

T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI



EVRIŞİMSEL SİNİR AĞLARI VE ÇEKİRGE OPTİMİZASYON
ALGORİTMASI KULLANARAK KOLON KANSER HASTALIĞI
TESBİTİ

AMNA ALI A MOHAMED

DOKTORA TEZİ

PROF. DR. AYBABA HAÇERLİOĞULLARI

TEMMUZ - 2024

KASTAMONU

TEZ ONAYI

Amna Ali A Mohamed tarafından hazırlanan “**Evrişimsel Sinir Ağları ve Çekirge Optimizasyon Algoritması kullanarak Kolon Kanser Hastalığı Tesbiti**” adlı tez çalışmasının savunma sınavı **22.07.2024** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Malzeme Bilimi ve Mühendisliği Ana Bilim Dalı Doktora Tezi** olarak kabul edilmiştir.

Danışman	Prof. Dr. Aybaba HANÇERLİOĞULLARI Kastamonu Üniversitesi	
Jüri Üyesi	Prof. Dr. Adnan SÖZEN Gazi Üniversitesi	
Jüri Üyesi	Prof. Dr. Aslı KURNAZ Kastamonu Üniversitesi	
Jüri Üyesi	Doç. Dr. Mehmet Zeki BUDANLI Sağlık Bilimleri Üniversitesi	
Jüri Üyesi	Doç. Dr. Elif AŞIKUZUN TOKEŞER Kastamonu Üniversitesi	

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitü Müdürü	Doç. Dr. Selçuk MEMİŞ	
----------------	-----------------------	-------

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını, bilimsel etiğe uygun olarak kaynak gösterildiğini bildirir ve taahhüt ederim.

Amna Ali A MOHAMED

ÖZET

DOKTORA TEZİ

EVİRİŞİMSEL SİNİR AĞLARI VE ÇEKİRGE OPTİMİZASYON ALGORİTMASI KULLANARAK KOLON KANSER HASTALIĞI TESBİTİ

AMNA ALI A MOHAMED

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN: PROF. DR. AYBABA HAÇERLİOĞULLARI

Kolon kanseri, etkili tedavi için erken ve doğru teşhis gerektiren yaygın ve potansiyel olarak ölümcül bir hastalıktır. Kolon kanserine yönelik geleneksel teşhis yaklaşımları sıklıkla doğruluk ve verimlilik açısından sınırlamalarla karşı karşıya kalır ve bu da erken teşhis ve tedavide zorluklara yol açar. Bu tez, özellik seçme yöntemine dayanan sağlam bir kolon kanseri teşhis yöntemi sunmaktadır. Kolon kanseri hastalığının teşhisi için önerilen yöntem üç adıma ayrılabilir. İlk adımda, evrişimli sinir ağına dayalı olarak görüntülerin özellikleri çıkarıldı. Evrişimsel sinir ağı için SqueezeNet, Resnet-50, AlexNet ve GoogleNet kullanıldı. Çıkarılan özellikler çok büyük ve özelliklerin sayısı sistemi eğitmek için uygun olamaz. Bu nedenle ikinci adımda özellik sayısını azaltmak için metasezgisel yöntem kullanılmıştır. Bu araştırma, özellik verilerinden en iyi özellikleri seçmek için çekirge optimizasyon algoritmasını kullanır. Son olarak makine öğrenmesi yöntemleri kullanılarak kolon kanseri hastalığı tanısının doğru ve başarılı olduğu görüldü. Önerilen yöntemin değerlendirilmesinde iki sınıflandırma yöntemi uygulanmıştır. Bu yöntemler karar ve destek vektör makinesini içerir. Önerilen yöntemi değerlendirmek için duyarlılık, özgüllük, doğruluk ve F1Score kullanılmıştır. Destek vektör makinesini temel alan SqueezeNet için %99,34 elde ettik; %99,41; %99,12; Duyarlılık, özgüllük, doğruluk, kesinlik ve F₁Score için sırasıyla %98,91 ve %98,94 sonuçlar. Sonunda önerilen tanıma yönteminin performansını 9 katmanlı CNN, Rastgele sayılar, 7 katmanlı CNN ve Drop-Block gibi diğer yöntemlerin performanslarıyla karşılaştırdık. Çözümümüzün diğerlerinden daha iyi performans gösterdiğini gösterdik. Ayrıca kolon kanserinin otomatik tespiti için yapay zekayı, özellikle de evrişimli sinir ağını (CNN) ve Fishier Mantis Optimizer'ı kullanan yenilikçi bir yöntem sunulmaktadır. Derin öğrenme tekniklerinin, özellikle CNN'nin kullanılması, tıbbi görüntüleme verilerinden karmaşık özelliklerin çıkarılmasını sağlayarak sağlam ve etkili bir teşhis modeli sağlar. Ek olarak, peygamber devesi karidesinin avlanma davranışından ilham alan, biyo-esinli bir optimizasyon algoritması olan Fishier Mantis Optimizer, CNN'nin parametrelerine ince ayar yapmak ve yakınsama hızını ve performansını artırmak için kullanılıyor. Bu hibrit yaklaşım, kolon kanseri teşhisinin doğruluğunu ve etkinliğini artırmak için hem derin öğrenmenin hem de doğadan ilham alan optimizasyonun güçlü yönlerinden yararlanarak geleneksel teşhis yöntemlerinin sınırlamalarını gidermeyi amaçlamaktadır. Önerilen yöntem, kolon kanseri görüntülerinden oluşan kapsamlı bir veri seti üzerinde değerlendirildi ve sonuçlar, geleneksel tanı yaklaşımlarına göre üstünlüğünü ortaya koydu. CNN-Fishier Mantis Optimizer modeli, kanserli ve kanserli olmayan kolon dokularını ayırt etmede yüksek hassasiyet, özgüllük ve genel doğruluk sergiledi. Biyo-ilhamlı optimizasyon algoritmalarının derin öğrenme

