir popülasyonun tekrar çalıştırılmasının da önüne geçilmiştir.

Bu çalışmada, kullanılan parametre ve hiper parametre fazlalığından dolayı en yüksek uygunluk değerinin elde edilmesini sağlayan kombinasyonun belirtilebilmesi için parametreler, veri türleri ve metrikler kısaltılarak isimlendirilmiştir. Tablo 10'da, en yüksek doğruluk skorunun elde edilmesini sağlayan parametre kombinasyonlarına ait sonuçların gösteriminde kullanılan kısaltmalar verilmektedir.


Tablo 10. Sonuç Kombinasyonlarına Ait Kısaltmalar

Parametre/Hiper Parametre/Veri Türü/Metrik	Kısaltma
EfficientNetB0	B0
EfficientNetB7	B7
DenseNet121	D121
MobileNetv2	MBv2
ResNet50	R50
XGBoost	XGB
Orijinal	Orj
CLAHE	CL
Doğruluk	Doğ.
Duyarlılık	Duy.
Kesinlik	Kes.
F1-Skor	F1
Cohen Kappa	CK

Parametrelerin, hiper parametrelerin ve veri türlerinin kısaltmalarının verildiği Tablo 10'daki veri türü, kullanılan verinin orijinal (CLAHE uygulanmayan) ya da CLAHE uygulanmış olan bir veri olduğudur.

Kısaltmaların oluşturulmasından sonra en iyi kombinasyonun isimlendirilmesinde de Şekil 26'da verilen akış diyagramı kullanılmıştır.

Şekil 26. En İyi Kombinasyonların İsimlendirilmesi için Akış Diyagramı



Hangi hiper parametrenin hangi sınıflandırıcıya ait olduğu bilgisi Tablo 9’da verilmiştir. Aşağıda en iyi kombinasyonlara ait Şekil 26’daki akış diyagramı kullanılarak isimlendirmeye dair örnekler verilmiştir.

Örnek 1: B0_Orj_BM3D_DVM_1.0

Örnek 1’de verilen en yüksek doğruluk skorunu elde eden kombinasyonda:

- Model = EfficientNetB0
- Veri Türü = Orijinal
- Filtre = BM3D
- Sınıflandırıcı = DVM
- Hiper Parametre: C = 1

Örnek 2: D121_CL_AD_K-EYK_1_brute_3

Örnek 2’de verilen en yüksek doğruluk skorunu elde eden kombinasyonda:

- Model = DenseNet121
- Veri Türü = CLAHE
- Filtre = AD
- Sınıflandırıcı = K-EYK
- Hiper Parametre: n_neighbors = 1
- Hiper Parametre: algorithm = brute
- Hiper Parametre: leaf_size = 3

Örnek 3: MBv2_Orj_(-)_RO_3_2

Örnek 3’te verilen en yüksek doğruluk skorunu elde eden kombinasyonda:

- Model = MobileNetv2
- Veri Türü = Orijinal
- Filtre = Filtre Uygulanmamış (-)
- Sınıflandırıcı = RO
- Hiper Parametre: n_estimators = 3
- Hiper Parametre: min_samples_leaf = 2

Tablo 9’da verilen model, sınıflandırıcı parametreleri ve onlara ait hiper parametreler ve 18 veri türü ile ANVS, MKVS-1, DR, AKVS ve MKVS-2 veri setlerinin DE algoritması kullanılarak 10 defa çalıştırılmasına ait sonuçlar her bir veri seti için alt başlıklar olarak verilmektedir.

4.2.1. ANVS’nin DE Algoritması ile Çalıştırılması


Tablo 11’de ANVS’nin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 27’de en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri, Şekil 28’de ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.

Tablo 11. ANVS'nin DE Algoritması ile Çalıştırılması


En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
Vgg16_Orj_(-)_K-EYK_1_brute_10	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-11:05
Vgg16_Orj_(-)_K-EYK_1_brute_60	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-8:18
Vgg16_Orj_(-)_K-EYK_1_brute_60	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-9:46
Vgg16_Orj_(-)_K-EYK_1_ball-tree_40	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-9:05
Vgg16_Orj_(-)_K-EYK_1_brute_10	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-10:09
Vgg16_Orj_(-)_K-EYK_1_brute_80	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-10:30
Vgg16_Orj_(-)_K-EYK_1_ball-tree_60	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-15:32
Vgg16_Orj_(-)_K-EYK_1_ball-tree_80	0,9783	0,9783	0,9784	0,9784	0,9542	0,9776	0-17:35
Vgg16_Orj_(-)_K-EYK_1_brute_80	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-9:07
Vgg16_Orj_(-)_K-EYK_1_brute_10	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892	0-9:54

Tablo 11 ve sonraki tüm sonuçlarda verilen parametre kombinasyonlarının ve metriklerin isimlendirilmesinde Tablo 10'daki kısaltmalar ve Şekil 26'daki akış diyagramı kullanılmıştır. Verilen kombinasyonların çalışma süresi de "Zaman" kolonunda Gün-Saat:Dakika şeklinde ifade edilmiştir. Birden fazla aynı doğruluk skorunun olduğu durumlarda ise en az sürede çalışan kombinasyon tercih edilmiş ve en iyi sonuç kalın punto ile belirtilmiştir.

Şekil 27. ANVS için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 28. ANVS için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



ANVS'nin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlara bakıldığında model olarak Vgg16, veri türü olarak filtre uygulanmamış orijinal veriden ve sınıflandırıcı olarak K-EYK'dan oluşan kombinasyonun en yüksek doğruluk skorunu elde etmede tek başına en iyi kombinasyon olduğu görülmektedir. Bu durum, ANVS için orijinal verilerde model ve sınıflandırıcıların daha umut vaat eden parametreler olduğu görülmekte ve DE algoritmasının da bu parametrelere yoğunlaştığı görülmektedir.

ANVS'nin DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 0.5791 olarak bulunmuştur. Bu sonuca göre, %5 güven düzeyinde H_0 hipotezi reddedilmez. Yani, ANVS için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

4.2.2. MKVS-1'in DE Algoritması ile Çalıştırılması

Tablo 12'de MKVS-1'in DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 29'da en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri, Şekil 30'da ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.


Tablo 12. MKVS-1'in DE Algoritması ile Çalıştırılması

En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
B0_CL (-)_DVM_1.0	0,813	0,813	0,8131	0,813	0,626	0,8826	5-6:31
B0_CL (-)_DVM_1.0	0,813	0,813	0,8131	0,813	0,626	0,8826	2-7:02
MBv2_CL (-)_DVM_1.0	0,8107	0,8107	0,8108	0,8107	0,6214	0,8778	3-13:24
D121_Orj_Gauss_DVM_1.0	0,8033	0,8033	0,8033	0,8033	0,6066	0,8725	1-20:56
Vgg16_CL_BM3D_DVM_1.0	0,7877	0,7877	0,7877	0,7877	0,5753	0,8604	1-5:32
MBv2_CL (-)_DVM_1.0	0,8107	0,8107	0,8108	0,8107	0,6214	0,8778	2-12:02
D121_CL_BM3D_XGB_14	0,7974	0,7974	0,7974	0,7974	0,5948	0,8711	0-7:48
B0_CL (-)_DVM_1.0	0,813	0,813	0,8131	0,813	0,626	0,8826	1-20:03
D121_CL_BM3D_DVM_1.0	0,7984	0,7984	0,7985	0,7984	0,5968	0,8722	0-23:32
D121_Orj (-)_XGB_14	0,7976	0,7976	0,7977	0,7976	0,5953	0,8698	1-17:45


MKVS-1'in DE algoritması ile 10 defa çalıştırılmasına ait sonuçlara göre en yüksek doğruluk skoru 0,813 olarak elde edilmiştir. Model olarak EfficientNetB0 ile

MobileNetv2 arasında az bir fark olmasına karşın EfficientNetB0 modeli MKVS-1 veri seti için daha iyi sonuç vermiştir. Sınıflandırıcı olarak DVM, en iyi sonuçların büyük çoğunluğunda etkili olmuştur. Veri türü olarak filtre uygulanmamış CLAHE'li veriler daha iyi sonuç vermiştir.

Şekil 29. MKVS-1 için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 30. MKVS-1 için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



MKVS-1'in DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 0.4922 olarak bulunmuştur. Bu sonuca göre, %5 güven düzeyinde H_0 hipotezi reddedilmez. Yani, MKVS-1 için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

4.2.3. DR Veri Setinin DE Algoritması ile Çalıştırılması

Tablo 13'te DR veri setinin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 31'de en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri, Şekil 32'de ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.


Tablo 13. DR Veri Setinin DE Algoritması ile Çalıştırılması

En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
D121_Orj_(-)_XGB_18	0,9016	0,9016	0,8995	0,9003	0,6951	0,9355	0-18:23
D121_Orj_(-)_XGB_14	0,9062	0,9062	0,9062	0,9062	0,7168	0,9383	0-22:26
D121_Orj_(-)_XGB_14	0,9062	0,9062	0,9062	0,9062	0,7168	0,9383	0-15:48
B0_CL_AG_DVM_1.0	0,9016	0,9016	0,898	0,8977	0,6808	0,918	0-22:30
MBv2_Orj_AG_DVM_1.0	0,8984	0,8984	0,8967	0,8974	0,6872	0,9332	0-18:59
D121_Orj_(-)_XGB_14	0,9062	0,9062	0,9062	0,9062	0,7168	0,9383	0-15:44
D121_Orj_(-)_XGB_14	0,9062	0,9062	0,9062	0,9062	0,7168	0,9383	0-16:48
D121_CL_AG_DVM_1.0	0,9	0,9	0,8963	0,8962	0,6767	0,9271	0-18:52
B0_Orj_AG_RO_100_1	0,9109	0,9109	0,9082	0,9074	0,7112	0,9275	0-19:45
B0_Orj_AG_RO_50_3	0,9141	0,9141	0,9116	0,9107	0,7213	0,9236	1-10:56


DR veri setinin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar incelendiğinde, en yüksek doğruluk skorunun elde edilmesini sağlayan kombinasyonlar

arasında bir çeşitlilik görülmektedir. En yüksek doğruluk skoru olan 0,9141 oranının elde edilmesini sağlayan kombinasyon, EfficientNetB0 modeli, orijinal veri türü, Ağırlıklandırılmış Gauss filtresi ve RO sınıflandırıcısından oluşmaktadır. En yüksek skora bir defa ulaşılmış olması ve geriye kalan sonuçların ise buna yakın olması, algoritmanın verilen popülasyon ve iterasyon değerleri ile zor da olsa optimum sonucu bulduğunun bir göstergesi olarak kabul edilmektedir.

Şekil 31. DR Veri Seti için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 32. DR Veri Seti için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



DR veri setinin DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 0.5723 olarak bulunmuştur. Bu sonuca göre, %5 güven düzeyinde H_0 hipotezi reddedilmez. Yani, DR veri seti için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

4.2.4. AKVS'nin DE Algoritması ile Çalıştırılması

Tablo 14'te AKVS'nin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 33'te en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri, Şekil 34'te ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.


Tablo 14. AKVS'nin DE Algoritması ile Çalıştırılması

En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
Vgg19_Orj_Gauss_YSA	0,85	0,85	0,8566	0,8512	0,6939	0,8542	0-2:51
B0_CL_Gauss_YSA	0,85	0,85	0,8909	0,8511	0,7059	0,9988	0-5:30
Vgg19_Orj_AD_YSA	0,85	0,85	0,8566	0,8512	0,6939	0,875	0-3:48
Vgg16_CL_(-)_YSA	0,85	0,85	0,8909	0,8511	0,7059	0,8542	0-3:56
Vgg16_CL_İKT_DVM_300	0,85	0,85	0,8909	0,8511	0,7059	0,9167	0-2:45
R50_Orj_BM3D_XGB_16	0,9	0,9	0,92	0,901	0,8	0,9271	0-4:18
Vgg19_Orj_AD_XGB_14	0,9	0,9	0,9	0,9	0,7917	0,9688	0-2:47
Vgg16_CL_İKT_DVM_100	0,85	0,85	0,8909	0,8511	0,7059	0,9167	0-4:00
Vgg19_Orj_AD_XGB_14	0,9	0,9	0,9	0,9	0,7917	0,9688	0-2:53
R50_CL_(-)_DVM_300	0,8	0,8	0,82	0,802	0,6	0,8542	0-5:06


AKVS'nin DE algoritması ile 10 defa çalıştırılmasında elde edilen sonuçlara göre en iyi skor olan 0,9 doğruluk skorunun elde edilmesin iki farklı model belirlenmesine

rağmen sınıflandırıcı ve veri türü olarak aynı parametreler fayda sağlamıştır. Genel anlamda 0,8 – 0,9 doğruluk skoru arasında gidip gelen algoritmanın en yüksek skoru birden fazla defa bulduğu görülmektedir. Farklı kombinasyonların en iyi skoru buldukları bir düzeyde, süre açısından daha az maliyetli olan kombinasyon tercih edilmiştir.

Şekil 33. AKVS için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 34. AKVS için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



AKVS veri setindeki en iyi sonuç olan 0,9 doğruluk skorunu elde eden kombinasyon, Vgg19 modeli, , Anizotropik Difüzyon filtresi uygulanmış orijinal veri türü ve XGBoost sınıflandırıcısından oluşmaktadır. AKVS veri setinin DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 0.2955 olarak bulunmuştur. Bu sonuca göre, %5 güven düzeyinde H_0 hipotezi reddedilmez. Yani, AKVS veri seti için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

4.2.5. MKVS-2'nin DE Algoritması ile Çalıştırılması


Tablo 15'te MKVS-2'nin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 35'te en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri, Şekil 36'da ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.

Tablo 15. MKVS-2'nin DE Algoritması ile Çalıştırılması


En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
D121_Orj_(-)_DVM_200	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-4:10
D121_Orj_(-)_DVM_200	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-0:30
D121_Orj_(-)_DVM_200	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-13:08
D121_Orj_(-)_DVM_100	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-18:23
D121_Orj_HM_DVM_100	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-20:01
D121_Orj_(-)_DVM_100	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-3:01
D121_Orj_HM_DVM_300	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-9:00
B0_Orj_Dalgacık_DVM_200	0,8697	0,8697	0,87	0,8655	0,6857	0,9233	1-10:38
D121_Orj_(-)_DVM_200	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-22:46
D121_Orj_(-)_DVM_200	0,8752	0,8752	0,8748	0,8719	0,7014	0,9327	1-4:31

MKVS-2’de en yüksek doğruluk skorunun elde edilmesinde DenseNet121 modelinin ve DVM sınıflandırıcısının etkin olduğu görülmektedir. Veri türü olarak orijinal ve filtre uygulanmış orijinal veri baskın gelmiştir. Süre açısından, orijinal verinin kullanıldığı kombinasyon tercih edilmiştir. MKVS-2 veri seti için en iyi sonuç olan 0,8752 doğruluk skorunun elde edilmesini sağlayan kombinasyon, DenseNet121 modeli, filtre uygulanmamış orijinal veri türü ve DVM sınıflandırıcısından oluşmaktadır.

Şekil 35. MKVS-2 için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 36. MKVS-2 için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



MKVS-2'nin DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 0.5791 olarak bulunmuştur. Bu sonuca göre, %5 güven düzeyinde H_0 hipotezi reddedilmez. Yani, MKVS-2 için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

4.3. Veri Artırma Uygulanan Veri Setlerinin DE Algoritması ile Çalıştırılması

ANVS, DR, AKVS ve MKVS-2 veri setlerine veri artırma ön işleme tekniği uygulanarak eğitim verilerinin sayıları artırılmıştır. Daha sonra bu veri setleri DE algoritması ile aynı parametreler (Tablo 9) kullanılarak 10 defa çalıştırılmıştır.

MKVS-1 için veri artırma tekniği uygulanmamasının nedeni, bu veri setindeki verilerin sayısının fazla olması ve optimizasyon işlemi için çalışma süresinin çok uzun olacağının beklenmesinden dolayı olmuştur.

Tablo 16'da veri artırma tekniği uygulanan veri setlerinin veri artırma öncesi (VAÖ) ve veri artırma sonrası (VAS) eğitim verisi sayıları verilmektedir.

Tablo 16. Veri Artırma Uygulanan Veri Setlerinin Öncesi ve Sonrasına Ait Eğitim Verisi Sayıları

Veri Seti	VAÖ Eğitim Verisi	VAS Eğitim Verisi
ANVS	6691	10704
DR	2560	4165
AKVS	80	1032
MKVS-2	1148	1890

Çalışmada uygulanan birçok ön işleme tekniğinin yanı sıra, veri artırma ön işleme tekniğinin kullanılmasının nedeni başta AKVS olmak üzere veri setlerinde eğitim verisinin az olmasından dolayıdır. Bunun yanında veri artırmanın da sınıflandırma başarısına etkisinin incelenmesi ve ileriki çalışmalarda bir parametre olarak önerilen algoritmaya eklenmesi faydalı olacaktır.

4.3.1. Veri Artırma Uygulanmış ANVS Analizi


Tablo 17’de veri artırma tekniği uygulanmış ANVS veri setinin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 37’de, en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri; Şekil 38’de ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.

Tablo 17. Veri Artırma Uygulanmış ANVS’nin DE Algoritması ile Çalıştırılması


En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
Vgg16_Orj_(-)_K-EYK_1_brute_60	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	0-21:33
Vgg16_Orj_(-)_K-EYK_1_brute_60	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	0-20:29
Vgg16_Orj_(-)_K-EYK_1_ball-tree_10	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	0-22:16
Vgg16_Orj_(-)_K-EYK_1_ball-tree_80	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	1-0:31
Vgg16_Orj_(-)_K-EYK_1_brute_10	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	1-1:44
Vgg16_Orj_(-)_K-EYK_1_brute_40	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	0-19:20
Vgg16_Orj_(-)_K-EYK_1_brute_10	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	0-22:56
Vgg16_Orj_(-)_K-EYK_1_ball-tree_40	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	1-5:14
Vgg16_Orj_(-)_K-EYK_1_brute_60	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	0-21:20
Vgg16_Orj_(-)_K-EYK_1_brute_40	0,9895	0,9895	0,9895	0,9895	0,9778	0,9885	1-7:30

Veri artırma tekniği uygulanmış ANVS’de yine en yüksek doğruluk skorunu elde eden kombinasyonların tamamında parametre olarak aynı model, sınıflandırıcı ve veri türü bulunmuştur. Doğruluk skorunda yüzdelik olarak hesaplandığı zaman, veri artırma uygulanmadan elde edilen en iyi sonuca göre 0,8 puanlık bir azalış görülmüştür.

Şekil 37. Veri Artırma Uygulanmış ANVS için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 38. Veri Artırma Uygulanmış ANVS için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



Veri artırma uygulanmış ANVS'nin DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 1.0 olarak bulunmuştur. Bu sonuca göre, %5 güven

düzeyinde H_0 hipotezi reddedilmez. Yani, veri artırma uygulanmış ANVS için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

4.3.2. Veri Artırma Uygulanmış DR Veri Seti Analizi

Tablo 18’de veri artırma tekniği uygulanmış DR veri setinin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 39’da en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri, Şekil 40’da ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.