teknikleriyle entegrasyonu, yalnızca kolon kanseri için bilgisayar destekli teşhis araçlarının geliştirilmesine katkıda bulunmakla kalmaz, aynı zamanda bu hastalığın erken tespitini ve teşhisini geliştirme ve böylece zamanında müdahaleyi ve iyileştirmeyi kolaylaştırma konusunda umut vaat eder. Hasta prognozu, kolon hastalıklarıyla ilişkili özellikleri yakalamak için GoogLeNet ve ResNet-50 gibi çeşitli CNN tasarımları kullanıldı. Ancak özneteliklerin çokluğu nedeniyle hem öznetelik çıkarımı hem de veri sınıflandırmasında yanlışlıklar ortaya çıkmıştır. Bu sorunu çözmek için, Fishier Mantis Optimizer algoritmaları kullanılarak özellik azaltma teknikleri uygulandı ve Genetik Algoritmalar ve simüle edilmiş tavlama gibi alternatif yöntemlerden daha iyi performans gösterdi. Duyarlılık, özgüllük, doğruluk ve F1 puanı gibi çeşitli metriklerin değerlendirilmesinde sırasıyla %94,87, %96,19, %97,65 ve %96,76 olarak tespit edilen cesaretlendirici sonuçlar elde edildi.

ANAHTAR KELİMELEER:Kolon Kanseri Hastalığı Teşhisi, Evrişimli Sinir Ağı, Çekirge Optimizasyon Algoritması, Makine öğrenimi

Temmuz 2024, 90 Sayfa



ABSTRACT

PH.D THESIS

COLON CANCER DISEASE DIAGNOSE WITH CONVOLUTIONAL NEURAL NETWORK AND GRASSHOPPER OPTIMIZATION ALGORITHM

AMNA ALI A MOHAMED

**KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF MATERIALS SCIENCE AND ENGINEERING
SUPERVISOR:PROF. DR. AYBABA HANÇERLİOGULLARI**