Tablo 18. Veri Artırma Uygulanmış DR Veri Setinin DE Algoritması ile Çalıştırılması

En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
D121_Orj_(-)_XGB_14	0,9094	0,9094	0,9085	0,9089	0,7232	0,9453	1-14:59
D121_Orj_(-)_XGB_14	0,9094	0,9094	0,9085	0,9089	0,7232	0,9453	2-5:05
D121_Orj_(-)_XGB_16	0,9016	0,9016	0,9003	0,9009	0,6985	0,9457	1-5:43
D121_CL_(-)_DVM_1.0	0,8984	0,8984	0,8976	0,898	0,6907	0,9368	4-3:06
MBv2_CL_AG_DVM_1.0	0,9031	0,9031	0,9021	0,9026	0,7041	0,9294	3-11:37
MBv2_CL_AD_DVM_1.0	0,9	0,9	0,899	0,8994	0,6946	0,9271	3-7:54
D121_Orj_(-)_XGB_14	0,9094	0,9094	0,9085	0,9089	0,7232	0,9453	2-7:11
D121_Orj_(-)_XGB_14	0,9094	0,9094	0,9085	0,9089	0,7232	0,9453	1-5:04
D121_Orj_(-)_XGB_14	0,9094	0,9094	0,9085	0,9089	0,7232	0,9453	2-5:39
D121_Orj_(-)_XGB_14	0,9094	0,9094	0,9085	0,9089	0,7232	0,9453	2-9:05


Tablo 18’deki sonuçlara göre en yüksek doğruluk skorunun elde edilmesinde DenseNet121 modeli, XGBoost sınıflandırıcısı ve filtre uygulanmamış orijinal veriden oluşan kombinasyonun baskınlığı görülmektedir. Bu kombinasyondaki model, sınıflandırıcı ve veri türünün değiştiği olasılıklarda doğruluk skorunun azaldığı

görülmektedir. Doğruluk skorunda yüzdelik olarak hesaplandığında, veri artırma uygulanmadan elde edilen en iyi sonuç ile karşılaştırıldığında 0,47 puanlık bir düşüş görülmüştür.

Şekil 39. Veri Artırma Uygulanmış DR Veri Seti için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 40. Veri Artırma Uygulanmış DR Veri Seti için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



Veri artırma uygulanmış DR veri setinin DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 0.0761 olarak bulunmuştur. Bu sonuca göre, %5 güven düzeyinde H_0 hipotezi reddedilmez. Yani, veri artırma uygulanmış DR veri seti için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

4.3.3. Veri Artırma Uygulanmış AKVS'nin Analizi

Tablo 19'da veri artırma tekniği uygulanmış AKVS'nin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 41'de en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri, Şekil 42'de ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.


Tablo 19. Veri Artırma Uygulanmış AKVS'nin DE Algoritması ile Çalıştırılması

En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
B0_CL_İKT_DVM_100	0,95	0,95	0,9556	0,9504	0,898	0,9167	0-13:27
B0_CL_Ortalama_XGB_16	0,95	0,95	0,9556	0,9504	0,898	0,9375	0-12:10
MBv2_Orj_TV_XGB_18	0,9	0,9	0,92	0,901	0,8	0,9062	0-12:15
B0_CL_BM3D_RO_50_1	0,9	0,9	0,9	0,9	0,7917	0,9115	0-16:39
B0_CL (-)_XGB_16	0,9	0,9	0,9	0,9	0,7917	0,9479	0-12:51
B0_CL (-)_XGB_12	0,9	0,9	0,9	0,9	0,7917	0,9479	0-10:10
B0_CL_İKT_DVM_100	0,95	0,95	0,9556	0,9504	0,898	0,9167	0-20:49
B0_CL (-)_XGB_16	0,9	0,9	0,9	0,9	0,7917	0,9479	0-15:36
B0_CL (-)_DVM_1.0	0,9	0,9	0,9	0,9	0,7917	0,9271	0-12:09
MBv2_Orj_TV_DVM_100	0,9	0,9	0,92	0,901	0,8	0,8958	0-9:35


Tablo 19'daki sonuçlara göre hem en yüksek doğruluk skorunun elde edilmesinde hem de ona yakın sonuçların elde edilmesinde EfficientNetB0 modeli ve filtre

uygulanmış CLAHE'li verilerden oluşan kombinasyonların daha etkin olduğu görülmektedir.

Şekil 41. Veri Artırma Uygulanmış AKVS için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 42. Veri Artırma Uygulanmış AKVS için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



En iyi sonuç olan 0,95 doğruluk skorunun elde edilmesini sağlayan kombinasyon, EfficientNetB0 modeli, ortalama filtre uygulanmış CLAHE’li veri türü ve XGBoost sınıflandırıcısından oluşmaktadır. Doğruluk skorunda yüzdelik olarak hesaplandığında, veri artırma uygulanmadan elde edilen en iyi sonuç ile karşılaştırıldığında 5 puanlık bir artış görülmüştür.

Veri artırma uygulanmış AKVS’nin DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 0.1519 olarak bulunmuştur. Bu sonuca göre, %5 güven düzeyinde H_0 hipotezi reddedilmez. Yani, veri artırma uygulanmış AKVS için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

4.3.4. Veri Artırma Uygulanmış MKVS-2’nin Analizi

Tablo 20’de veri artırma tekniği uygulanmış MKVS-2’nin DE algoritması ile 10 defa çalıştırılmasına ait sonuçlar verilmektedir. Şekil 43’te en yüksek doğruluk skorunun elde edildiği kombinasyona ait karmaşıklık matrisi ve ROC eğrisi grafikleri, Şekil 44’te ise doğruluk skorunun 10 iterasyon boyunca kat ettiği gelişimi gösteren grafik verilmektedir.


Tablo 20. Veri Artırma Uygulanmış MKVS-2'nin DE Algoritması ile Çalıştırılması

En iyi Kombinasyon	Doğ.	Duy.	Kes.	F1	CK	AUC	Zaman(G-SS:DD)
D121_CL_(-)_DVM_300	0,8807	0,8807	0,8793	0,8791	0,7202	0,9478	2-11:56
D121_CL_(-)_DVM_100	0,8807	0,8807	0,8793	0,8791	0,7202	0,9478	1-9:34
D121_CL_(-)_DVM_200	0,8807	0,8807	0,8793	0,8791	0,7202	0,9478	1-20:27
D121_CL_(-)_DVM_100	0,8807	0,8807	0,8793	0,8791	0,7202	0,9478	1-19:13
D121_CL_(-)_DVM_300	0,8807	0,8807	0,8793	0,8791	0,7202	0,9478	2-3:59
D121_CL_(-)_DVM_200	0,8807	0,8807	0,8793	0,8791	0,7202	0,9478	1-12:42
D121_Orj_(-)_DVM_200	0,8789	0,8789	0,8776	0,8779	0,7189	0,9299	2-16:29
B0_CL_(-)_DMV_200	0,8752	0,8752	0,874	0,8726	0,7041	0,9319	1-13:13
D121_CL_(-)_DVM_100	0,8807	0,8807	0,8793	0,8791	0,7202	0,9478	2-9:30
D121_CL_(-)_DVM_300	0,8807	0,8807	0,8793	0,8791	0,7202	0,9478	2-3:59


Tablo 20'deki sonuçlara göre en yüksek doğruluk skorunun elde edilmesinde DenseNet121 modeli, DVM sınıflandırıcısı ve filtre uygulanmamış CLAHE'li verilerden oluşan kombinasyonun baskın olma durumu söz konusudur.

Sadece sınıflandırıcı hiper parametresinin değiştiği en yüksek doğruluk skorunu veren kombinasyonlar arasında en az sürede çalışan kombinasyon tercih edilmiştir. Doğruluk skorunda yüzdeler olarak hesaplandığında, veri artırma uygulanmadan elde edilen en iyi sonuca göre 0,57 puanlık bir artış olmuştur.

Şekil 43. Veri Artırma Tekniği MKVS-2 için Karmaşıklık Matrisi ve ROC Eğrisi Grafikleri



Şekil 44. Veri Artırma Uygulanmış MKVS-2 için Doğruluk Skorunun DE Algoritmasındaki İlerleyişi



Veri artırma uygulanmış MKVS-2'nin DE algoritması ile birbirinden bağımsız şekilde 10 defa çalıştırılması sonucunda elde edilen doğruluk skorlarına ait sonuçlara WİST uygulanmış ve p değeri 0.3049 olarak bulunmuştur. Bu sonuca göre, %5 güven düzeyinde H_0 hipotezi reddedilmez. Yani, veri artırma uygulanmış MKVS-2 için elde edilen doğruluk sonuçları ile bu sonuçların medyanları arasında anlamlı bir fark yoktur ve istatistiksel olarak benzer sonuçlar elde edildiği görülmektedir.

Çalışmanın bundan sonraki bölümünde, veri setlerinin veri artırma tekniği uygulanmadan önceki ve sonraki durumlarında elde edilen sonuçlarına dair bir karşılaştırma yapılmıştır. Böylelikle, en yüksek doğruluk skorunun elde edilmesinde veri artırma tekniğinin etkisi olup olmadığı belirlenmiştir.

4.4. Veri Artırma Öncesi ve Sonrası Sonuçların Karşılaştırılması

Tablo 21'de çalışmadaki veri setleri, veri artırma tekniği kullanılıp kullanılmadığı durumu ve uygunluk değeri olan doğruluk skoruna göre en iyi yöntem ve kombinasyonlar verilmiştir. En yüksek doğruluk skorunu veren yöntem ve kombinasyon koyu olarak belirtilmiştir.

Tablo 21. En Yüksek Doğruluk Skorunu Sağlayan Yöntem ve Kombinasyon Karşılaştırması

Veri Seti	VAÖ		VAS	
	Kombinasyon	Doğruluk	Kombinasyon	Doğruluk
ANVS	Vgg16_Orj_(-)_K-EYK_1_brute_60	0,9903	Vgg16_Orj_(-)_K-EYK_1_brute_40	0,9895
MKVS-1	B0_CL_(-)_DVM_1.0	0,813	-	-
DR	B0_Orj_AG_RO_50_3	0,9141	D121_Orj_(-)_XGB_14	0,9094
AKVS	Vgg19_Orj_AD_XGB_14	0,9	B0_CL_Ortalama_XGB_16	0,95
MKVS-2	D121_Orj_(-)_DVM_200	0,8752	D121_CL_(-)_DVM_100	0,8807

Tablo 21'de verilen doğruluk, uygunluk değeri olan doğruluk skoruna karşılık gelmektedir. Tablo 21'deki karşılaştırmaya göre, veri artırma tekniği uygulanan dört veri

setinin ikisinde doğruluk skorunda artış olurken, diğer ikisinde ise azalma görülmüştür. Bu durumda, veri artırma tekniğinin yarı yarıya başarılı olduğu söylenebilir.

Çalışmanın bundan sonraki bölümünde, aynı veri setleri ile literatürde yapılan çalışmalara ait sonuçlar ve bu çalışmada elde edilen Tablo 21'deki nihai sonuçlar arasında bir karşılaştırma yapılmaktadır. Her bir veri seti için kabul edilen kombinasyonlar ve onlara ait sonuçlar Tablo 21'deki koyu olarak yazılmış kombinasyonlar ve sonuçlardır.

4.5. Literatür Karşılaştırması

Çalışmanın bu bölümünde, bu çalışmada tıbbi görüntü sınıflandırması için kullanılan beş farklı veri seti için elde edilen en iyi sonuçlar ile literatürde aynı veri setini kullanarak yapılan çalışmalara ait sonuçların karşılaştırılması yapılmaktadır. En yüksek değeri elde eden sonuçlar koyu olarak belirtilmiştir.

4.5.1. ANVS için Literatür Karşılaştırması

Tablo 22’de ANVS (LUNA16) için literatürde elde edilen sonuçlar ve bu çalışmada elde edilen en iyi sonuçlar arasında yapılan karşılaştırma verilmektedir.

Tablo 22. ANVS (LUNA16) Veri Setine Ait Literatür Karşılaştırması

Yazar	Model	Doğ.	Duy.	Kes.	F1	CK	AUC
Zhu vd. (2018)	DeepLung: 3D Faster R-CNN	0,9274	0,958	-	-	-	-
Zhai vd. (2020)	MT-CNN	-	0,84	-	-	-	0,973
Balannolla vd. (2022)	Vgg16	0,971	0,986	0,967	-	-	-
Lai vd. (2022)	ResNet101-CBAM	-	0,66	0,96	-	-	-
Lalitha ve Murugan (2023)	3D CNN – RNN	0,986	0,87	-	-	-	-
Guo vd. (2023)	3D SAACNet with GBM	0,9518	0,9735	-	-	-	0,977
Bu çalışma	Vgg16_Orj_(-)_K-EYK_1_brute_60	0,9903	0,9903	0,9903	0,9903	0,9794	0,9892

ANVS (LUNA16)’de elde edilen sonuçlar literatürdeki sonuçlar ile karşılaştırıldığında bu veri setinde elde edilmiş en yüksek skorların, çalışmada kullanılan Vgg16 modeli, filtre uygulanmamış orijinal veri türü ve K-EYK sınıflandırıcısından oluşan kombinasyonuna ait olduğu görülmektedir. ANVS (LUNA16) için bu çalışmada elde edilen doğruluk skoru, literatürdeki en yüksek sonuç olarak Lalitha ve Murugan (2023) tarafından elde edilen 0,986 doğruluk skorunu (yüzdelik olarak) 0,43 puan fark ile geride bırakmış ve daha iyi sonuç vermiştir. Diğer sınıflandırma metrikleri için yüzdelik olarak 1-33 puan aralığında daha iyi performans göstermiştir ve bütün metrikler açısından en başarılı sonuç bu çalışmaya aittir.

4.5.2. MKVS-1 için Literatür Karşılaştırması

Tablo 23'te MKVS-1 (PCam) için literatürde elde edilen sonuçlar ve bu çalışmada elde edilen en iyi sonuçlar arasında yapılan karşılaştırma verilmektedir.

Tablo 23. MKVS-1 (PCam) için Literatür Karşılaştırması

Yazar	Model	Doğ.	Duy.	Kes.	F1	CK	AUC
Xia vd. (2018)	Fine-Tuned GoogLeNet	0,843	-	-	-	-	-
Awan vd. (2018)	ResNet+DVM	0,75	-	-	-	-	-
Chen vd. (2019)	Vgg19	0,804	-	-	-	-	-
Carse vd. (2021)	Multi-Directional Masked	0,801	-	-	-	-	-
Teh ve Taylor (2022)	ResNet34	82,50±1,10	-	-	-	-	-
Bhausahab ve Kashyap (2023)	DSA temelli SSDHO	0,8681	0,802	0,851	-	-	-
Bu çalışma	B0_CL_(-)_DVM_1.0	0,813	0,813	0,8131	0,813	0,626	0,8826

Tablo 23'teki sonuçlara göre, bu çalışmada elde edilen en iyi sonuç düşük görülse de veri setinin zorluğuna rağmen literatürdeki çalışmalara yakın sonuçlar elde edilmiştir. MKVS-1 (PCam) için bu çalışmada elde edilen doğruluk skoru, literatürdeki en yüksek sonuç olarak Bhausahab ve Kashyap (2023) tarafından elde edilen 0,8681 doğruluk skorundan (yüzdelik olarak) 5,51 puan fark ile geride kalmıştır. Buna rağmen, duyarlılık, F1, CK ve AUC metrikleri için literatürdeki en yüksek skorlar bu çalışmada elde edilmiştir.

4.5.3. DR Veri Seti için Literatür Karşılaştırması

Tablo 24’te DR (RFMiD) veri seti ile literatürde elde edilen sonuçlar ve bu çalışmada elde edilen en iyi sonuçlar arasında yapılan karşılaştırma verilmektedir.

Tablo 24. DR (RFMiD) Veri Setine Ait Literatür Karşılaştırması

Yazar	Model	Doğ.	Duy.	Kes.	F1	CK	AUC
Oh ve Park (2022)	End-to-end two branck network	-	-	-	-	-	0,8826
Rodríguez vd. (2022)	Label Mask Training (LMT)	0,90	-	-	0,824	-	0,976
Sun vd. (2022)	EfficientNetB4	0,8835	-	-	0,7622	-	0,8444
Ho vd. (2022)	Ensemble Learning	-	0,8712	-	-	-	0,9295
Mittal ve Anita Rajam (2023)	Game Theory based dynamic weighted ensemble learning	0,92	0,81	0,74	0,88	-	-
Sengar vd. (2023)	EyeDeep-Net	-	0,8214	0,7268	0,7711	-	-
Bu çalışma	B0_Orj_AG_RO_50_3	0,9141	0,9141	0,9116	0,9107	0,7213	0,9236

Tablo 24’teki sonuçlara göre DR (RFMiD) veri setinin sonuçları ile literatürdeki sonuçlar karşılaştırıldığında, çalışmada elde edilen doğruluk skoru, literatürdeki en yüksek sonuç olarak Mittal ve Anita Rajam (2023) tarafından elde edilen 0,92 doğruluk skorundan (yüzdelik olarak) 0,59 puan fark ile geride kalmıştır. Öte yandan, duyarlılık, kesinlik, F1 ve CK metrikleri için literatürdeki diğer sonuçlardan (yüzdelik olarak) 4-17 puan aralığında daha iyi sonuçlar elde edilmiştir.

4.5.4. AKVS için Literatür Karşılaştırması

Tablo 25’te AKVS (TCGA-LUAD) için literatürde elde edilen sonuçlar ve bu çalışmada elde edilen en iyi sonuçlar arasında yapılan karşılaştırma verilmektedir.

Tablo 25. AKVS (TCGA-LUAD) için Literatür Karşılaştırması

Yazar	Model	VA	Doğ.	Duy.	Kes.	F1	CK	AUC
Livieris vd. (2019)	Ensemble Self-labeled (ENSL) Algorithm	-	0,72	0,76	-	0,7308	-	-
Qin vd. (2020)	3B DenseNet	+	0,72	-	-	-	-	0,92
Yang vd. (2020)	DVM	-	0,662	-	-	-	-	0,69
Chen vd. (2022)	Cycle GAN	+	-	-	-	-	-	0,78
Naqvi vd. (2023)	Karar Ağacı	+	0,89	0,89	0,85	0,86	-	0,954
Qiu vd. (2023)	PathInNL	+	0,913	0,925	-	0,913	-	0,965
Bu çalışma	B0_CL_Ortalama_XGB_16	+	0,95	0,95	0,9556	0,9504	0,898	0,9375

Tablo 25’te verilen VA kolonu, ilgili çalışmada veri artırma ön işleme tekniğinin kullanılıp kullanılmadığı hakkında bilgi vermektedir. Veri artırma ön işleme tekniği kullanılmışsa “+”, kullanılmamışsa “-” simgesi ile ifade edilmiştir. Bunun nedeni, bu çalışmada kullanılan veri setleri arasında AKVS (TCGA-LUAD) ve MKVS-2 (BreaKHis) veri setlerinde elde edilen en yüksek sonucun veri artırma ön işleme tekniği kullanılması ile mümkün olmasıdır.