Colon cancer is a prevalent and potentially fatal disease that demands early and accurate diagnosis for effective treatment. Traditional diagnostic approaches for colon cancer often face limitations in accuracy and efficiency, leading to challenges in early detection and treatment. This thesis presents a robust colon cancer diagnosis method based on the feature selection method. The proposed method for colon cancer disease diagnosis can be divided into three steps. In the first step, the images' features were extracted based on the convolutional neural network. Squeezenet, Resnet-50, AlexNet, and GoogleNet were used for the convolutional neural network. The extracted features are huge, and the number of features cannot be appropriate for training the system. For this reason, the metaheuristic method is used in the second step to reduce the number of features. This research uses the grasshopper optimization algorithm to select the best features from the feature data. Finally, using machine learning methods, the colon cancer disease diagnosis was found to be accurate and successful. Two classification methods are applied for the evaluation of the proposed method. These methods include the decision tree and the support vector machine. The sensitivity, specificity, accuracy, and F1Score have been used to evaluate the proposed method. For Squeezenet based on the support vector machine, we obtained 99.34%; 99.41%; 99.12%; 98.91% and 98.94% results for sensitivity, specificity, accuracy, precision, and F1Score respectively. In the end, we compared the suggested recognition method's performance to the performances of other methods, including 9-layer CNN, Random Forest, 7-layer CNN, and DropBlock. We demonstrated that our solution outperformed the others. Also in this thesis an innovative method presented that leverages artificial intelligence, specifically convolutional neural network (CNN) and Fishier Mantis Optimizer, for the automated detection of colon cancer. The utilization of deep learning techniques, specifically CNN, enables the extraction of intricate features from medical imaging data, providing a robust and efficient diagnostic model. Additionally, the Fishier Mantis Optimizer, a bio-inspired optimization algorithm inspired by the hunting behavior of the mantis shrimp, is employed to fine-tune the parameters of the CNN, enhancing its convergence speed and performance. This hybrid approach aims to address the limitations of traditional diagnostic methods by leveraging the strengths of both deep learning and nature-inspired optimization to enhance the accuracy and effectiveness of colon cancer diagnosis. The proposed method was evaluated on a comprehensive dataset comprising colon cancer images, and the results demonstrate its superiority over traditional diagnostic approaches. The CNN–Fishier Mantis Optimizer model exhibited high sensitivity, specificity, and overall accuracy in distinguishing between cancer and non-cancer colon tissues. The integration of bio-inspired

optimization algorithms with deep learning techniques not only contributes to the advancement of computer-aided diagnostic tools for colon cancer but also holds promise for enhancing the early detection and diagnosis of this disease, thereby facilitating timely intervention and improved patient prognosis. Various CNN designs, such as GoogLeNet and ResNet-50, were employed to capture features associated with colon diseases. However, inaccuracies were introduced in both feature extraction and data classification due to the abundance of features. To address this issue, feature reduction techniques were implemented using Fishier Mantis Optimizer algorithms, outperforming alternative methods such as Genetic Algorithms and simulated annealing. Encouraging results were obtained in the evaluation of diverse metrics, including sensitivity, specificity, accuracy, and F1 score, which were found to be 94.87%, 96.19%, 97.65%, and 96.76%, respectively.

KEYWORDS: Colon Cancer Disease Diagnosis, Convolutional Neural Network, Grasshopper Optimization Algorithm, Machine Learning

July 2024, 90 Page



TEŞEKKÜR

Bu araştırmanın gerçekleşmesine yaptığı yardımdan dolayı danışmanım Prof. Dr. Aybaba Hançerlioğulları'na teşekkürlerimi sunarım, bu tez onun rehberliği ve desteği olmadan mümkün olamazdı. Ayrıca tez izleme komitesine ve Ana bilim dalı öğretim üyelerine teşekkür ediyorum. İyi ve kötü günlerimde yanımda olan ve başarılı olmama yardımcı olan maddi ve manevi desteklerini esirgemeyen tüm aile bireylerine teşekkürlerimi sunmak istiyorum. Bana Türkiye'de doktora eğitimim boyunca burs imkânı sağlayan Libya hükümetine ve sorumlu yetkililere teşekkür ederim.