Tablo 25’teki AKVS (TCGA-LUAD) için bu çalışmada EfficientNetB0 modeli, ortalama filtre uygulanmış CLAHE’li veri türü ve XGBoost sınıflandırıcısından oluşan kombinasyon, literatürdeki en yüksek doğruluk skoru sonucunu elde etmiştir. Bu kombinasyon ile elde edilen doğruluk skoru, literatürdeki en yüksek sonuç olarak Qiu vd.

(2023) tarafından elde edilen 0,913 doğruluk skorunu (yüzdelik olarak) 3,7 puan fark ile geride bırakmış ve daha iyi sonuç vermiştir. AUC skoru haricindeki diğer sınıflandırma metrikleri için yüzdelik olarak 3-22 puan aralığında daha iyi performans göstermiştir ve bu metrikler açısından en başarılı sonuçlar bu çalışmaya aittir.

4.5.5. MKVS-2 için Literatür Karşılaştırması Sonuçları

Tablo 26’da MKVS-2 (BreaKHis) için literatürde elde edilen sonuçlar ve bu çalışmada elde edilen en iyi sonuçlar arasında yapılan karşılaştırma verilmektedir.

Tablo 26. MKVS-2 (BreaKHis) için Literatür Karşılaştırması

Yazar	Model	VA	Doğ.	Duy.	Kes.	F1	CK	AUC
Saxena vd. (2021)	ResNet50- KWELM	-	0,8416	0,8424	0,8212	0,8282	-	-
Hu vd. (2021)	ResNet34	+	0,8879	0,8746	0,8065	0,8392	-	-
Zerouaoui ve Idri (2022)	MLP-DenseNet (MDEN)	+	0,9173	0,9366	0,903	0,9191	-	-
Chattopadhy ay vd. (2022)	DRDA-Net7	-	0,9684	0,952	0,981	0,9662	-	-
Yu vd. (2023)	Specialized Enhanced Classifying Strategy (SECS)	+	0,9643	0,9598	0,9728	0,9663	-	-
Jakhar vd. (2023)	Sacked-based Ensemble Learning (SELF)	+	0,9435	0,9596	0,9245	0,9414	-	0,8941
Bu çalışma	D121_CL_ (-) _DVM_100	+	0,8807	0,8807	0,8793	0,8791	0,720	0,9478

Tablo 26'daki sonuçlar göz önünde bulundurulduğunda, sınıflandırma metrikleri arasında sadece AUC skorunda Jakhar vd. (2023) tarafından elde edilen sonuca göre (yüzdelik olarak) 5,37 puanlık bir artışla iyi bir sonuç elde edilmiştir. Doğruluk skoru ile kıyaslandığı zaman literatürdeki en yüksek doğruluk skoru olan ve Chattopadhyay vd. (2022) tarafından elde edilen sonuca göre (yüzdelik olarak) 8,77 puan geride kalmıştır. BreaKHis veri seti literatürde meme kanseri ve histopatolojik görüntü içeren veri setleri arasında en popüler olanlardan biridir. Bu nedenle, bu çalışmadaki en iyi skor diğer çalışmalara nazaran (yüzdelik olarak) 0,72-8,77 puan aralığında daha düşük bir performans göstermiştir.

Özellikle, BreaKHis gibi veri setleri için modifiye edilen derin öğrenme modelleri ve histopatolojik görüntüler de sıklıkla kullanılan renk normalizasyonu teknikleri sayesinde böyle başarılı sonuçlar elde edilebilmektedir. Ancak, bu durum tüm sınıflandırma metrikleri için geçerli olmayabilir. Nitekim, Jakhar vd. (2023) tarafından geliştirilen modelde doğruluk skoru olarak 0,9435 gibi iyi bir oran elde edilmişken, bir başka sınıflandırma metriği olan AUC skoru için 0,8941 skorunu elde edilmiştir.

Farklı tıbbi görüntü formatları ve organlara ait görüntüler kullanılarak tıbbi görüntü sınıflandırma başarısının artırılması için ön işleme teknikleri ve model parametrelerinin sezgisel optimizasyonunun gerçekleştirildiği bu çalışmada, literatürdeki popüler veri setleri üzerinde iyi bir sonuç elde edilmiştir. Geliştirilen model, çoğunlukla ya literatürdeki birçok çalışmayı geride bırakacak sonuçlar elde etmiş ya da bu sonuçlar ile rekabet edebilecek düzeyde sonuçlar üretmiştir.

SONUÇ

Teknolojinin gelişmesi birçok sorunun çözümünde büyük bir kolaylık ve ilerleme sağlamıştır. 1990'lı yılların sonlarında donanım teknolojilerindeki ilerlemeler sayesinde yapay zekâ, görüntü işleme alanında sıklıkla kullanılmaya başlanmıştır. Yapay zekânın görüntü işleme alanında belirli bir doygunluğa ulaşmasından sonra farklı sektörlerde kendisinden faydalanan ve hatta kendisine danışılan güçlü bir statüye kavuşması ise pek uzun sürmemiştir. Günümüzde ise sadece tıp alanında bile hastalıkların görüntülenmesinden teşhis konulmasına, ilaç keşfinden tedavi sürecine, tıbbi cihazların geliştirilmesinden robotik cerrahi tekniklerine uzanan çok geniş bir kullanım alanı mevcuttur.

Son yılların en önemli halk sağlığı sorunlarından olan kanser hastalığının önleme, tanı ve tedavi aşamalarında da yapay zekâ ve onun alt teknolojilerinden makine öğrenmesi, derin öğrenme, doğal dil işleme vb. faydalanılmaktadır.

Kanser, günümüzde çok yaygın bir hastalık olmasına karşın erken teşhis edildiğinde önleyici yöntemler ile tedavisi kolay olan bir hastalıktır. Tıbbi görüntülerin radyolog ve patolog gibi uzmanlar tarafından incelenerek kanser hastalığına dair bir teşhis konulması, bilinen en geleneksel yöntemdir. Sağlık sektöründeki uzmanların iş yükü düşünüldüğünde bu yöntem çok maliyetli olabilmektedir. Zira, burada uzmanın yoğunluk vb. insani nedenlerden dolayı hata yapma olasılığı söz konusu olabilir. Ayrıca, 2019 yılının sonlarında ortaya çıkan ve kısa sürede tüm Dünya'da genel bir pandemiye neden olan Covid-19 gibi durumlarda sağlık uzmanlarını bile aşan olağanüstü koşullar da meydana gelebilmektedir.

Özellikle, Covid-19 pandemisi esnasında hem tıbbi görüntü verilerine açık erişimin hem de mümkün olan en kısa sürede bu verilerin kullanılarak yapılacak bir teşhisin önemi ortaya çıkmıştır. Bu nedenle, hastalık teşhisinde yapay zekânın kullanımı ile ilgili yapılan bilimsel çalışmalarda büyük bir artış yaşanmıştır. Pandemi esnasında yapay zekâ ve onun alt teknolojilerinin kullanılarak tıbbi görüntülerin işlenerek hastalık teşhisi yapılmasını sağlayan çalışmalar sadece Covid-19 ile de sınırlı tutulmamıştır. Farklı tıbbi görüntüleme teknikleri ile elde edilen tıbbi görüntüler kullanılarak hastalıkların teşhis edilmesi konusu birçok branş için çeşitlilik arz edecek düzeye gelmiştir.

Farklı hücre, doku ve organlara ait tıbbi görüntüler kullanılarak kanser hastalığının teşhisi ve sınıflandırması için birçok model geliştirilmiştir. Her kanser türü ve onlara ait tıbbi görüntüler farklılık gösterdikleri için genelleştirilebilir bir model üretilmesi çok zor bir iştir. Bu nedenle, geliştirilen bazı modellerin tıbbi görüntüyü daha iyi işleyecek ve daha yüksek bir başarı elde edecek şekilde modifiye edilmesi ya da görüntülerin filtrelenmesi pek sık görülen bir süreçtir.

Bu çalışmada, tıbbi görüntülerin sınıflandırma başarısının artırılması için model, sınıflandırıcı ve görüntü filtrelerinden oluşan büyük bir parametre uzayının DE algoritması ile sezgisel optimizasyonu yapılmıştır.

Çalışmada, kadınlar ve erkekler arasında en yaygın görülen meme ve akciğer kanserlerine ve yaygın bir göz hastalığı olan DR hastalığına ait tıbbi görüntüler içeren beş farklı veri seti kullanılmıştır. Kullanılan her bir veri seti, literatürde kendi alanında bilinen ve daha önce çalışılmış veri setleridir.

Çalışmanın amacı, hastalık sınıflandırmasında çok sayıda parametre uzayı arasında mümkün olan en yüksek başarıyı elde edecek şekilde bu arama uzayını daraltarak farklı hastalıklara yönelik genelleştirilebilir modeller ortaya koymaktır. Yani veri setine sahip olduğumuz bir hastalık için mümkün olan en başarılı modeli tespit edebilmektir.

Literatürde “state-of-the-art” olarak bilinen Vgg16, Vgg19, ResNet, EfficientNet, DenseNet ve MobileNet derin öğrenme modellerinin kullanıldığı bu çalışma, tıbbi görüntüler üzerinde birçok filtre, farklı sınıflandırıcılar ve bunlara ait hiper parametreler bulunması sebebiyle çok fazla sayıda araştırılacak olası çözüm içermektedir. Önerilen algoritma, çok sayıda parametre üzerinde sezgisel optimizasyon gerçekleştirerek makul bir sürede optimum sonuca yakınsayabilmektedir. Bu açıdan literatüre büyük katkısı bulunmaktadır.

Çalışmada ele alınacak hastalık türleri (meme, akciğer ve göz) belirlendikten sonra çevrimiçi erişime açık veri setleri temin edilmiştir. Akciğer kanseri için ANVS ve AKVS, meme kanseri için MKVS-1 ve MKVS-2, göz hastalığı için ise DR veri seti kullanılmıştır. Bu beş veri setinin tamamı literatürde kendi alanlarında popüler olan veri setleri olup, bu çalışmada önerilen algoritmanın literatürdeki aynı veri setini kullanan çalışmalarla performans açısından karşılaştırılabilmesi açısından tercih edilmiştir. Veri

setleri elde edildikten sonra orijinal ve CLAHE uygulanmış veriler olarak ikiye ayrılmıştır.

Verilerin bu şekilde ayrılmasından sonra bu verilere uygulanacak olan filtreler belirlenmiştir. Hem CLAHE ön işleme tekniğinin uygulanması hem de görüntülerin filtrelenmesindeki amaç, ön işlemenin sınıflandırma başarısına olan etkisinin ölçülmesidir.

Veri setleri ön işleme teknikleri ile işlendikten sonra IA, DE ve PSO optimizasyon yöntemlerine ile çalıştırılmıştır. Öncelikle, kullanılan parametrelerin her birini birbiriyle eşleştiren IA yöntemi ile ANVS üzerinde en yüksek sınıflandırma doğruluğu skoru elde edilmiştir. Model olarak Vgg16, Vgg19, ResNet50, EfficientNetB0 ve EfficientNetB7, sınıflandırıcı olarak DVM, RO ve YSA, görüntü filtrelemesi için AD, İKT, BM3D, Gauss, HM, Ortalama, TV ve Dalgacık filtrenin kullanıldığı aşamada toplam 270 farklı model-sınıflandırıcı-veri türü eşleşmesi durumu ortaya çıkmıştır. IA yöntemi ile optimizasyonda EfficientNetB0-DVM-filtre uygulanmış orijinal görüntü kombinasyonu 0,8947 doğruluk skoru ile en iyi sonucu elde etmiştir.

Mevcut parametreler arasında en yüksek doğruluk skorunu veren kombinasyon belirlendikten sonra, DE ve PSO optimizasyon yöntemleri yine ANVS için 10 defa çalıştırılmıştır. Bu aşamada, DE ve PSO optimizasyon yöntemlerinden hangisinin en yüksek skoru ya da ona yakın bir skoru ne sıklıkla elde ettiği görülmüştür. DE ve PSO yöntemleri arasındaki karşılaştırmada PSO algoritması en yüksek skor olan 0,8947 oranını hiç elde edememiştir. DE algoritması ise bu skoru iki defa elde etmiştir. 10 defa çalışma için DE algoritması $0,8913 \pm 0,0032$ ortalama doğruluk skoru, PSO algoritması ise $0,8848 \pm 0,0092$ ortalama doğruluk skoru elde etmiştir. Parametre sayısı çok daha fazla artırıldığında zaman açısından artık IA yöntemi anlamlı olmayacağı ve DE yöntemi PSO yöntemine göre daha başarılı bulunduğu için deneysel çalışmalarda DE algoritması ile devam edilmiştir.

DE algoritması sezgisel yöntem olarak tercih edildikten sonra mevcut beş veri seti, model ve sınıflandırıcılara eklenen yeni parametreler ile 10 defa çalıştırılmıştır. Filtrelerin sabit kaldığı bu aşamada, model olarak Vgg16, Vgg19, ResNet50, EfficientNetB0, DenseNet121 ve MobileNetv2, sınıflandırıcı olarak da DVM, RO, K-EYK, XGBoost ve YSA kullanılmıştır. Hiper parametreler, çalışmada kullanılan

sınıflandırıcılara ait olan ve onların performansını belirleyen bileşenler olup bu aşamada hiper parametre optimizasyonu da gerçekleştirilmiştir. Hiper parametrelerin de eklenmesiyle beraber, ilk aşamada 270 olan toplam kombinasyon sayısı 756'ya çıkmıştır. DE algoritması ise 15 popülasyon ve 10 iterasyon olarak kullanılmıştır.

Çalışmadaki beş veri setinin DE algoritması ile 10 defa çalıştırılmasının sonucunda; ANVS için en yüksek doğruluk skoru 0,9903 ve en iyi kombinasyon filtre uygulanmamış orijinal veri ile Vgg16 modeli ve K-EYK sınıflandırıcısı, MKVS-1 için en yüksek doğruluk skoru 0,813 ve en iyi kombinasyon CLAHE uygulanmış veri ile EfficientNetB0 modeli ve DVM sınıflandırıcısı, DR veri seti için en yüksek doğruluk skoru 0,9141 ve en iyi kombinasyon AG filtre uygulanmış orijinal veri ile EfficientNetB0 modeli ve RO sınıflandırıcısı, AKVS için en yüksek doğruluk skoru 0,9 ve en iyi kombinasyon AD filtre uygulanmış orijinal veri ile Vgg19 modeli ve XGBoost sınıflandırıcısı ve son olarak MKVS-2 için en yüksek doğruluk skoru 0,8752 ve en iyi kombinasyon filtre uygulanmamış orijinal veri ile DenseNet121 modeli ve DVM sınıflandırıcısı olarak elde edilmiştir. Ayrıca, DR veri seti için AG filtre türü de çalışmaya dahil edilmiştir. AG filtre, göz hastalıklarının tespitinde özel olarak kullanılan bir filtreleme türüdür. Bu çalışmada da dahil edilmesinin sınıflandırma başarısına etkisi görülmüştür.

Bu skorların elde edilmesinden sonra, mevcut veri setlerinden MKVS-1 veri seti haricindeki tüm veri setlerine veri artırma ön işleme tekniği uygulanmıştır. MKVS-1 veri seti ise veri sayısının fazlalığı ve uzun çalışma süresine sahip olması nedeniyle bu veri setine veri artırma uygulanmamıştır. Veri artırma ön işleme tekniği uygulanan veri setleri aynı parametre ve hiper parametreler kullanılarak DE algoritması ile 10 defa çalıştırılmıştır.

Veri artırma ön işleme tekniği uygulandıktan sonra; ANVS için en yüksek doğruluk skoru 0,9895 ve en iyi kombinasyon filtre uygulanmamış orijinal veri ile Vgg16 modeli ve K-EYK sınıflandırıcısı, DR veri seti için en yüksek doğruluk skoru 0,9094 ve en iyi kombinasyon filtre uygulanmamış orijinal veri ile DenseNet121 modeli ve XGBoost sınıflandırıcısı, AKVS için en yüksek doğruluk skoru 0,95 ve en iyi kombinasyon ortalama filtre uygulanmış CLAHE'li veri ile EfficientNetB0 modeli ve XGBoost sınıflandırıcısı ve MKVS-2 için en yüksek doğruluk skoru 0,8807 ve en iyi

kombinasyon filtre uygulanmamış CLAHE'li veri ile DenseNet121 modeli ve DVM sınıflandırıcısı olarak belirlenmiştir.

Veri artırma ön işlemi tekniği uygulandıktan sonra ANVS ve DR veri setlerinde başarı açısından küçük düşüşler yaşanmasına karşın AKVS ve MKVS-2'de ise artış görülmüştür. Özellikle, AKVS sadece 80 eğitim verisine sahip olduğu için veri artırma işleminden sonra doğruluk skorunun 0,9'dan 0,95'e yükseldiği gözlemlenmiştir.

Her biri kendi alanında bilinen veri setlerinin kullanıldığı bu çalışmada elde edilen sonuçlar, aynı veri setini önceden kullanmış çalışmalarda elde edilen sonuçlar ile karşılaştırılmıştır.

ANVS (LUNA16) için elde edilen sonuç, literatürdeki sonuçlardan çok daha başarılı bulunmuştur. Vgg16 modelinin ve K-EYK sınıflandırıcısının orijinal veri üzerinde elde ettiği 0,9903 doğruluk skoru, sonraki aşamalarda eklenen K-EYK sınıflandırıcısının ve ona ait hiper parametrelerin ne kadar önemli olduğunu göstermektedir. Zira, ilk aşamada elde edilen 0,8947 doğruluk skorunun çok üzerine çıkıldığı görülmektedir.

MKVS-1 (PCam), literatürde çok farklı veri sayısı ve veri boyutundan oluşan histopatolojik görüntülerden oluşmaktadır. Her ne kadar elde edilen 0,813 doğruluk skoru az gibi görünse de veri setinin zorluğundan dolayı bu skorun literatür ortalamasında olduğu görülmektedir. Nitekim, AUC skoru ve diğer sınıflandırma metrikleri açısından bu çalışmada elde edilen sonuç daha başarılı bulunmuştur.