Amna Ali A MOHAMED

Kastamonu, 2024

İÇİNDEKİLER

Sayfa

TEZ ONAYI	ii
TAAHHÜTNAME	iii
ÖZET.....	iv
ABSTRACT	vi
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xi
1. GİRİŞ.....	1
1.1 Arka plan.....	1
1.2 Kolorektal Kanser (CRC) Önleme Yolları	3
1.3 Kolon Kanseri	3
1.3.1 Risk Faktörleri	4
1.3.1.1 Yaş	4
1.3.1.2 Cinsiyet	4
1.3.1.3 Diğer risk faktörleri.....	4
1.3.2 Kolon Kanseri Belirtileri	5
1.3.3 Kolon Kanseri Gelişiminde İnflamatuar Bağırsak Hastalığı	6
1.4 Önerilen Araştırma.....	9
1.5 Araştırmanın Yaklaşımı	9
1.6 Araştırmanın Motivasyonu	10
1.7 Araştırmanın Katkısı	10
1.8 Tezin Düzenlenmesi.....	11
2. LİTERATÜR TARAMASI	12
2.1 Makine Öğrenimi ve Kanser Tespiti.....	12
2.2 Kolon Kanseri	13
2.2.1 Kolon Kanseri Hastalığının Teşhisi.....	15
2.3 Yapay Sinir Ağı (ANN)	18
2.3.1 Arka plan	18
2.3.2 İleri Beslemeli Sinir Ağları (FFNN).....	21
2.3.3 Yapay Sinir Ağlarının Öğretimi	26
2.3.4 Transfer Öğrenimi	27
3. MATERYAL VE METOT	29
3.1 Çekirge Optimizasyon Algoritmasının Arkaplanı	29
3.1.1 Mesafe ve Hareket	30
3.1.2 Güncelleme Aşaması	30
3.1.3 Küçülme Faktörü	34
3.2 Karınca Kolonisi Optimizasyon Algoritması.....	35
3.3 Parçacık Sürü Optimizasyon Algoritması ile Özellik Seçimi.....	37
3.4 Balıkçı Peygamber Devesi Optimizasyon Algoritması	47
3.4.1 Başlangıç Durum Popülasyonunun Oluşturulması.....	48
3.4.2 Durum Hatırlatıcıları	49
3.4.3 Optimum Konumlara Doğru Hareket	49

3.4.4 Optimum Konumlara Doğru Hareketi Geçersiz Kılma.....	50
3.4.5 Tüm Optimal Durumları Kullanma	50
3.5 Veri Kümesi	52
4. SONUÇLAR VE TARTIŞMA	55
4.1 Arka plan.....	55
4.2 Veri Kümesi	55
4.3 Değerlendirme.....	55
4.3.1 Amaç Fonksiyonu Analizi	57
4.3.2 GOA Algoritmasını Kullanarak Sınıflandırma Doğruluğu Analizi	58
4.3.3 Karşılaştırma.....	60
4.4 ACO-PSO İçin Öğrenilebilir Sınıflandırıcılar Kullanarak Sınıflandırma ...	63
4.4.1 Kolon Kanseri Hastalığı Veri Kümesi İçin PSO’lu Otokodlayıcı.....	63
4.4.2 Kolon Kanseri Hastalığı Veri Kümesi İçin Otokodlayıcıyı ACO-PSO ile Kullanma	64
4.4.3 Kolon Kanseri Hastalığı Veri Kümesi İçin ACO-PSO ile Önceden Öğretilmiş CNN	64
4.5 Kolon Kanseri Hastalığı Veri Kümesi İçin Otokodlayıcıyı FMO ile Kullanma.....	67
4.6 Kolon Kanseri Hastalığı Veri Kümesi İçin FMO’lu Önceden Öğretilmiş CNN	67
5. SONUÇ VE GELECEK ÇALIŞMALAR	76
5.1 Sonuç.....	76
5.2 Gelecek Çalışmalar	79
KAYNAKLAR	80
ÖZGEÇMİŞ.....	89