DR (RFMiD) veri seti, DR göz hastalığının sınıflandırmasında kullanılan OKT görüntülerinden oluşan popüler bir veri setidir. Göz hastalıkları için çoklu sınıflandırma amacıyla oluşturulmuş bu veri seti içerisindeki DR ve normal etiketli veriler kullanılmıştır. Bu çalışmada elde edilen 0,9141 doğruluk skorunun, literatürdeki diğer sonuçlar ile karşılaştırıldığında oldukça iyi seviyelerde olduğu görülmektedir. Duyarlılık, kesinlik, F1 skor ve CK skoru olarak literatürdeki diğer çalışmalardan çok daha başarılı sonuçlar elde edilmiştir. Bu başarılı skorun elde edilmesinde, göz hastalığı sınıflandırmasında kullanılan AG filtrenin büyük bir etkisi olduğu düşünülmektedir.

AKVS (TCGA-LUAD), 100 BT görüntüsünden oluşan oldukça sınırlı bir veri setidir. Özellikle veri artırma ön işleme tekniği uygulandıktan sonra elde edilen 0,95

doğruluk skoru, literatürdeki en iyi sonucu veren çalışmalar ile karşılaştırıldığında diğer tüm çalışmalardan daha başarılı bulunmuştur.

MKVS-2 (BreaKHis), mevcut veri setleri içerisinde en popüler olanıdır. Meme kanseri sınıflandırması için farklı yakınlık seviyelerinin bulunduğu histopatolojik görüntülerden oluşur. Veri artırma işleminden sonra doğruluk skoru, 0,8752'den 0,8807'ye yükselerek çok küçük bir artış göstermiştir. Literatürdeki diğer çalışmalar ile karşılaştırıldığında yalnızca AUC skoru açısından çok başarılı bir sonuç elde ettiği görülmektedir. Özellikle 2022 ve 2023 yıllarında yapılan çalışmalarda doğruluk skoru oranının 0,84-0,88'den 0,95'lerin üzerine çıktığı görülmektedir. Bu duruma, veri seti için geliştirilen modifiye edilmiş çok yüksek hesaplama parametrelerine sahip modeller, özel filtreler ve histopatolojik görüntülere özel renk normalizasyonu işlemlerinin etkisi olduğu düşünülmektedir. İleriki çalışmalarda önerilen algoritmaya bu parametrelerin de eklenilmesinin sınıflandırma başarısını artıracığı öngörülmektedir.

Farklı organlara ve kanser türlerine ait veri setlerinin kullanıldığı bu çalışmada, sınıflandırma doğruluğunun artırılması için çözüm uzayı olabildiğince geniş tutulmaya çalışılmıştır. Bu yapılırken de en iyi çözüme ait kombinasyonun mümkün olan en kısa sürede elde edilmesi hedeflenmiştir. Tüm veri setleri için genelleştirilebilir bir model ortaya konulamamış olsa da problemleri tek başına başarılı bir şekilde modelleyecek olan parametreler sezgisel optimizasyon ile belirlenebilmiştir.

Tıbbi görüntülerin sınıflandırma başarısının artırılması için sezgisel optimizasyon kullanan çalışmalarda aynı hastalığa yönelik tek bir veri seti ile yapılmış çalışmalar, literatür taramasında çoğunluğu oluşturmaktadır. Bu yönden bakıldığında, bu çalışmanın özgün yanı, mevcut parametreler ile farklı hastalıklara yönelik birden fazla veri setinde hem literatür ortalamasına denk hem de literatürdeki en iyi sonuçları elde eden bir modelin geliştirilmiş olmasıdır.

Çalışmada elde edilen en iyi sonuçlar, literatürdeki sonuçlar ile karşılaştırıldığında özellikle ANVS (LUNA16) ve AKVS (TCGA-LUAD) için literatürdeki diğer çalışmalardan çok daha iyi sonuçlar elde edilmiştir. Diğer veri setlerinin ise çalışmada optimize edilen doğruluk skoru açısından literatüre çok yakın sonuçlar elde ettiği gözlenmiştir.

Bunun yanında, en yüksek doğruluk skorunun elde edilmesinde veri türlerinin etkisi unutulmamalıdır. Çalışmada ön işleme tekniği olarak kullanılan CLAHE yöntemi ve özellikle görüntü filtreleme tekniklerinin kullanılması genel olarak başarılı bulunmuştur. DR veri seti için göz hastalıklarının sınıflandırmasında özellikle kullanılan AG filtre, en yüksek doğruluk skorunun elde edilmesini sağlamıştır.

İleriki çalışmalarda, histopatolojik görüntüler için de bu görüntülere özgü filtrelerin ve normalizasyon tekniklerinin algoritmaya eklenilmesi düşünülmektedir.



KAYNAKÇA

- Abdellatif, A., Abdellatef, H., Kanesan, J., Chow, C. O., Chuah, J. H. ve Gheni, H. M. (2022). An effective heart disease detection and severity level classification model using machine learning and hyperparameter optimization methods. *ieee access*, 10, 79974-79985. doi: 10.1109/ACCESS.2022.3191669.
- Abdollahi, B., Tomita, N. ve Hassanpour, S. (2020). Data augmentation in training deep learning models for medical image analysis. *Deep learners and deep learner descriptors for medical applications*, 167-180. doi: 10.1007/978-3-030-42750-4_6.
- Abu Alfeilat, H. A., Hassanat, A. B., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., Eyal Salman, H. S. ve Prasath, V. S. (2019). Effects of distance measure choice on k-nearest neighbor classifier performance: a review. *Big data*, 7(4), 221-248. doi: 10.1089/big.2018.0175.
- Aggarwal, P., Mishra, N. K., Fatimah, B., Singh, P., Gupta, A. ve Joshi, S. D. (2022). Covid-19 image classification using deep learning: Advances, challenges and opportunities. *Computers in Biology and Medicine*, 144(8), 1-23. doi: 10.1016/j.compbiomed.2022.105350.
- Ahmed, T. ve Sabab, N. H. N. (2022). Classification and understanding of cloud structures via satellite images with EfficientUNet. *SN Computer Science*, 3(1), 1-11. doi: 10.1007/s42979-021-00981-2.
- Ajai, A. K., ve Anitha, A. (2022). Clustering based lung lobe segmentation and optimization based lung cancer classification using CT images. *Biomedical Signal Processing and Control*, 78(1), 103986. doi: 10.1016/j.bspc.2022.103986.
- Akciğer Kanseri Veri Seti (19.09.2023). <https://www.kaggle.com/datasets/kmader/siim-medical-images>
- Akciğer Nodülü Veri Seti (19.09.2023). <https://www.kaggle.com/kmader/lungnodemalignancy>
- Al Sabbahi, R. ve Tekli, J. (2022). Low-light homomorphic filtering network for integrating image enhancement and classification. *Signal Processing: Image Communication*, 100(1), 1-12. doi: 10.1016/j.image.2021.116527.

- Albashish, D., Al-Sayyed, R., Abdullah, A., Ryalat, M. H. ve Almansour, N. A. (2021, July). Deep cnn model based on vgg16 for breast cancer classification. *2021 International conference on information technology (ICIT)*, 805-810. doi: 10.1109/ICIT52682.2021.9491631.
- Al-Issa, Y. ve Alqudah, A. M. (2022). A lightweight hybrid deep learning system for cardiac valvular disease classification. *Scientific Reports*, 12(1), 1-20. doi: 10.1038/s41598-022-18293-7.
- Aliyi, S., Dese, K. ve Raj, H. (2023). Detection of gastrointestinal tract disorders using deep learning methods from colonoscopy images and videos. *Scientific African*, 20, 1-17. doi: 10.1016/j.sciaf.2023.e01628.
- Aljuaid, H., Alturki, N., Alsubaie, N., Cavallaro, L., ve Liotta, A. (2022). Computer-aided diagnosis for breast cancer classification using deep neural networks and transfer learning. *Computer Methods and Programs in Biomedicine*, 223(4), 1-10. doi: 10.1016/j.cmpb.2022.106951.
- Alomar, K., Aysel, H. I. ve Cai, X. (2023). Data augmentation in classification and segmentation: A survey and new strategies. *Journal of Imaging*, 9(2), 1-26. doi: 10.3390/jimaging9020046.
- Alqudah, A. M. (2020). Aoct-net: a convolutional network automated classification of multiclass retinal diseases using spectral-domain optical coherence tomography images. *Medical & biological engineering & computing*, 58(1), 41-53. doi: 10.1007/s11517-019-02066-y.
- Amini, N. ve Shalbaf, A. (2022). Automatic classification of severity of covid-19 patients using texture feature and random forest based on computed tomography images. *International Journal of Imaging Systems and Technology*, 32(1), 102-110. doi: 10.1002/ima.22679.
- Angelov, P. P., Soares, E. A., Jiang, R., Arnold, N. I. ve Atkinson, P. M. (2021). Explainable artificial intelligence: an analytical review. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 11(5), 1-13. doi: 10.1002/widm.1424.

- Ashburner, J. (2012). Spm: a history. *Neuroimage*, 62(2), 791-800. doi: 10.1016/j.neuroimage.2011.10.025.
- Aswathy, M. A. ve Jagannath, M. (2017). Detection of breast cancer on digital histopathology images: Present status and future possibilities. *Informatics in Medicine Unlocked*, 8, 74-79. doi: 10.1016/j.imu.2016.11.001.
- Atban, F., Ekinici, E., ve Garip, Z. (2023). Traditional machine learning algorithms for breast cancer image classification with optimized deep features. *Biomedical Signal Processing and Control*, 81, 1-12. doi: 10.1016/j.bspc.2022.104534.
- Atiya, S. U., Ramesh, N. V. K. ve Reddy, B. N. K. (2023). Classification of non-small cell lung cancers using deep convolutional neural networks. *Multimedia Tools and Applications*, 1-30. doi: 10.1007/s11042-023-16119-w.
- Attota, D., Tadikonda, D. N., Pethe, S., ve Khan, M. A. A. H. (2022). An ensembled method for diabetic retinopathy classification using transfer learning. *2022 IEEE 46th Annual Computers, Software, and Applications Conference (COMPSAC)*, 1444-1449. doi: 10.1109/COMPSAC54236.2022.00229.
- Awan, R., Koohbanani, N. A., Shaban, M., Lisowska, A. ve Rajpoot, N. (2018). Context-aware learning using transferable features for classification of breast cancer histology images. *Image Analysis and Recognition: 15th International Conference, ICIAR 2018, Póvoa de Varzim, Portugal, June 27–29, 2018, Proceedings 15*, 10882, 788-795. doi: 10.1007/978-3-319-93000-8_89.
- Aziz, R., Verma, C. K. ve Srivastava, N. (2018). Artificial neural network classification of high dimensional data with novel optimization approach of dimension reduction. *Annals of Data Science*, 5(12), 615-635. doi: 10.1007/s40745-018-0155-2.
- Bai, H. X., Hsieh, B., Xiong, Z., Halsey, K., Choi, J. W., Tran, T. M. L., ... ve Liao, W. H. (2020). Performance of radiologists in differentiating COVID-19 from non-COVID-19 viral pneumonia at chest CT. *Radiology*, 296(2), 46-54. doi: 10.1148/radiol.2020200823.

- Balannolla, S., Nikhath, A. K. ve Yeruva, S. (2022). Detection and Classification of Lung Carcinoma using CT scans. *Journal of Physics: Conference Series*, 2286(1), 1-8. doi: 10.1088/1742-6596/2286/1/012011.
- Bansode, B. N., KM, B., Dildar, A. S., ve GS, S. (2023). Deep CNN-based feature extraction with optimised LSTM for enhanced diabetic retinopathy detection. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 11(3), 960-975. doi: 10.1080/21681163.2022.2124545.
- Basha, S. S., Dubey, S. R., Pulabaigari, V. ve Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112-119. doi: 10.1016/j.neucom.2019.10.008.
- Becker, A. (2019). Artificial intelligence in medicine: What is it doing for us today?. *Health Policy and Technology*, 8(2), 198-205. doi: 10.1016/j.hlpt.2019.03.004.
- Berral, J. L., Aranda, O., Dominguez, J. L. ve Torres, J. (2022). Distributing deep learning hyperparameter tuning for 3d medical image segmentation. *2022 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW)*, 1045-1052. Doi: 10.1109/IPDPSW55747.2022.00172.
- Berrimi, M. ve Moussaoui, A. (2020). Deep learning for identifying and classifying retinal diseases. *2020 2nd International Conference on computer and information sciences (ICCIS)*, 1-6. doi: 10.1109/ICCIS49240.2020.9257674.
- Bhausahab, D. P. ve Kashyap, K. L. (2023). Shuffled shepherd deer hunting optimization based deep neural network for breast cancer classification using breast histopathology images. *Biomedical Signal Processing and Control*, 83(2), 1-12. doi: 10.1016/j.bspc.2023.104570.
- Bhonsle, D., Chandra, V. ve Sinha, G. R. (2012). Medical image denoising using bilateral filter. *International Journal of Image, Graphics and Signal Processing*, 4(6), 36-43. doi: 10.5815/ijigsp.2012.06.06.
- Bhosale, Y. H. ve Patnaik, K. S. (2023). PulDi-COVID: Chronic obstructive pulmonary (lung) diseases with Covid-19 classification using ensemble deep convolutional

- neural network from chest X-ray images to minimize severity and mortality rates. *Biomedical Signal Processing and Control*, 81(3), 1-17. doi: 10.1016/j.bspc.2022.104445.
- Bhowmik, A., Kumar, S. ve Bhat, N. (2019). Eye disease prediction from optical coherence tomography images with transfer learning. *Engineering Applications of Neural Networks: 20th International Conference, EANN 2019, Xersonisos, Crete, Greece, May 24-26, 2019, Proceedings 20*, 104-114. doi: 10.1007/978-3-030-20257-6_9.
- Bishnoi, V., ve Goel, N. (2023). Tensor-RT-based transfer learning model for lung cancer classification. *Journal of Digital Imaging*, 36(7553), 1364-1375. doi: 10.1007/s10278-023-00822-z.
- Boumaraf, S., Liu, X., Zheng, Z., Ma, X. ve Ferkous, C. (2021). A new transfer learning based approach to magnification dependent and independent classification of breast cancer in histopathological images. *Biomedical Signal Processing and Control*, 63, 1-12. doi: 10.1016/j.bspc.2020.102192.
- Brainder. (8 Eylül 2023). NIFTI görüntü formatı. <https://brainder.org/2015/04/03/the-nifti-2-file-format/>
- Brei, V. A. (2020). Machine learning in marketing: Overview, learning strategies, applications, and future developments. *Foundations and Trends® in Marketing*, 14(3), 173-236. doi: 10.1561/17000000065.
- Buckner, C. (2019). Deep learning: A philosophical introduction. *Philosophy compass*, 14(10), 1-19. doi: 10.1111/phc3.12625.
- Bushberg, J. T. ve Boone, J. M. (2011). The essential physics of medical imaging (3. baskı). Lippincott Williams ve Wilkins Yayınları.
- Carse, J., Carey, F. ve McKenna, S. (2021). Unsupervised representation learning from pathology images with multi-directional contrastive predictive coding. *2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI)*, 1254-1258. doi: 10.1109/ISBI48211.2021.9434140.
- Celard, P., Iglesias, E. L., Sorribes-Fdez, J. M., Romero, R., Vieira, A. S. ve Borrajo, L. (2023). A survey on deep learning applied to medical images: from simple artificial

- neural networks to generative models. *Neural Computing and Applications*, 35(3), 2291-2323. doi: 10.1007/s00521-022-07953-4.
- Chakraborty, S., Saha, A. K., Ezugwu, A. E., Agushaka, J. O., Zitar, R. A. ve Abualigah, L. (2023). Differential evolution and its applications in image processing problems: A comprehensive review. *Archives of Computational Methods in Engineering*, 30(2), 985-1040. doi: 10.1007/s11831-022-09825-5.
- Chakravarthy, S. S., Bharanidharan, N. ve Rajaguru, H. (2023). Deep learning-based metaheuristic weighted k-nearest neighbor algorithm for the severity classification of breast cancer. *IRBM*, 44(3), 1-19. doi: 10.1016/j.irbm.2022.100749.
- Chan, G. C., Kamble, R., Müller, H., Shah, S. A., Tang, T. B. ve Mériaudeau, F. (2018). Fusing results of several deep learning architectures for automatic classification of normal and diabetic macular edema in optical coherence tomography. *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 670-673. doi: 10.1109/EMBC.2018.8512371.
- Chandra, M. A. ve Bedi, S. S. (2021). Survey on SVM and their application in image classification. *International Journal of Information Technology*, 13(2), 1-11. doi: 10.1007/s41870-017-0080-1.
- Chandran, J. J. G., Jabez, J., ve Srinivasulu, S. (2023). Auto-Metric Graph Neural Network optimized with Capuchin search optimization algorithm for coinciding diabetic retinopathy and diabetic Macular edema grading. *Biomedical Signal Processing and Control*, 80(2), 1-11. doi: 10.1016/j.bspc.2022.104386.
- Chattopadhyay, S., Dey, A., Singh, P. K. ve Sarkar, R. (2022). DRDA-Net: Dense residual dual-shuffle attention network for breast cancer classification using histopathological images. *Computers in biology and medicine*, 145(10), 1-11. doi: 10.1016/j.combiomed.2022.105437.
- Chaunzwa, T. L., Hosny, A., Xu, Y., Shafer, A., Diao, N., Lanuti, M., ... ve Aerts, H. J. (2021). Deep learning classification of lung cancer histology using ct images. *Scientific reports*, 11(1), 1-12. doi: 10.1038/s41598-021-84630-x.
- Chen, J., Jiao, J., He, S., Han, G. ve Qin, J. (2019). Few-shot breast cancer metastases classification via unsupervised cell ranking. *IEEE/ACM transactions on*

- computational biology and bioinformatics*, 18(5), 1914-1923. doi: 10.1109/TCBB.2019.2960019.
- Chen, J., Wee, L., Dekker, A. ve Bermejo, I. (2022). Improving reproducibility and performance of radiomics in low-dose ct using cycle GANs. *Journal of Applied Clinical Medical Physics*, 23(10), 1-17. doi: 10.1002/acm2.13739.
- Chen, T. ve Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 785-794. doi: 10.1145/2939672.2939785.
- Chennamsetty, S. S., Safwan, M. ve Alex, V. (2018). Classification of breast cancer histology image using ensemble of pre-trained neural networks. *Image Analysis and Recognition: 15th International Conference, ICIAR 2018, Póvoa de Varzim, Portugal, June 27–29, 2018, Proceedings 15*, 804-811. doi: 10.1007/978-3-319-93000-8_91.
- Chollet, F. (2021). Deep learning with Python (1. baskı). Simon and Schuster.
- Chopard, B., Tomassini, M., Chopard, B. ve Tomassini, M. (2018). Particle swarm optimization: An introduction to metaheuristics for optimization. Natural Computing Series. Springer, Cham. 97-102. doi: 10.1007/978-3-319-93073-2_6.
- Cohen, S. (2021). The evolution of machine learning: Past, present, and future. *Artificial intelligence and deep learning in pathology*, 1-12. doi: 10.1016/B978-0-323-67538-3.00001-4.
- Corea, F. ve Corea, F. (2019). AI knowledge map: How to classify AI technologies. *An introduction to data: Everything you need to know about AI, big data and data science*, 25-29. doi: 10.1007/978-3-030-04468-8_4.
- Cox, R. W. (2012). Afni: what a long strange trip it's been. *Neuroimage*, 62(2), 743-747. doi: 10.1016/j.neuroimage.2011.08.056.
- Cui, Y., Sun, R., Liu, B., Liu, Z. ve Toe, T. T. (2023). Eye diseases classification using transfer learning of residual neural network. *2023 3rd International Symposium on Computer Technology and Information Science (ISCTIS)*, 244-248. doi: 10.1109/ISCTIS58954.2023.10213138.