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1 Kolon dokusunun mukozal bölgesinin ve yoğunluğu kırmızı oklarla gösterilen kanser hücrelerinin resmi	14
Şekil 2.2 Soldan sağa sırasıyla T2 ve T3 manyetik rezonans görüntüleri	15
Şekil 2.3 Abdominal BT tarama görüntü örnekleri (daha parlak noktalara sahip alanlar tümörlü alanlardır)	15
Şekil 2.4 Nöronun temel bileşenleri	19
Şekil 2.5 Nöronun hesaplama işlemlerinin görsel temsili	20
Şekil 2.6 Nöronların aktivasyon fonksiyonu	21
Şekil 2.7 İleri beslemeli yapay sinir ağı örneği	22
Şekil 2.8 Atlamalı sinir ağı modeli	23
Şekil 2.9 Maksimum havuzlama çıktısına bir örnek	25
Şekil 3.1 Gerçek çekirge ve çekirgenin yaşam döngüsü	29
Şekil 3.2 $f = 0,5$ ve $l = 1,5$ iken, X sınırları 1-4 (solda) olduğundaki S fonksiyonu (sağda 0)	31
Şekil 3.3 f veya l değerlerinin değişmesi durumunda S fonksiyonu	31
Şekil 3.4 Bir çekirge sürüsünde primitif düzeltme eğilimleri	32
Şekil 3.5 Kolon kanseri hastalığı tanısı için önerilen yöntemin akış şeması	35
Şekil 3.6 ACO algoritmasının şematik gösterimi	37
Şekil 3.7 PSO'da hız ve konum güncellemelerini gösteren diyagram	39
Şekil 3.8 PSO algoritmasının şematik gösterimi	40
Şekil 3.9 Kolon kanseri hastalığı olan hastaların tanısı için önerilen metodolojinin yapısı	43
Şekil 3.10 (a) Doğal ortamındaki bir peygamber devesinin görüntüsü ve (b) Balık yiyen bir peygamber devesinin avlanma durumundaki görüntüsü	47
Şekil 3.11 Kolon kanseri hastalığının teşhisi için önerilen metodolojinin özeti	52
Şekil 3.12 Veri kümesinden örnek görüntüler	54
Şekil 4.1 GOA algoritması yinelemeleri bakımından özellik seçme fonksiyonunun azaltılması	58
Şekil 4.2 Önerilen yöntemin farklı CNN yöntemlerindeki sonuçları	59
Şekil 4.3 Önerilen yöntem ve diğer yöntemlerdeki hassasiyet, özgüllük, kesinlik, doğruluk ve F1'in ortalama indeksi	62
Şekil 4.4 ResNet-50 ve ACO-PSO'yu temel alan simülasyonun sonucu	65
Şekil 4.5 ACO-PSO ile GoogLeNet'i temel alan simülasyon sonucu	66
Şekil 4.6 ResNet-50 ve FMO'ya dayalı simülasyonun sonucu	68
Şekil 4.7 FMO'lu GoogLeNet'i temel alan simülasyonun sonucu	69
Şekil 4.8 Önerilen yöntemde ve karşılaştırılabilir yaklaşımlarda ortalama doğruluk, hassasiyet, kesinlik ve F1 puanının karşılaştırmalı analizi	70
Şekil 4.9 AUC sayısal sonuçlarını içeren ROC diyagramı	72

TABLÖLAR DİZİNİ

Sayfa

Tablo 3.1 Veri kümesinin açıklaması.	54
Tablo 4.1 Hassasiyet, özgüllük, doğruluk ve F1 puanlarının karşılaştırılması	60
Tablo 4.2 Farklı yöntemlerin ortalama hassasiyet, özgüllük, doğruluk, kesinlik ve F1 Puanı karşılaştırması	61
Tablo 4.3 PSO özellik seçim algoritmasını kullanan otokodlayıcıya ait kolon kanseri hastalığı veri kümesi	63
Tablo 4.4 Kolon kanseri hastalığı veri kümesi için otokodlayıcı ve ACO-PSO özellik seçiminin kullanımı	64
Tablo 4.5 FMO özellik seçim algoritmasını kullanan otokodlayıcının kolon hastalığı veri kümesi	67
Tablo 4.6 Önerilen yöntem ile karşılaştırılabilir yaklaşımlar arasındaki ortalama hassasiyet, özgüllük ve doğruluk karşılaştırması	70