- Da Nóbrega, R. V. M., Peixoto, S. A., da Silva, S. P. P., ve Rebouças Filho, P. P. (2018). Lung nodule classification via deep transfer learning in CT lung images. *2018 IEEE 31st international symposium on computer-based medical systems (CBMS)*, 244-249. doi: 10.1109/CBMS.2018.00050.
- Dayana, A. M., ve Emmanuel, W. S. (2022). An enhanced swarm optimization-based deep neural network for diabetic retinopathy classification in fundus images. *Multimedia Tools and Applications*, 81(15), 20611-20642. doi: 10.1007/s11042-022-12492-0.
- De Santis, S., Lazzaro, D., Mengoni, R. ve Morigi, S. (2022). Quantum median filter for total variation image denoising. *Annali Dell'universita'di Ferrara*, 68(2), 597-620. doi: 10.1007/s11565-022-00445-2.
- Dicom library. (8 Eylül 2023). DICOM görüntü formatı. <https://www.dicomlibrary.com/>
- Dirik, M. (2020). Al-Jazari: The Ingenious Inventor of Cybernetics and Robotics. *Journal of Soft Computing and Artificial Intelligence*, 1(1), 47-58.
- Djurović, I. (2016). BM3D filter in salt-and-pepper noise removal. *EURASIP Journal on Image and Video Processing*, 2016(1), 1-11. doi: 10.1186/s13640-016-0113-x.
- Djurović, I. (2017). Combination of the adaptive Kuwahara and BM3D filters for filtering mixed Gaussian and impulsive noise. *Signal, Image and Video Processing*, 11(4), 753-760. doi: 10.1007/s11760-016-1019-x.
- Doi, K. (2007). Computer-aided diagnosis in medical imaging: historical review, current status and future potential. *Computerized medical imaging and graphics*, 31(4-5), 198-211. doi: 10.1016/j.compmedimag.2007.02.002.
- Diyabetik Retinopati Veri Seti (19.09.2023). <https://www.kaggle.com/datasets/andrewmvd/retinal-disease-classification>
- Ebenezer, A. S., Kanmani, S. D., Sivakumar, M. ve Priya, S. J. (2022). Effect of image transformation on EfficientNet model for covid-19 CT image classification. *Materials Today: Proceedings*, 51(3), 2512-2519. doi: 10.1016/j.matpr.2021.12.121.

- Elguea-Aguinaco, Í., Serrano-Muñoz, A., Chrysostomou, D., Inziarte-Hidalgo, I., Bøgh, S. ve Arana-Arexolaleiba, N. (2023). A review on reinforcement learning for contact-rich robotic manipulation tasks. *Robotics and Computer-Integrated Manufacturing*, 81(4), 1-24. doi: 10.1016/j.rcim.2022.102517.
- Engelbrecht, A. P. (2013). Particle swarm optimization: Global best or local best?. *2013 BRICS congress on computational intelligence and 11th Brazilian congress on computational intelligence*, 124-135. doi: 10.1109/BRICS-CCI-CBIC.2013.31.
- Fang, T. (2018). A novel computer-aided lung cancer detection method based on transfer learning from GoogLeNet and median intensity projections. *2018 IEEE international conference on computer and communication engineering technology (CCET)*, 286-290. doi: 10.1109/CCET.2018.8542189.
- Feng, S., Sun, H., Yan, X., Zhu, H., Zou, Z., Shen, S. ve Liu, H. X. (2023). Dense reinforcement learning for safety validation of autonomous vehicles. *Nature*, 615(7953), 620-627. doi: 10.1038/s41586-023-05732-2.
- Ferreira, C. A., Melo, T., Sousa, P., Meyer, M. I., Shakibapour, E., Costa, P. ve Campilho, A. (2018). Classification of breast cancer histology images through transfer learning using a pre-trained inception resnet v2. *International conference image analysis and recognition*, 10882 , 763-770. doi: 10.1007/978-3-319-93000-8_86.
- Gangwar, A. K., ve Ravi, V. (2021). Diabetic retinopathy detection using transfer learning and deep learning. *Evolution in Computational Intelligence: Frontiers in Intelligent Computing: Theory and Applications (FICTA 2020)*, 1, 679-689. doi: 10.1007/978-981-15-5788-0_64.
- Garcea, F., Serra, A., Lamberti, F. ve Morra, L. (2022). Data augmentation for medical imaging: A systematic literature review. *Computers in Biology and Medicine*, 152(1), 1-20. doi: 10.1016/j.combiomed.2022.106391.
- Ghosh, S., Dasgupta, A. ve Swetapadma, A. (2019). A study on support vector machine based linear and non-linear pattern classification. *2019 International Conference on Intelligent Sustainable Systems (ICISS)*, 24-28. doi: 10.1109/ISS1.2019.8908018.

- Ginat, D. T. ve Gupta, R. (2014). Advances in computed tomography imaging technology. *Annual review of biomedical engineering*, 16(1), 431-453. doi: 10.1146/annurev-bioeng-121813-113601.
- Goertzel, B. ve C. Pennachin (Eds.) (2007). Artificial general intelligence (1.baskı). Springer.
- Gorad, B. ve Kotrappa, S. (2021). Novel dataset generation for indian brinjal plant using image data augmentation. *IOP Conference Series: Materials Science and Engineering*, 1065(1), 1-11. doi: 10.1088/1757-899X/1065/1/012041.
- Gorde, K. S., ve Gurjar, A. A. (2023). A Comparative Analysis on Diabetic Retinopathy using Deep Learning and Nature based Optimization Algorithms. *2023 International Conference on Intelligent Systems, Advanced Computing and Communication (ISACC)*, 1-9. doi: 10.1109/ISACC56298.2023.10083804.
- Gour, M., Jain, S. ve Sunil Kumar, T. (2020). Residual learning based cnn for breast cancer histopathological image classification. *International Journal of Imaging Systems and Technology*, 30(3), 621-635. doi: 10.1002/ima.22403.
- Gruetzemacher, R., Gupta, A. ve Paradise, D. (2018). 3D deep learning for detecting pulmonary nodules in CT scans. *Journal of the American Medical Informatics Association*, 25(10), 1301-1310. doi: 10.1093/jamia/ocy098.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... ve Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377. doi: 10.1016/j.patcog.2017.10.013.
- Gumus, M. ve Kiran, M. S. (2017). Crude oil price forecasting using XGBoost. *2017 International conference on computer science and engineering (UBMK)*, 1100-1103. doi: 10.1109/UBMK.2017.8093500.
- Guo, Z., Yang, J., Zhao, L., Yuan, J. ve Yu, H. (2023). 3D SAACNet with GBM for the classification of benign and malignant lung nodules. *Computers in Biology and Medicine*, 153(2), 1-12. doi: 10.1016/j.compbiomed.2022.106532.
- Gupta, G. (2011). Algorithm for image processing using improved median filter and comparison of mean, median and improved median filter. *International Journal of Soft Computing and Engineering (IJSCE)*, 1(5), 304-311.

- Gupta, S., Panwar, A., Goel, S., Mittal, A., Nijhawan, R., ve Singh, A. K. (2019). Classification of lesions in retinal fundus images for diabetic retinopathy using transfer learning. *2019 International Conference on Information Technology (ICIT)*, 342-347. doi: 10.1109/ICIT48102.2019.00067.
- Hameed, Z., Zahia, S., Garcia-Zapirain, B., Javier Aguirre, J. ve Maria Vanegas, A. (2020). Breast cancer histopathology image classification using an ensemble of deep learning models. *Sensors*, 20(16), 1-17. doi: 10.3390/s20164373.
- Hamet, P. ve Tremblay, J. (2017). Artificial intelligence in medicine. *Metabolism*, 69, 36-40. doi: 10.1016/j.metabol.2017.01.011.
- Harrison Jr, J. H., Gilbertson, J. R., Hanna, M. G., Olson, N. H., Seheult, J. N., Sorace, J. M. ve Stram, M. N. (2021). Introduction to artificial intelligence and machine learning for pathology. *Archives of pathology & laboratory medicine*, 145(10), 1228-1254. doi: 10.5858/arpa.2020-0541-CP.
- Harsono, I. W., Liawatimena, S., ve Cenggoro, T. W. (2022). Lung nodule detection and classification from Thorax CT-scan using RetinaNet with transfer learning. *Journal of King Saud University-Computer and Information Sciences*, 34(3), 567-577. Doi: 10.1016/j.jksuci.2020.03.013.
- Hassan, E., Elmougy, S., Ibraheem, M. R., Hossain, M. S., AlMutib, K., Ghoneim, A., ... ve Talaat, F. M. (2023). Enhanced deep learning model for classification of retinal optical coherence tomography images. *Sensors*, 23(12), 1-18. doi: 10.3390/s23125393.
- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778. doi: 10.48550/arXiv.1512.03385.
- He, X., Yang, H., Hu, Z. ve Lv, C. (2022). Robust lane change decision making for autonomous vehicles: An observation adversarial reinforcement learning approach. *IEEE Transactions on Intelligent Vehicles*, 8(1), 184-193. doi: 10.1109/TIV.2022.3165178.
- Hekmatmanesh, A., Wu, H., Jamaloo, F., Li, M. ve Handroos, H. (2020). A combination of CSP-based method with soft margin SVM classifier and generalized RBF kernel

- for imagery-based brain computer interface applications. *Multimedia Tools and Applications*, 79(6), 17521-17549. doi: 10.1007/s11042-020-08675-2.
- Hendee, W. R. ve Ritenour, E. R. (2002). Medical imaging physics (4. baskı). Wiley.
- Herliana, A., Arifin, T., Susanti, S., ve Hikmah, A. B. (2018). Feature selection of diabetic retinopathy disease using particle swarm optimization and neural network. *2018 6th international conference on cyber and IT service management (CITSM)*, 1-4. doi: 10.1109/CITSM.2018.8674295.
- Hire, M., ve Shinde, S. (2018). Ant colony optimization based exudates segmentation in retinal fundus images and classification. *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBE)*, 1-6. doi: 10.1109/ICCUBE.2018.8697727.
- Ho, E., Wang, E., Youn, S., Sivajohan, A., Lane, K., Chun, J. ve Hutnik, C. M. (2022). Deep Ensemble Learning for Retinal Image Classification. *Translational Vision Science & Technology*, 11(10), 39-39.
- Holzinger, A., Langs, G., Denk, H., Zatloukal, K. ve Müller, H. (2019). Causability and explainability of artificial intelligence in medicine. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(4), 1-13. doi: 10.1002/widm.1312.
- Homod, R. Z., Togun, H., Hussein, A. K., Al-Mousawi, F. N., Yaseen, Z. M., Al-Kouz, W., ... ve Hussein, O. A. (2022). Dynamics analysis of a novel hybrid deep clustering for unsupervised learning by reinforcement of multi-agent to energy saving in intelligent buildings. *Applied Energy*, 313(9), 1-21. doi: 10.1016/j.apenergy.2022.118863.
- Houssein, E. H., Emam, M. M., ve Ali, A. A. (2022). An optimized deep learning architecture for breast cancer diagnosis based on improved marine predators algorithm. *Neural Computing and Applications*, 34(20), 18015-18033. doi: 10.1007/s00521-022-07445-5.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... ve Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*. doi: 10.48550/arXiv.1704.04861.

- Hu, C., Sun, X., Yuan, Z. ve Wu, Y. (2021). Classification of breast cancer histopathological image with deep residual learning. *International Journal of Imaging Systems and Technology*, 31(3), 1583-1594. doi: 10.1002/ima.22548.
- Hu, Y., Zhong, Z., Wang, R., Liu, H., Tan, Z. ve Zheng, W. S. (2021). Data augmentation in logit space for medical image classification with limited training data. *Medical Image Computing and Computer Assisted Intervention–MICCAI 2021: 24th International Conference, Strasbourg, France, September 27–October 1, 2021, Proceedings, Part V* 24, 469-479. doi: 10.1007/978-3-030-87240-3_45.
- Huang, D., Swanson, E. A., Lin, C. P., Schuman, J. S., Stinson, W. G., Chang, W., ... ve Fujimoto, J. G. (1991). Optical coherence tomography. *science*, 254(5035), 1178-1181. doi: 10.1126/science.195716.
- Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708. doi: 10.48550/arXiv.1608.06993.
- Humayun, M., Sujatha, R., Almuayqil, S. N., ve Jhanjhi, N. Z. (2022). A transfer learning approach with a convolutional neural network for the classification of lung carcinoma. *Healthcare*, 10(6), 1058-1072. doi: 10.3390/healthcare10061058.
- Hussain, Z., Gimenez, F., Yi, D. ve Rubin, D. (2017). Differential data augmentation techniques for medical imaging classification tasks. *AMIA annual symposium proceedings*, 979-984. PMID: 29854165.
- Ibrahim, D. M., Elshennawy, N. M. ve Sarhan, A. M. (2021). Deep-chest: multi-classification deep learning model for diagnosing covid-19, pneumonia, and lung cancer chest diseases. *Computers in biology and medicine*, 132(2), 1-13. doi: 10.1016/j.compbimed.2021.104348.
- Iqbal, S., Qureshi, A. N., Ullah, A., Li, J. ve Mahmood, T. (2022). Improving the Robustness and Quality of Biomedical CNN Models through Adaptive Hyperparameter Tuning. *Applied Sciences*, 12(22), 1-20. doi: 10.3390/app122211870.

- Ismael, S. H., Kareem, S. W. ve Almukhtar, F. H. (2020). Medical image classification using different machine learning algorithms. *AL-Rafidain Journal of Computer Sciences and Mathematics*, 14(1), 135-147. doi: 10.33899/CSMJ.2020.164682.
- Ito, K. ve Xiong, K. (2000). Gaussian filters for nonlinear filtering problems. *IEEE transactions on automatic control*, 45(5), 910-927. doi: 10.1109/9.855552.
- Jabbar, M. K., Yan, J., Xu, H., Ur Rehman, Z. ve Jabbar, A. (2022). Transfer learning-based model for diabetic retinopathy diagnosis using retinal images. *Brain Sciences*, 12(5), 1-12. doi: 10.3390/brainsci12050535.
- Jadhav, A. S., Patil, P. B., ve Biradar, S. (2021). Optimal feature selection-based diabetic retinopathy detection using improved rider optimization algorithm enabled with deep learning. *Evolutionary intelligence*, 14(4) 1431-1448. doi: 10.1007/s12065-020-00400-0.
- Jakhar, A. K., Gupta, A. ve Singh, M. (2023). SELF: a stacked-based ensemble learning framework for breast cancer classification. *Evolutionary Intelligence*, 1-16. doi: 0.1007/s12065-023-00824-4.
- Janani, M. ve Jebakumar, R. (2023). Detection and classification of groundnut leaf nutrient level extraction in RGB images. *Advances in Engineering Software*, 175(12), 1-10. doi: 10.1016/j.advengsoft.2022.103320.
- Jenkinson, M., Beckmann, C. F., Behrens, T. E., Woolrich, M. W. ve Smith, S. M. (2012). Fsl. *Neuroimage*, 62(2), 782-790. doi: 10.1016/j.neuroimage.2011.09.015.
- Jiang, H., Diao, Z., Shi, T., Zhou, Y., Wang, F., Hu, W., ... ve Yao, Y. D. (2023). A review of deep learning-based multiple-lesion recognition from medical images: classification, detection and segmentation. *Computers in Biology and Medicine*, 157(1), 1-22. doi: 10.1016/j.combiomed.2023.106726.
- Jiwani, N., Gupta, K., Sharif, M. H. U., Datta, R., Habib, F., ve Afreen, N. (2023). Application of transfer learning approach for diabetic retinopathy classification. *2023 International Conference on Power Electronics and Energy (ICPEE)*, 1-4. doi: 10.1109/ICPEE54198.2023.10060777.
- Jordan, M. I. ve Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. doi: 10.1126/science.aaa8415.

- Ju, H., Juan, R., Gomez, R., Nakamura, K. ve Li, G. (2022). Transferring policy of deep reinforcement learning from simulation to reality for robotics. *Nature Machine Intelligence*, 4(12), 1077-1087. doi: 10.1038/s42256-022-00573-6.
- Junior, F. E. F. ve Yen, G. G. (2019). Particle swarm optimization of deep neural networks architectures for image classification. *Swarm and Evolutionary Computation*, 49, 62-74. doi: 10.1016/j.swevo.2019.05.010.
- Kaplan, A. ve Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business horizons*, 62(1), 15-25. doi: 10.1016/j.bushor.2018.08.004.
- Karthik, R., Menaka, R., Hariharan, M. ve Won, D. (2022). Contour-enhanced attention CNN for CT-based Covid-19 segmentation. *Pattern Recognition*, 125(2), 1-16. doi: 10.1016/j.patcog.2022.108538.
- Karthikeyan, R., ve Alli, P. (2018). Feature selection and parameters optimization of support vector machines based on hybrid glowworm swarm optimization for classification of diabetic retinopathy. *Journal of medical systems*, 42(10), 1-11. Doi: 10.1007/s10916-018-1055-x.
- Kasim, Ö. (2023). Ensemble classification based optimized transfer learning feature method for early stage diagnosis of diabetic retinopathy. *Journal of Ambient Intelligence and Humanized Computing*, 14(8), 1-12. doi: 10.1007/s12652-023-04648-z.
- Ke, Q., Zhang, J., Wei, W., Połap, D., Woźniak, M., Kośmider, L. ve Damaševičius, R. (2019). A neuro-heuristic approach for recognition of lung diseases from X-ray images. *Expert systems with applications*, 126, 218-232. doi: 10.1016/j.eswa.2019.01.060.
- Kennedy, J. ve Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95-international conference on neural networks*, 4, 1942-1948. doi: 10.1109/ICNN.1995.488968.
- Ker, J., Singh, S. P., Bai, Y., Rao, J., Lim, T. ve Wang, L. (2019). Image thresholding improves 3-dimensional convolutional neural network diagnosis of different acute

- brain hemorrhages on computed tomography scans. *Sensors*, 19(9), 1-12. doi: 10.3390/s19092167.
- Khan, S., Islam, N., Jan, Z., Din, I. U., ve Rodrigues, J. J. C. (2019). A novel deep learning based framework for the detection and classification of breast cancer using transfer learning. *Pattern Recognition Letters*, 125, 1-6. doi: 10.1016/j.patrec.2019.03.022.
- Khaparde, A., Chapadgaonkar, S., Kowdiki, M., ve Deshmukh, V. (2023). An Attention-Based Swin U-Net-Based Segmentation and Hybrid Deep Learning Based Diabetic Retinopathy Classification Framework Using Fundus Images. *Sensing and Imaging*, 24(1), 1-38. doi: 10.1007/s11220-023-00426-5.
- Kirkerød, M., Borgli, R. J., Thambawita, V., Hicks, S., Riegler, M. A. ve Halvorsen, P. (2019). Unsupervised preprocessing to improve generalisation for medical image classification. *2019 13th International Symposium on Medical Information and Communication Technology (ISMICT)*, 1-6. Doi: 10.1109/ISMICT.2019.8743979.
- Kollias, D., Arsenos, A. ve Kollias, S. (2022). Ai-mia: Covid-19 detection and severity analysis through medical imaging. *European Conference on Computer Vision* (pp. 677-690). doi: 10.1007/978-3-031-25082-8_46.
- Komura, D. ve Ishikawa, S. (2018). Machine learning methods for histopathological image analysis. *Computational and structural biotechnology journal*, 16, 34-42. doi: 10.1016/j.csbj.2018.01.001.
- Krishnamoorthy, S., Weifeng, Y., Luo, J., ve Kardy, S. (2023). H1DBi-R Net: Hybrid 1D bidirectional rnn for efficient diabetic retinopathy detection and classification. *Artificial Intelligence Review*, 1-29. doi: 10.1007/s10462-023-10589-y.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25(2), 1097-1105. doi: 10.1145/3065386.
- Kumbhare, S., Kathole, A. B. ve Shinde, S. (2023). Federated learning aided breast cancer detection with intelligent Heuristic-based deep learning framework. *Biomedical Signal Processing and Control*, 86, 1-18. doi: 10.1016/j.bspc.2023.105080.

- Lai, K. D., Le, T. H. ve Nguyen, T. T. (2022). Image classification of lung nodules by requiring the integration of attention mechanism into ResNet model. *2022 14th International Conference on Knowledge and Systems Engineering (KSE)*, 1-5. doi: 10.1109/KSE56063.2022.9953758.
- Lalitha, S. ve Murugan, D. (2023). Segmentation and classification of 3D lung tumor diagnoses using convolutional neural networks. *2023 Second International Conference on Augmented Intelligence and Sustainable Systems (ICAISS)*, 230-238. doi: 10.1109/ICAISS58487.2023.10250625.
- Landini, L., Positano, V. ve Santarelli, M. F. (2008). 3D medical image processing. *Image Processing in Radiology* (pp. 67-85). doi: 10.1007/978-3-540-49830-8_6.
- Larobina, M. ve Murino, L. (2014). Medical image file formats. *Journal of digital imaging*, 27(2), 200-206. doi: 10.1007/s10278-013-9657-9.
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444. doi: 10.1038/nature14539.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. ve Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541-551. doi: 10.1162/neco.1989.1.4.541.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. doi: 10.1109/5.726791.
- Leon, M. ve Xiong, N. (2014). Investigation of mutation strategies in differential evolution for solving global optimization problems. *Artificial Intelligence and Soft Computing: 13th International Conference, ICAISC 2014, Zakopane, Poland, June 1-5, 2014, Proceedings, Part I 13*, 8467, 372-383. doi: 10.1007/978-3-319-07173-2_32.
- Lewis, J., Cha, Y. J. ve Kim, J. (2023). Dual encoder–decoder-based deep polyp segmentation network for colonoscopy images. *Scientific Reports*, 13(1), 1-12. doi: 10.1038/s41598-023-28530-2.
- Li, C. F., Xu, Y. D., Ding, X. H., Zhao, J. J., Du, R. Q., Wu, L. Z. ve Sun, W. P. (2022). MultiR-net: a novel joint learning network for COVID-19 segmentation and

- classification. *Computers in Biology and Medicine*, 144(2), 1-13. doi: 10.1016/j.compbiomed.2022.105340
- Li, G., Yang, Y., Li, S., Qu, X., Lyu, N. ve Li, S. E. (2022). Decision making of autonomous vehicles in lane change scenarios: Deep reinforcement learning approaches with risk awareness. *Transportation research part C: emerging technologies*, 134(5), 1-18. doi: 10.1016/j.trc.2021.103452.
- Li, X., Morgan, P. S., Ashburner, J., Smith, J. ve Rorden, C. (2016). The first step for neuroimaging data analysis: dicom to nifti conversion. *Journal of neuroscience methods*, 264, 47-56. doi: 10.1016/j.jneumeth.2016.03.001.
- Li, Z., Liu, F., Yang, W., Peng, S. ve Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*. 33(12), 1-21. doi: 10.1109/TNNLS.2021.3084827.
- Liang, W., Liang, Y. ve Jia, J. (2023). MiAMix: Enhancing image classification through a multi-stage augmented mixed sample data augmentation method. *arXiv preprint arXiv:2308.02804*. doi: 10.48550/arXiv.2308.02804.
- Liew, X. Y., Hameed, N. ve Clos, J. (2021). An investigation of XGBoost-based algorithm for breast cancer classification. *Machine Learning with Applications*, 6(3), 1-15. doi: 10.1016/j.mlwa.2021.100154.
- Lin, M., Bao, G., Sang, X. ve Wu, Y. (2022). Recent advanced deep learning architectures for retinal fluid segmentation on optical coherence tomography images. *Sensors*, 22(8), 1-21. doi: 10.3390/s22083055.
- Liu, J., Musialski, P., Wonka, P. ve Ye, J. (2012). Tensor completion for estimating missing values in visual data. *IEEE transactions on pattern analysis and machine intelligence*, 35(1), 208-220. doi: 10.1109/TPAMI.2012.39.
- Livieris, I., Kanavos, A. ve Pintelas, P. (2019). Detecting lung abnormalities from X-rays using an improved SSL algorithm. *Electronic Notes in Theoretical Computer Science*, 343, 19-33. doi: 10.1016/j.entcs.2019.04.008.
- Loheswaran, K. (2020). Optimized KFCM Segmentation and RNN Based Classification System for Diabetic Retinopathy Detection. *ICCCE 2020: Proceedings of the 3rd*

- International Conference on Communications and Cyber Physical Engineering*, 698, 1309-1322. doi: 10.1007/978-981-15-7961-5_119.
- Loverdos, K., Fotiadis, A., Kontogianni, C., Iliopoulou, M. ve Gaga, M. (2019). Lung nodules: a comprehensive review on current approach and management. *Annals of thoracic medicine*, 14(4), 226-238. doi: 10.4103/atm.ATM_110_19.
- LUNA16 yarışması (19.09.2023). <https://luna16.grand-challenge.org/>
- Luo, X., Li, J., Chen, M., Yang, X. ve Li, X. (2021). Ophthalmic disease detection via deep learning with a novel mixture loss function. *IEEE Journal of Biomedical and Health Informatics*, 25(9), 3332-3339. doi: 10.1109/JBHI.2021.3083605.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR).[Internet]*, 9(1), 381-386. doi: 10.54254/2755-2721/4/20230355.
- Mahmud, M. I., Mamun, M., ve Abdelgawad, A. (2023). A Deep analysis of transfer learning based breast cancer detection using histopathology images. *2023 10th International Conference on Signal Processing and Integrated Networks (SPIN)*, 198-204. doi: 10.1109/SPIN57001.2023.10117110.
- Malakouti, S. M. (2023). Heart disease classification based on ECG using machine learning models. *Biomedical Signal Processing and Control*, 84(5), 1-7. doi: 10.1016/j.bspc.2023.104796.
- Maleki, N., Zeinali, Y. ve Niaki, S. T. A. (2021). A k-nn method for lung cancer prognosis with the use of a genetic algorithm for feature selection. *Expert Systems with Applications*, 164(5), 1-7. doi: 10.1016/j.eswa.2020.113981.
- Malik, H. ve Anees, T. (2022). BDCNet: Multi-classification convolutional neural network model for classification of covid-19, pneumonia, and lung cancer from chest radiographs. *Multimedia Systems*, 28(3), 815-829. doi: 10.1007/s00530-021-00878-3.
- Malik, H., Anees, T., Din, M. ve Naeem, A. (2023). CDC_Net: Multi-classification convolutional neural network model for detection of COVID-19, pneumothorax, pneumonia, lung Cancer, and tuberculosis using chest X-rays. *Multimedia Tools and Applications*, 82(9), 13855-13880. doi: 10.1007/s11042-022-13843-7.

- Martinez-Murcia, F. J., Ortiz, A., Ramírez, J., Górriz, J. M., ve Cruz, R. (2021). Deep residual transfer learning for automatic diagnosis and grading of diabetic retinopathy. *Neurocomputing*, 452(2), 424-434. doi: 10.1016/j.neucom.2020.04.148.
- Mascarenhas, S. ve Agarwal, M. (2021). A comparison between vgg16, vgg19 and ResNet50 architecture frameworks for image classification. *2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON)*, 1, 96-99. doi: 10.1109/CENTCON52345.2021.9687944.
- Matsuo, Y., LeCun, Y., Sahani, M., Precup, D., Silver, D., Sugiyama, M., ... ve Morimoto, J. (2022). Deep learning, reinforcement learning, and world models. *Neural Networks*, 152, 267-275. doi: 10.1016/j.neunet.2022.03.037.
- Mattiuzzi, C. ve Lippi, G. (2020). Cancer statistics: a comparison between world health organization (WHO) and global burden of disease (GBD). *European journal of public health*, 30(5), 1026-1027. doi: 10.1093/eurpub/ckz216.
- Maulidina, F., Rustam, Z., ve Pandelaki, J. (2021). Lung cancer classification using support vector machine and hybrid particle swarm optimization-genetic algorithm. *2021 International Conference on Decision Aid Sciences and Application (DASA)*, 751-755. doi: 10.1109/DASA53625.2021.9682259.
- Meme Kanseri Veri Seti-1 (19.09.2023).
<https://www.kaggle.com/competitions/histopathologic-cancer-detection>
- Meme Kanseri Veri Seti-2 (19.09.2023).
<https://www.kaggle.com/datasets/forderation/breakhis-400x>
- Michalski, R. S., Carbonell, J. G., ve Mitchell, T. M. (Eds.). (2013). Machine learning: An artificial intelligence approach (1. baskı). Springer Science ve Business Media Yayınları.
- Mikołajczyk, A. ve Grochowski, M. (2018). Data augmentation for improving deep learning in image classification problem. *2018 international interdisciplinary PhD workshop (IIPHDW)*, 117-122. doi: 10.1109/IIPHDW.2018.8388338.

- Mirjalili, S. (2015a). The ant lion optimizer. *Advances in engineering software*, 83, 80-98. doi: 10.1016/j.advengsoft.2015.01.010.
- Mirjalili, S. (2015b). Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm. *Knowledge-based systems*, 89, 228-249. doi: 10.1016/j.knosys.2015.07.006.
- Mishra, P., Biancolillo, A., Roger, J. M., Marini, F. ve Rutledge, D. N. (2020). New data preprocessing trends based on ensemble of multiple preprocessing techniques. *TrAC Trends in Analytical Chemistry*, 132(3), 1-12. doi: 10.1016/j.trac.2020.116045.
- Mittal, H. ve Saraswat, M. (2019). Classification of histopathological images through bag-of-visual-words and gravitational search algorithm. *Soft Computing for Problem Solving: SocProS 2017, Volume 2*, 817, 231-241. doi: 10.1007/978-981-13-1595-4_18.
- Mittal, K. ve Anita Rajam, V. M. (2023). Game theory-based dynamic weighted ensemble for retinal disease classification. *Intelligent Automation & Soft Computing*, 35(2), 1907-1921. doi: 10.32604/iasc.2023.029037.
- Mohamed, T. I., Oyelade, O. N., ve Ezugwu, A. E. (2023). Automatic detection and classification of lung cancer CT scans based on deep learning and ebola optimization search algorithm. *Plos one*, 18(8), 1-33. doi: 10.1371/journal.pone.0285796.
- Mohammed, S. H. ve Çinar, A. (2021). Lung cancer classification with convolutional neural network architectures. *Qubahan Acad. J*, 1(1), 33-39. doi: 10.48161/qaj.v1n1a33.
- Montazeri, M., Baghshah, M. S. ve Enhesari, A. (2015). Hyper-Heuristic algorithm for finding efficient features in diagnose of lung cancer disease. *arXiv preprint arXiv:1512.04652*. doi: 10.48550/arXiv.1512.04652.
- Mueller, J. P. ve Massaron, L. (2021). Machine learning for dummies (1. baskı). John Wiley ve Sons Yayınları.
- Mumcuoglu, T., Erdurman, C. ve Durukan, A. H. (2008). Optik koherens tomografi prensipleri ve uygulamadaki yenilikler. *Turk J Ophthalmol*, 38, 168-75.

- Mungra, D., Agrawal, A., Sharma, P., Tanwar, S. ve Obaidat, M. S. (2020). PRATIT: a cnn-based emotion recognition system using histogram equalization and data augmentation. *Multimedia Tools and Applications*, 79, 2285-2307. doi: 10.1007/s11042-019-08397-0.
- Murphy, K. P. (2022). Probabilistic machine learning: an introduction (1. baskı). MIT press.
- Murugesan, M., Arieth, R. M., Balraj, S. ve Nirmala, R. (2023). Colon cancer stage detection in colonoscopy images using YOLOv3 MSF deep learning architecture. *Biomedical Signal Processing and Control*, 80(7), 1-8. doi: 10.1016/j.bspc.2022.104283.
- Mustra, M., Delac, K. ve Grgic, M. (2008). Overview of the DICOM standard. *2008 50th International Symposium ELMAR, I*, 39-44.
- Nadimi, M., Divyanth, L. G. ve Paliwal, J. (2023). Automated detection of mechanical damage in flaxseeds using radiographic imaging and machine learning. *Food and Bioprocess Technology*, 16(3), 526-536. doi: 10.1007/s11947-022-02939-5.
- Nandipati, B. L., ve Devarakonda, N. (2023). Vgg19+ CNN: Deep learning-based lung cancer classification with meta-heuristic feature selection methodology. *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, 11(1), 248-266. doi: 10.52549/ijeai.v11i1.4394.
- Naqvi, A. A. T., Rizvi, S. A. M. ve Hassan, M. I. (2023). Pan-cancer analysis of Chromobox (CBX) genes for prognostic significance and cancer classification. *Biochimica et Biophysica Acta (BBA)-Molecular Basis of Disease*, 1869(1), 1-13. doi: 10.1016/j.bbadis.2022.166561.
- Nawaz, W., Ahmed, S., Tahir, A. ve Khan, H. A. (2018). Classification of breast cancer histology images using alexnet. *Image Analysis and Recognition: 15th International Conference, ICIAR 2018, Póvoa de Varzim, Portugal, June 27–29, 2018, Proceedings 15*, 10882, 869-876. doi: 10.1007/978-3-319-93000-8_99.
- Nayak, D. R., Das, D., Majhi, B., Bhandary, S. V. ve Acharya, U. R. (2021). ECNet: An evolutionary convolutional network for automated glaucoma detection using

- fundus images. *Biomedical Signal Processing and Control*, 67(11), 1-9. doi: 10.1016/j.bspc.2021.102559.
- Nimh. (15 Mayıs 2020). NIFTI görüntü formatı. <https://nifti.nimh.nih.gov/nifti-1/>
- Oh, Y. T. ve Park, H. (2022). End-to-end two-branch classifier for retinal imaging analysis. *2022 International Conference on Electronics, Information, and Communication (ICEIC)*, 1-3. doi: 10.1109/ICEIC54506.2022.9748765.
- Omran, M. G., Engelbrecht, A. P. ve Salman, A. (2006). Particle swarm optimization for pattern recognition and image processing. *Swarm intelligence in data mining*, 34, 125-151. doi: 10.1007/978-3-540-34956-3_6.
- Opencv. (1 Ekim 2023). Ağırlıklandırılmış Gauss Filtre. https://docs.opencv.org/3.4/d5/dc4/tutorial_adding_images.html
- O'Shea, K. ve Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*. doi: 10.48550/arXiv.1511.08458.
- Otoni, A. L. C., de Amorim, R. M., Novo, M. S. ve Costa, D. B. (2023). Tuning of data augmentation hyperparameters in deep learning to building construction image classification with small datasets. *International Journal of Machine Learning and Cybernetics*, 14(1), 171-186. doi: 10.1007/s13042-022-01555-1.
- Ou, X., Gao, L., Quan, X., Zhang, H., Yang, J. ve Li, W. (2022). BFENet: A two-stream interaction cnn method for multi-label ophthalmic diseases classification with bilateral fundus images. *Computer Methods and Programs in Biomedicine*, 219(12), 1-8. doi: 10.1016/j.cmpb.2022.106739.
- Oyelade, O. N., ve Ezugwu, A. E. (2022). Characterization of abnormalities in breast cancer images using nature-inspired metaheuristic optimized convolutional neural networks model. *Concurrency and Computation: Practice and Experience*, 34(4), 1-25. doi: 10.1002/cpe.6629.
- Ozdil, O. ve Gunes, A. (2015). Unsupervised hyperspectral image segmentation using adaptive bilateral filtering. *2015 23rd Signal Processing and Communications Applications Conference (SIU)*, 1010-1013. Doi: 10.1109/SIU.2015.7130003.

- Özdoğan, M. (27 Eylül 2023). 2020 Yılı Türkiye Kanser İstatistikleri .
<https://www.drozdogan.com/turkiye-kanser-istatistikleri-2020/>
- Özen, Ş. K. ve Akşahin, M. F. (2020, November). Automatic brain tissue segmentation on TOF MRA image. *2020 Medical Technologies Congress (TIPTEKNO)*, 1-4. doi: 10.1109/TIPTEKNO50054.2020.9299302.
- Öztemel, E. (2006). Yapay sinir ağları. Papatya Yayınları.
- Page, J., Bain, M. ve Mukhlis, F. (2018). The risks of low level narrow artificial intelligence. *2018 IEEE international conference on intelligence and safety for robotics (ISR)*, 1-6. doi: 10.1109/IISR.2018.8535903.
- Pal, R. ve Saraswat, M. (2019). Histopathological image classification using enhanced bag-of-feature with spiral biogeography-based optimization. *Applied Intelligence*, 49(3), 3406-3424. doi: 10.1007/s10489-019-01460-1.
- Pan, J., Hofmanninger, J., Nenning, K. H., Prayer, F., Röhrich, S., Sverzellati, N., ... ve Langs, G. (2023). Unsupervised machine learning identifies predictive progression markers of IPF. *European Radiology*, 33(2), 925-935. doi: 10.1007/s00330-022-09101-x.
- Pannu, A. (2015). Artificial intelligence and its application in different areas. *Artificial Intelligence*, 4(10), 79-84. doi: IJEIT1412201504_15.
- Pantanowitz, L. (2010). Digital images and the future of digital pathology. *Journal of pathology informatics*, 1(15), 1-4. doi: 10.4103/2153-3539.68332.
- Park, H. ve Monahan, C. (2019). Genetic deep learning for lung cancer screening. *arXiv preprint arXiv:1907.11849*. doi: 10.48550/arXiv.1907.11849.
- Park, M., Kang, B., Jin, S. J. ve Luo, S. (2009). Computer aided diagnosis system of medical images using incremental learning method. *Expert Systems with Applications*, 36(3), 7242-7251. doi: 10.1016/j.eswa.2008.09.058.
- Parmar, H. S., Nutter, B., Long, R., Antani, S. ve Mitra, S. (2020). Deep learning of volumetric 3D CNN for fMRI in Alzheimer's disease classification. *Medical Imaging 2020: Biomedical Applications in Molecular, Structural, and Functional Imaging*, 7(5), 66-71. doi: 10.1117/1.jmi.7.5.056001.

- Parvathy, V. S., Pothiraj, S. ve Sampson, J. (2021). Hyperparameter optimization of deep neural network in multimodality fused medical image classification for medical and industrial IoT. *Smart Sensors for Industrial Internet of Things: Challenges, Solutions and Applications*, 127-146. Doi: 10.1007/978-3-030-52624-5_9.
- Pena, M. L. C., Carballal, A., Rodríguez-Fernández, N., Santos, I. ve Romero, J. (2021). Artificial intelligence applied to conceptual design. A review of its use in architecture. *Automation in Construction*, 124(3-4), 1-30 . doi: 10.1016/j.autcon.2021.103550.
- Pérez-García, F., Sparks, R. ve Ourselin, S. (2021). TorchIO: a Python library for efficient loading, preprocessing, augmentation and patch-based sampling of medical images in deep learning. *Computer Methods and Programs in Biomedicine*, 208, 1-12. doi: 10.1016/j.cmpb.2021.106236.
- Perona, P. ve Malik, J. (1990). Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on pattern analysis and machine intelligence*, 12(7), 629-639. doi: 10.1109/34.56205.
- Pethuraj, M. S., Aboobaidar, B. B. M. ve Salahuddin, L. B. (2022). Analyzing ct images for detecting lung cancer by applying the computational intelligence-based optimization techniques. *Computational Intelligence*, 1-20. doi: 10.1111/coin.12567.
- Pham, T. D. (2020). Classification of benign and metastatic lymph nodes in lung cancer with deep learning. *2020 IEEE 20th International Conference on Bioinformatics and Bioengineering (BIBE)*, 728-733. doi: 10.1109/BIBE50027.2020.00124.
- Ping, X., Yang, F., Zhang, H., Xing, C., Yao, B. ve Wang, Y. (2022). An outlier removal and feature dimensionality reduction framework with unsupervised learning and information theory intervention for organic Rankine cycle (ORC). *Energy*, 254, 1-13. doi: 10.1016/j.energy.2022.124268.
- Podoleanu, A. G. (2012). Optical coherence tomography. *Journal of microscopy*, 247(3), 209-219. doi: 10.1111/j.1365-2818.2012.03619.x.
- Pour, A. M., Seyedarabi, H., Jahromi, S. H. A. ve Javadzadeh, A. (2020). Automatic detection and monitoring of diabetic retinopathy using efficient convolutional

- neural networks and contrast limited adaptive histogram equalization. *IEEE Access*, 8, 136668-136673. doi: 10.1109/ACCESS.2020.3005044.
- Prabukumar, M., Agilandeewari, L., ve Ganesan, K. (2019). An intelligent lung cancer diagnosis system using cuckoo search optimization and support vector machine classifier. *Journal of ambient intelligence and humanized computing*, 10(3), 267-293. doi: 10.1007/s12652-017-0655-5.
- Prajapati, G. L. ve Patle, A. (2010). On performing classification using SVM with radial basis and polynomial kernel functions. *2010 3rd International Conference on Emerging Trends in Engineering and Technology*, 512-515. doi: 10.1109/ICETET.2010.134.
- Pramanik, P., Mukhopadhyay, S., Mirjalili, S., ve Sarkar, R. (2023). Deep feature selection using local search embedded social ski-driver optimization algorithm for breast cancer detection in mammograms. *Neural Computing and Applications*, 35(7), 5479-5499. doi: 10.1007/s00521-022-07895-x.
- Prasad, U., Chakravarty, S., ve Mahto, G. (2023). Lung cancer detection and classification using deep neural network based on hybrid metaheuristic algorithm. *Soft Computing*, 1-24. doi: 10.1007/s00500-023-08845-y.
- Priya, M. M. M. A., Jawhar, S. J. ve Geisa, J. M. (2021). Optimal deep belief network with opposition based pity beetle algorithm for lung cancer classification: A DBNOPBA approach. *Computer Methods and Programs in Biomedicine*, 199(2), 1-18. doi: 10.1016/j.cmpb.2020.105902.
- Pu, Y., Apel, D. B., Liu, V. ve Mitri, H. (2019). Machine learning methods for rockburst prediction-state-of-the-art review. *International Journal of Mining Science and Technology*, 29(4), 565-570. doi: 10.1016/j.ijmst.2019.06.009.
- Pugal Priya, R., Saradadevi Sivarani, T. ve Gnana Saravanan, A. (2022). Deep long and short term memory based Red Fox optimization algorithm for diabetic retinopathy detection and classification. *International Journal for Numerical Methods in Biomedical Engineering*, 38(3), 1-18. doi: 10.1002/cnm.3560.

- Punitha, S., Amuthan, A., ve Joseph, K. S. (2019). Enhanced Monarchy Butterfly Optimization Technique for effective breast cancer diagnosis. *Journal of Medical Systems*, 43(7) 1-14. doi: 10.1007/s10916-019-1348-8.
- Qin, R., Wang, Z., Jiang, L., Qiao, K., Hai, J., Chen, J., ... ve Yan, B. (2020). Fine-grained lung cancer classification from PET and CT images based on multidimensional attention mechanism. *Complexity*, 2020, 1-12. doi: 10.1155/2020/6153657.
- Qiu, H., Lee, J., Lin, J. ve Yu, G. (2006). Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics. *Journal of sound and vibration*, 289(4), 1066-1090. doi: 10.1016/j.jsv.2005.03.007.
- Qiu, L., Zhao, L., Hou, R., Zhao, W., Zhang, S., Lin, Z., ... ve Zhao, J. (2023). Hierarchical multimodal fusion framework based on noisy label learning and attention mechanism for cancer classification with pathology and genomic features. *Computerized Medical Imaging and Graphics*, 104(4), 1-11. doi: 10.1016/j.compmedimag.2022.102176.
- Raj, R. J. S., Shobana, S. J., Pustokhina, I. V., Pustokhin, D. A., Gupta, D. ve Shankar, K. J. I. A. (2020). Optimal feature selection-based medical image classification using deep learning model in internet of medical things. *IEEE Access*, 8, 58006-58017. doi: 10.1109/ACCESS.2020.2981337.
- Ramesh, R. ve Sathiamoorthy, S. (2023). Deep learning with heuristic optimization driven diabetic retinopathy detection on fundus images. *2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, 252-258. doi: 10.1109/ICAAIC56838.2023.10140220.
- Ramos-Soto, O., Rodríguez-Esparza, E., Balderas-Mata, S. E., Oliva, D., Hassanien, A. E., Meleppat, R. K. ve Zawadzki, R. J. (2021). An efficient retinal blood vessel segmentation in eye fundus images by using optimized top-hat and homomorphic filtering. *Computer Methods and Programs in Biomedicine*, 201(1), 1-13. doi: 10.1016/j.cmpb.2021.105949.
- Ranschaert, E. R., Morozov, S. ve Algra, P. R. (Eds.). (2019). Artificial intelligence in medical imaging: opportunities, applications and risks. Springer.

- Rashidi, H. H., Tran, N., Albahra, S. ve Dang, L. T. (2021). Machine learning in health care and laboratory medicine: General overview of supervised learning and Auto-ML. *International Journal of Laboratory Hematology*, 43, 15-22. doi: 10.1111/ijlh.13537.
- Raz, M., Nguyen, T. C. ve Loh, E. (Eds.). (2022). Artificial Intelligence in Medicine: Applications, Limitations and Future Directions. Springer Nature.
- Raza, R., Zulfiqar, F., Khan, M. O., Arif, M., Alvi, A., Iftikhar, M. A. ve Alam, T. (2023). Lung-EffNet: Lung cancer classification using EfficientNet from ct-scan images. *Engineering Applications of Artificial Intelligence*, 126, 1-17. doi: 10.1016/j.engappai.2023.106902.
- Razzak, M. I., Naz, S., ve Zaib, A. (2018). Deep learning for medical image processing: Overview, challenges and the future. *Classification in BioApps: Automation of Decision Making*, 323-350. doi: 10.1007/978-981-15-6321-8_3.
- Reddy, V. P. C. ve Gurralla, K. K. (2022). OHGCNet: optimal feature selection-based hybrid graph convolutional network model for joint DR-DME classification. *Biomedical Signal Processing and Control*, 78(3), 1-13. doi: 10.1016/j.bspc.2022.103952.
- Reed, R. ve MarksII, R. J. (1999). Neural smithing: supervised learning in feedforward artificial neural networks. Mit Press.
- Rezaee, K., Rezaee, A., Shaikhi, N., ve Haddadnia, J. (2020). Multi-mass breast cancer classification based on hybrid descriptors and memetic meta-heuristic learning. *SN Applied Sciences*, 2(7), 1-19. doi: 10.1007/s42452-020-3103-7.
- Ritter, F., Boskamp, T., Homeyer, A., Laue, H., Schwier, M., Link, F. ve Peitgen, H. O. (2011). Medical image analysis. *IEEE pulse*, 2(6), 60-70. doi: 10.1109/MPUL.2011.942929.
- Rodríguez, M. A., AlMarzouqi, H. ve Liatsis, P. (2022). Multi-label retinal disease classification using transformers. *IEEE Journal of Biomedical and Health Informatics*, 27(6), 2739-2750. doi: 10.1109/JBHI.2022.3214086.

- Roonizi, A. K. ve Selesnick, I. W. (2022). A Kalman filter framework for simultaneous lti filtering and total variation denoising. *IEEE Transactions on Signal Processing*, 70, 4543-4554. doi: 10.1109/TSP.2022.3203852.
- Roshini, T. V., Ravi, R. V., Reema Mathew, A., Kadan, A. B., ve Subbian, P. S. (2020). Automatic diagnosis of diabetic retinopathy with the aid of adaptive average filtering with optimized deep convolutional neural network. *International Journal of Imaging Systems and Technology*, 30(4), 1173-1193. doi: 10.1002/ima.22419.
- Rudin, L. I., Osher, S. ve Fatemi, E. (1992). Nonlinear total variation based noise removal algorithms. *Physica D: nonlinear phenomena*, 60(1-4), 259-268. doi: 10.1016/0167-2789(92)90242-F.
- Ruffle, J. K., Farmer, A. D. ve Aziz, Q. (2019). Artificial intelligence-assisted gastroenterology—promises and pitfalls. *Official journal of the American College of Gastroenterology| ACG*, 114(3), 422-428. doi: 10.1038/s41395-018-0268-4.
- Ryan, M. (2020). In ai we trust: ethics, artificial intelligence, and reliability. *Science and Engineering Ethics*, 26(5), 2749-2767. doi: 10.1007/s11948-020-00228-y.
- Sae-Lim, W., Wettayaprasit, W. ve Aiyarak, P. (2019). Convolutional neural networks using MobileNet for skin lesion classification. *2019 16th international joint conference on computer science and software engineering (JCSSE)*, 242-247. doi: 10.1109/JCSSE.2019.8864155.
- Sagiroglu, S. ve Besdok, E. (2012). A novel approach for image denoising based on artificial neural networks. *Journal Of Polytechnic-Politeknik Dergisi*, 15(2), 71-86. doi: 10.2339/2012.15.2.
- Saha, S., Gan, Z., Cheng, L., Gao, J., Kafka, O. L., Xie, X., ... ve Liu, W. K. (2021). Hierarchical deep learning neural network (HiDeNN): An artificial intelligence (ai) framework for computational science and engineering. *Computer Methods in Applied Mechanics and Engineering*, 373, 1-28. Doi: 10.1016/j.cma.2020.113452.
- Salama, W. M., Shokry, A. ve Aly, M. H. (2022). A generalized framework for lung Cancer classification based on deep generative models. *Multimedia Tools and Applications*, 81(23), 32705-32722. doi: 10.1007/s11042-022-13005-9.

- Samatin Njikam, A. N. ve Zhao, H. (2016). A novel activation function for multilayer feed-forward neural networks. *Applied Intelligence*, 45, 75-82. doi: 10.1007/s10489-015-0744-0.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. ve Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4510-4520. doi: 10.1109/CVPR.2018.00474.
- Saranya, P. ve Asha, P. (2023). Cancer prognosis with machine learning-based modified meta-heuristics and weighted gradient boosting algorithm. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 1-17. doi: 10.1080/21681163.2023.2219772.
- Saraswat, M., Pal, R., Singh, R., Mittal, H., Pandey, A. ve Chand Bansal, J. (2021). An optimal feature selection approach using IBBO for histopathological image classification. *Intelligent Learning for Computer Vision: Proceedings of Congress on Intelligent Systems 2020*, 61, 31-40. doi: 10.1007/978-981-33-4582-9_3.
- Saravanan, T. M., Jagadeesan, M., PA, S., Mubarak, M. M., Kumar, S. P. ve Sanjay, S. (2023). A cnn based machine learning scheme to detect lung cancer detection from ct scan images. *2023 International Conference on Computer Communication and Informatics (ICCCI)*, 1-5. doi: 10.1109/ICCCI56745.2023.10128479.
- Sarki, R., Ahmed, K., Wang, H. ve Zhang, Y. (2020). Automated detection of mild and multi-class diabetic eye diseases using deep learning. *Health Information Science and Systems*, 8(1), 1-9. doi: 10.1007/s13755-020-00125-5.
- Sasakawa, T., Hu, J. ve Hirasawa, K. (2008). A brainlike learning system with supervised, unsupervised, and reinforcement learning. *Electrical Engineering in Japan*, 162(1), 32-39. doi: 10.1002/eej.20600.
- Saxena, S., Shukla, S. ve Gyanchandani, M. (2020). Pre-trained convolutional neural networks as feature extractors for diagnosis of breast cancer using histopathology. *International Journal of Imaging Systems and Technology*, 30(3), 577-591. doi: 10.1002/ima.22399.

- Saxena, S., Shukla, S. ve Gyanchandani, M. (2021). Breast cancer histopathology image classification using kernelized weighted extreme learning machine. *International Journal of Imaging Systems and Technology*, 31(1), 168-179. doi: 10.1002/ima.22465.
- Sayed, G. I. ve Hassanien, A. E. (2017). Moth-flame swarm optimization with neutrosophic sets for automatic mitosis detection in breast cancer histology images. *Applied Intelligence*, 47(5), 397-408. doi: 10.1007/s10489-017-0897-0.
- Schwartz, W. B. (1970). Medicine and the computer: the promise and problems of change. *Use and impact of computers in clinical medicine*, 321-335. doi: 10.1007/978-1-4613-8674-2_20.
- Scikit-learn. (14 Ekim 2023). Scikit-learn kütüphanesi. <https://scikit-learn.org/stable/>
- Seemendra, A., Singh, R., ve Singh, S. (2020). Breast cancer classification using transfer learning. *Evolving Technologies for Computing, Communication and Smart World: Proceedings of ETCCS 2020*, 425-436. doi: 10.1007/978-981-15-7804-5_32.
- Selesnick, I. W. ve Bayram, I. (2010). Total variation filtering. *White Paper*.
- Sengar, N., Joshi, R. C., Dutta, M. K. ve Burget, R. (2023). EyeDeep-Net: A multi-class diagnosis of retinal diseases using deep neural network. *Neural Computing and Applications*, 35, 10551-10571. Doi: 10.1007/s00521-023-08249-x.
- Shah, A., Bangash, J. I., Khan, A. W., Ahmed, I., Khan, A., Khan, A. ve Khan, A. (2022). Comparative analysis of median filter and its variants for removal of impulse noise from gray scale images. *Journal of King Saud University-Computer and Information Sciences*, 34(3), 505-519. doi: 10.1016/j.jksuci.2020.03.007.
- Shaikhina, T., Lowe, D., Daga, S., Briggs, D., Higgins, R. ve Khovanova, N. (2019). Decision tree and random forest models for outcome prediction in antibody incompatible kidney transplantation. *Biomedical Signal Processing and Control*, 52, 456-462. doi: 10.1016/j.bspc.2017.01.012.
- Shakeel, P. M., Burhanuddin, M. A. ve Desa, M. I. (2022). Automatic lung cancer detection from CT image using improved deep neural network and ensemble classifier. *Neural Computing and Applications*, 34(15), 1-14. doi: 10.1007/s00521-020-04842-6.

- Shandilya, S. ve Nayak, S. R. (2022). Analysis of lung cancer by using deep neural network. *Innovation in Electrical Power Engineering, Communication, and Computing Technology: Proceedings of Second IEPCCT 2021*, 814 , 427-436. doi: 10.1007/978-981-16-7076-3_37.
- Shao, L., Yan, R., Li, X. ve Liu, Y. (2013). From heuristic optimization to dictionary learning: A review and comprehensive comparison of image denoising algorithms. *IEEE transactions on cybernetics*, 44(7), 1001-1013. doi: 10.1109/TCYB.2013.2278548.
- Sharma, S. ve Kumar, S. (2022). The Xception model: A potential feature extractor in breast cancer histology images classification. *ICT Express*, 8(1), 101-108. doi: 10.1016/j.ict.2021.11.010.
- Sharma, S. ve Mehra, R. (2020). Conventional machine learning and deep learning approach for multi-classification of breast cancer histopathology images—a comparative insight. *Journal of digital imaging*, 33(6), 632-654. doi: 10.1007/s10278-019-00307-y.
- Sharma, T., Nair, R., ve Gomathi, S. (2022). Breast cancer image classification using transfer learning and convolutional neural network. *International Journal of Modern Research*, 2(1), 8-16.
- Shen, D., Wu, G. ve Suk, H. I. (2017). Deep learning in medical image analysis. *Annual review of biomedical engineering*, 19, 221-248. doi: 10.1146/annurev-bioeng-071516-044442.
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P. ve Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325. doi: 10.1109/JSTARS.2020.3026724.
- Shorten, C. ve Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48. doi: 10.1186/s40537-019-0197-0.
- Shyni, H. M. ve Chitra, E. (2022). A comparative study of X-ray and CT images in Covid-19 detection using image processing and deep learning techniques. *Computer*

- Methods and Programs in Biomedicine Update*, 2, 1-14. doi: 10.1016/j.cmpbup.2022.100054.
- Simonyan, K. ve Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*. doi: 10.48550/arXiv.1409.1556.
- Singh, S. P., Wang, L., Gupta, S., Goli, H., Padmanabhan, P. ve Gulyás, B. (2020). 3D deep learning on medical images: a review. *Sensors*, 20(18), 1-24. doi: 10.3390/s20185097.
- Sinha, D. ve El-Sharkawy, M. (2019). Thin mobilenet: An enhanced mobilenet architecture. *2019 IEEE 10th annual ubiquitous computing, electronics & mobile communication conference (UEMCON)*, 280-285. doi: 10.1109/UEMCON47517.2019.8993089.
- Song, Y. Y. ve Ying, L. U. (2015). Decision tree methods: applications for classification and prediction. *Shanghai archives of psychiatry*, 27(2), 130-135. doi: 10.11919/j.issn.1002-0829.215044.
- Spector, J. M. ve Ma, S. (2019). Inquiry and critical thinking skills for the next generation: from artificial intelligence back to human intelligence. *Smart Learning Environments*, 6(1), 1-11. doi: 10.1186/s40561-019-0088-z.
- Srikantamurthy, M. M., Rallabandi, V. S., Dudekula, D. B., Natarajan, S., ve Park, J. (2023). Classification of benign and malignant subtypes of breast cancer histopathology imaging using hybrid CNN-LSTM based transfer learning. *BMC Medical Imaging*, 23(1), 1-15. doi: 10.1186/s12880-023-00964-0.
- Steyaert, S., Pizurica, M., Nagaraj, D., Khandelwal, P., Hernandez-Boussard, T., Gentles, A. J., ve Gevaert, O. (2023). Multimodal data fusion for cancer biomarker discovery with deep learning. *Nature Machine Intelligence*, 5(4), 351-362. doi: 10.1038/s42256-023-00633-5.
- Stray, J. (2021). Making artificial intelligence work for investigative journalism. *Algorithms, Automation, and News*, 97-118. doi: 10.4324/9781003099260-6.

- Sugeno, A., Ishikawa, Y., Ohshima, T., ve Muramatsu, R. (2021). Simple methods for the lesion detection and severity grading of diabetic retinopathy by image processing and transfer learning. *Computers in Biology and Medicine*, 137(14), 1-9. doi: 10.1016/j.combiomed.2021.104795.
- Sun, K., He, M., He, Z., Liu, H. ve Pi, X. (2022). EfficientNet embedded with spatial attention for recognition of multi-label fundus disease from color fundus photographs. *Biomedical Signal Processing and Control*, 77(4), 1-12. doi: 10.1016/j.bspc.2022.103768.
- Suryanarayana, G., Chandran, K., Khalaf, O. I., Alotaibi, Y., Alsufyani, A. ve Alghamdi, S. A. (2021). Accurate magnetic resonance image super-resolution using deep networks and Gaussian filtering in the stationary wavelet domain. *IEEE Access*, 9, 71406-71417. doi: 10.1109/ACCESS.2021.3077611.
- Sutton, R. S. ve Barto, A. G. (2018). Reinforcement learning: An introduction. MIT press.
- Tahamtan, A. ve Ardebili, A. (2020). Real-time RT-PCR in Covid-19 detection: issues affecting the results. *Expert review of molecular diagnostics*, 20(5), 453-454. doi: 10.1080/14737159.2020.1757437.
- Taheri, S. ve Golrizkhatami, Z. (2023). Magnification-specific and magnification-independent classification of breast cancer histopathological image using deep learning approaches. *Signal, Image and Video Processing*, 17(2), 583-591. doi: 10.1007/s11760-022-02263-7.
- Talasila, S., Rawal, K. ve Sethi, G. (2022). Conventional data augmentation techniques for plant disease detection and classification systems. *Intelligent Systems and Sustainable Computing: Proceedings of ICISSC 2021*, 289, 279-287. doi: 10.1007/978-981-19-0011-2_26.
- Tan, H. H. ve Lim, K. H. (2019). Review of second-order optimization techniques in artificial neural networks backpropagation. *IOP conference series: materials science and engineering*, 495(1), 1-7. doi: 10.1088/1757-899X/495/1/012003.
- Tan, M. ve Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *International conference on machine learning*, 97, 6105-6114. doi: 10.48550/arXiv.1905.11946.

- Tariq, M., Palade, V., Ma, Y. ve Altahhan, A. (2023). Diabetic retinopathy detection using transfer and reinforcement learning with effective image preprocessing and data augmentation techniques. *Fusion of Machine Learning Paradigms: Theory and Applications*, 33-61. doi: 10.1007/978-3-031-22371-6_3.
- Tchito Tchapg, C., Mih, T. A., Tchagna Kouanou, A., Fozin Fonzin, T., Kuetché Fogang, P., Mezatio, B. A. ve Tchiotsop, D. (2021). Biomedical image classification in a big data architecture using machine learning algorithms. *Journal of Healthcare Engineering*, 2021(2), 1-11. 10.1155/2021/9998819.
- Teh, E. W. ve Taylor, G. W. (2022). Learning with less labels in digital pathology via scribble supervision from natural images. *arXiv preprint arXiv:2201.02627*. doi: 10.48550/arXiv.2201.02627.
- Thawkar, S., Sharma, S., Khanna, M., ve kumar Singh, L. (2021). Breast cancer prediction using a hybrid method based on butterfly optimization algorithm and ant lion optimizer. *Computers in Biology and Medicine*, 139, 1-13. doi: 10.1016/j.combiomed.2021.104968.
- Thota, N. B., ve Reddy, D. U. (2020). Improving the accuracy of diabetic retinopathy severity classification with transfer learning. *2020 IEEE 63rd International Midwest Symposium on Circuits and Systems (MWSCAS)*, 1003-1006. doi: 10.1109/MWSCAS48704.2020.9184473.
- Tian, M., Wang, H., Liu, X., Ye, Y., Ouyang, G., Shen, Y., ... ve Wu, S. (2023). Delineation of clinical target volume and organs at risk in cervical cancer radiotherapy by deep learning networks. *Medical Physics*.
- Tomasi, C. ve Manduchi, R. (1998). Bilateral filtering for gray and color images. *Sixth international conference on computer vision (IEEE Cat. No. 98CH36271)*, 839-846. doi: 10.1109/ICCV.1998.710815.
- Truba. (14 Ekim 2023). <https://www.truba.gov.tr/>
- Tsalafoutas, I. A. ve Metallidis, S. I. (2011). A method for calculating the dose length product from CT dicom images. *The British Journal of Radiology*, 84(999), 236-243. doi: 10.1259/bjr/37630380.
- Turing, A. M. (1950). *Mind*. *Mind*, 59(236), 433-460.

- Uddin, S., Haque, I., Lu, H., Moni, M. A. ve Gide, E. (2022). Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction. *Scientific Reports*, 12(1), 1-11. doi: 10.1038/s41598-022-10358-x.
- Ullah, I., Ali, F., Shah, B., El-Sappagh, S., Abuhmed, T. ve Park, S. H. (2023). A deep learning based dual encoder–decoder framework for anatomical structure segmentation in chest X-ray images. *Scientific Reports*, 13(1), 1-14. doi: 10.1038/s41598-023-27815-w.
- Usama, M., Qadir, J., Raza, A., Arif, H., Yau, K. L. A., Elkhatib, Y., ... ve Al-Fuqaha, A. (2019). Unsupervised machine learning for networking: Techniques, applications and research challenges. *IEEE access*, 7, 65579-65615. doi: 10.1109/ACCESS.2019.2916648.
- Varma, D. R. (2012). Managing dicom images: Tips and tricks for the radiologist. *Indian Journal of Radiology and Imaging*, 22(1), 4-13. Doi: 10.4103/0971-3026.95396.
- Vesal, S., Ravikumar, N., Davari, A., Ellmann, S., v Maier, A. (2018). Classification of breast cancer histology images using transfer learning. *Image Analysis and Recognition: 15th International Conference, ICIAR 2018, Póvoa de Varzim, Portugal, June 27–29, 2018, Proceedings 15*, 812-819. doi: 10.1007/978-3-319-93000-8_92.
- Vijh, S., Saraswat, M. ve Kumar, S. (2023). Automatic multilevel image thresholding segmentation using hybrid bio-inspired algorithm and artificial neural network for histopathology images. *Multimedia Tools and Applications*, 82(4), 4979-5010. doi: 10.1007/s11042-022-12168-9.
- Waibel, A., Hanazawa, T., Hinton, G., Shikano, K. ve Lang, K. J. (1989). Phoneme recognition using time-delay neural networks. *Trans. Acoust., Speech, Signal Process*, 37(3), 328-339. doi: 10.1109/29.21701.
- Wang, C., Chen, D., Hao, L., Liu, X., Zeng, Y., Chen, J., ve Zhang, G. (2019). Pulmonary image classification based on inception-v3 transfer learning model. *IEEE Access*, 7, 146533-146541. doi: 10.1109/ACCESS.2019.2946000.

- Wang, D., Zhang, Y., Zhang, K. ve Wang, L. (2020). FocalMix: Semi-supervised learning for 3D medical image detection. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 3951-3960). doi: 10.1109/CVPR42600.2020.00401.
- Wang, P., Xue, B., Liang, J. ve Zhang, M. (2022). Differential Evolution-based feature selection: a niching-based multiobjective approach. *IEEE Transactions on Evolutionary Computation*, 27(2), 296-310. doi: 10.1109/TEVC.2022.3168052.
- Wang, Z., Liu, Y. ve Niu, X. (2023). Application of artificial intelligence for improving early detection and prediction of therapeutic outcomes for gastric cancer in the era of precision oncology. *Seminars in Cancer Biology*, 93(3), 83-96. doi: 10.1016/j.semcancer.2023.04.009.
- Whitcher, B., Schmid, V. J. ve Thorton, A. (2011). Working with the dicom and nifti data standards in R. *Journal of Statistical Software*, 44(6), 1-29. doi: 10.18637/jss.v044.i06.
- Wright, L. G., Onodera, T., Stein, M. M., Wang, T., Schachter, D. T., Hu, Z. ve McMahon, P. L. (2022). Deep physical neural networks trained with backpropagation. *Nature*, 601(7894), 549-555. doi: 10.1038/s41586-021-04223-6.
- Xavier, F. J. (2023). ODMNet: Automated glaucoma detection and classification model using heuristically-aided optimized densenet and mobilenet transfer learning. *Cybernetics and Systems*, 1-33. doi: 10.1080/01969722.2023.2166250.
- Xia, T., Kumar, A., Feng, D. ve Kim, J. (2018). Patch-level tumor classification in digital histopathology images with domain adapted deep learning. *2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, 644-647. doi: 10.1109/EMBC.2018.8512353.
- Yang, C. H. H., Huang, J. H., Liu, F., Chiu, F. Y., Gao, M., Lyu, W. ve Tegner, J. (2018). A novel hybrid machine learning model for auto-classification of retinal diseases. *arXiv preprint arXiv:1806.06423*. doi: 10.48550/arXiv.1806.06423.
- Yang, S., Xiao, W., Zhang, M., Guo, S., Zhao, J. ve Shen, F. (2022). Image data augmentation for deep learning: A survey. *arXiv preprint arXiv:2204.08610*. doi: 10.48550/arXiv.2204.08610.

- Yang, Z., Ran, L., Zhang, S., Xia, Y. ve Zhang, Y. (2019). EMS-Net: Ensemble of multiscale convolutional neural networks for classification of breast cancer histology images. *Neurocomputing*, 366(3), 46-53. doi: 10.1016/j.neucom.2019.07.080.
- Yang, Z., Yin, H., Shi, L. ve Qian, X. (2020). A novel microRNA signature for pathological grading in lung adenocarcinoma based on TCGA and GEO data. *International journal of molecular medicine*, 45(5), 1397-1408. doi: 10.3892/ijmm.2020.4526.
- Yu, D., Lin, J., Cao, T., Chen, Y., Li, M. ve Zhang, X. (2023). SECS: An effective cnn joint construction strategy for breast cancer histopathological image classification. *Journal of King Saud University-Computer and Information Sciences*, 35(2), 810-820. doi: 10.1016/j.jksuci.2023.01.017.
- Yu, H., Zhou, Z. ve Wang, Q. (2020). Deep learning assisted predict of lung cancer on computed tomography images using the adaptive hierarchical heuristic mathematical model. *IEEE Access*, 8, 86400-86410. doi: 10.1109/ACCESS.2020.2992645.
- Yugander, P., Tejaswini, C. H., Meenakshi, J., Varma, B. S. ve Jagannath, M. (2020). MR image enhancement using adaptive weighted mean filtering and homomorphic filtering. *Procedia Computer Science*, 167(1), 677-685. doi: 10.1016/j.procs.2020.03.334.
- Zaadnoordijk, L., Besold, T. R. ve Cusack, R. (2022). Lessons from infant learning for unsupervised machine learning. *Nature Machine Intelligence*, 4(6), 510-520. doi: 10.1038/s42256-022-00488-2.
- Zerouaoui, H. ve Idri, A. (2022). Deep hybrid architectures for binary classification of medical breast cancer images. *Biomedical Signal Processing and Control*, 71(1), 1-20. doi: 10.1016/j.bspc.2021.103226.
- Zhai, P., Tao, Y., Chen, H., Cai, T. ve Li, J. (2020). Multi-task learning for lung nodule classification on chest CT. *IEEE access*, 8, 180317-180327. doi: 10.1109/ACCESS.2020.3027812.

- Zhang, C., Tavanapong, W., Wong, J., de Groen, P. C. ve Oh, J. (2017). Real data augmentation for medical image classification. *Intravascular Imaging and Computer Assisted Stenting, and Large-Scale Annotation of Biomedical Data and Expert Label Synthesis: 6th Joint International Workshops, CVII-STENT 2017 and Second International Workshop, LABELS 2017, Held in Conjunction with MICCAI 2017, Québec City, QC, Canada, September 10–14, 2017, Proceedings 2*, 67-76. doi: 10.1007/978-3-319-67534-3_8.
- Zhang, K., Cao, Z. ve Wu, J. (2020). Circular shift: An effective data augmentation method for convolutional neural network on image classification. *2020 IEEE International conference on image processing (ICIP)*, 1676-1680. doi: 10.1109/ICIP40778.2020.9191303.
- Zhang, L., Wang, J., Li, B., Liu, Y., Zhang, H. ve Duan, Q. (2022). A MobileNetV2-SENet-based method for identifying fish school feeding behavior. *Aquacultural Engineering*, 99, 1-13. doi: 10.1016/j.aquaeng.2022.102288.
- Zhang, W., Tanida, J., Itoh, K. ve Ichioka, Y. (1988). Shift-invariant pattern recognition neural network and its optical architecture. *Proceedings of annual conference of the Japan Society of Applied Physics*, 564.
- Zhao, A., Balakrishnan, G., Durand, F., Gutttag, J. V. ve Dalca, A. V. (2019). Data augmentation using learned transformations for one-shot medical image segmentation. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 8543-8553.
- Zheng, B., Gao, A., Huang, X., Li, Y., Liang, D. ve Long, X. (2023). A modified 3D EfficientNet for the classification of Alzheimer's disease using structural magnetic resonance images. *IET Image Processing*, 17(1), 77-87. doi: 10.1049/ipr2.12618.
- Zhu, W., Liu, C., Fan, W. ve Xie, X. (2018). Deeplung: Deep 3d dual path nets for automated pulmonary nodule detection and classification. *2018 IEEE winter conference on applications of computer vision (WACV)*, 673-681. doi: 10.1109/WACV.2018.00079.

Zhu, Y. ve Huang, C. (2012). An adaptive histogram equalization algorithm on the image gray level mapping. *Physics Procedia*, 25, 601-608. doi: 10.1016/j.phpro.2012.03.132.

Zouch, W., Sagga, D., Ectiou, A., Khemakhem, R., Ghorbel, M., Mhiri, C., ve Hamida, A. B. (2022). Detection of Covid-19 from CT and chest X-ray images using deep learning models. *Annals of Biomedical Engineering*, 50(7), 825-835. doi: 10.1007/s10439-022-02958-5.



ÖZGEÇMİŞ

Kişisel Bilgiler :

Adı ve Soyadı : Furkan ATLAN

Eğitim Durumu :

Lisans Öğrenimi : T.C. Burdur Mehmet Akif Ersoy Üniversitesi
Yönetim Bilişim Sistemleri Bölümü
Mezuniyet: 20/06/2017

Yüksek Lisans Öğrenimi : T.C. Burdur Mehmet Akif Ersoy Üniversitesi
Sosyal Bilimler Enstitüsü
Yönetim Bilişim Sistemleri Ana Bilim Dalı
Yönetim Bilişim Sistemleri Tezli Yüksek
Lisans Programı
Mezuniyet: 24/07/2019

İş Deneyimi : İnser Mühendislik ve Dış Ticaret Ltd. Şti.
(Staj-2017)

Bilimsel Yayınlar ve Çalışmalar :

1. Uluslararası hakemli dergilerde yayımlanan makaleler:

Atlan, F., ve Pençe, İ. (2021). Yapay Zekâ ve Tıbbi Görüntüleme Teknolojilerine Genel Bakış. *Acta Infologica*, 5(1), 207-230. Doi: 10.26650/acin.813736

Atlan, F., ve Pençe, İ. (2021). Forecasting of Bitcoin Price Using The Multilayer Perceptron Technique. *Scientific Journal of Mehmet Akif Ersoy University*, 4(2), 68-74.

Atlan, F., Hançer, E., ve Pençe, İ. (2020). U-Net ile Çekirdek Segmentasyonunda Hiper Parametre Optimizasyonu Etkisinin Değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 60-69. Doi: 10.31590/ejosat.818791

2. Uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında (proceedings) basılan bildiriler:

Atlan, F., Pençe, I., ve Çeşmeli, M. Ş. (2020). Online Price Forecasting Model Using Artificial Intelligence for Cryptocurrencies as Bitcoin, Ethereum and Ripple. *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE. Doi: 10.1109/SIU49456.2020.9302082

Atlan, F., Hançer, E., ve Pençe, İ. (2020). U-Net ile çekirdek segmentasyonunda hiper parametre optimizasyonu etkisinin değerlendirilmesi. *4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), Istanbul, Turkey*. Doi: 10.31590/ejosat.818791.

Atlan, F., Pençe, İ., Şişeci Çeşmeli, M., Kalkan, A. (2018). Bitcoin'in Türkiye piyasasındaki değerinin yapay zekâ teknikleri ile tahmini. *IMISC*. Doi: 10.6084/m9.figshare.7471376.v2

3. Uluslararası kitaplar:

Atlan, F., Şişeci Çeşmeli, M., Pençe, İ. (2022). Destekleyici Öğrenme ve Q Öğrenmesi Üzerine Genel Bakış. LAP LAMBERT Akademik Yayıncılık. ISBN: 978-6204985268

Atlan, F. (2019). Türkiye'de Bitcoin değerinin matematiksel modellenmesi. LAP LAMBERT Akademik Yayıncılık. ISBN: 978- 6200302311