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

$\vec{e}_w$	: Birim Vektör
$\vec{e}_g$	: Birim Vektör
$\frac{\partial \theta}{\partial w}$	: Hatanın Yenilenmesine İlişkin Ağın Sonucunun İlerleme Hızı
f	: Frekans
L	: Maksimum Kümülatif Tekrar Sayısı
φ	: Phi
$\Delta \tau_i^k$	: Wrapper Yöntemi Kullanılarak Elde Edilen Hatanın Tersisi
A_i	: Rüzgârın Salınımı
$c_1 - c_2$	: İvme Faktörleri
c_{max}	: En Yüksek Değer
c_{min}	: En Düşük Değer
E	: Ağın Sonucu ile Ondan Beklenen Arasındaki Hata
f	: Işık Kaynağının Yoğunluğunu
g	: Dünyanın Merkezindeki Yerçekimi Sabiti
G_i	: Yerçekimi Kuvveti
l	: Işık Emilim Faktörünü
L	: Öğrenme Oranı
lb_d	: d'inci Boyuttaki Minimum
N	: Çekirge Sayısı
p_g	: Optimal Küresel Sonucu
p_i	: En İyi Yerel Sonucu
$r_1 - r_2$	: Bağımsız Rastgele Değer
S_i	: Çekirgeler Arasındaki Sosyal Etkileşimler
t	: Yineleme Sayısı
T_d	: Hedefteki Boyut d'nin Değeri
u	: Rüzgara Doğru Sürekli Erozyonu
ub_d	: d'inci Boyuttaki Maksimum
w	: Atalet Ağırlığı
x	: Çözümü
X_i	: Değişkeninin Değeri i'inci Çekirgenin Konumu
y	: Beklenen Değer
$\hat{Y}$	: Sonuç Katmanındaki i Çıktıları İçin Gerçek Zorunlu Teşvikler
η	: Sezgisel Bilgi
Σ	: Sigma
τ	: Feromon İzi
$v_{i,k}$	: Atalet Faktörü
$x_{i,k}$	: Parçacığın Konumu
α	: Bireysel Öğrenme Parametresi
β	: Sürü Etkisi Öğrenme Parametresi

Kısaltmalar

ACC	: Doğruluk (Accuracy)
ACO	: Karınca Kolonisi Optimizasyonu (Ant Colony Optimization)
ANN	: Yapay Sinir Ağı (Artificial Neural Network)
BT	: Bilgisayarlı Tomografi
cm	: Santimetre
CNN	: Evrişimli Sinir Ağı (Convolution Neural Networks)
CRC	: Kolorektal Kanser (Colorectal cancer)
CT	: Computed tomography
DNA	: Deoksiribonükleik Asit
DT	: Karar Ağacı (Decision Tree)
FFNN	: İleri Beslemeli Sinir Ağları (Feedforward Neural Networks)
FMO	: Balıkçı Peygamber Devesi Optimizasyon
FN	: Yanlış Negatif (False negative)
FP	: Yanlış Pozitif (False positive)
GA	: Genetik Algoritma
GOA	: Güve-Alev Optimizasyonu
GWO	: Gri Kurt Optimizasyonu (Grey Wolf Optimizer)
HIPAA	: Sağlık Sigortası Taşınabilirlik ve Sorumluluk Yasası (Health Insurance Portability and Accountability Act)
IBD	: İltihabi (İnflamatuvar) Bağırsak Hastalığı (Inflammatory Bowel Disease)
KNN	: K-En Yakın Komşu
MRI	: Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
MS	: Multiple Skleroz
MSE	: Çapraz entropi ve Ortalama Karesel Hata (Mean Squared Error)
nm	: nanometre
NN	: Sinir Ağı (Neural Network)
NPV	: Negatif Tahmini Değer (Negative predictive value)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
PPV	: Pozitif Tahmini Değer (Positive predictive value)
PSO	: Parçacık Sürüsü Optimizasyonu
ReLU	: Düzeltilmiş Doğrusal Birim (Rectified Linear Units Layer)
ROC	: Alıcı İşlem Karakteristikleri (Receiver Operating Characteristic)
SSE	: Karesel Hataların Toplamı (Sum squared error)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
TanH	: Hiperbolik Tanjant
TN	: Gerçek Negatif (True Negative)
TNR	: Gerçek Negatif Oran (True Negative Rate)
TP	: Gerçek Pozitif (True Positive)
TPR	: Gerçek Pozitif Oran (True Positive Rate)

1. GİRİŞ

1.1 Arka plan

Görüntü işleme yöntemleri genellikle kolon kanseri hastalığının teşhisinde kullanılmaktadır ve bu görüntüleri analiz etmek için dikkatli bir öğrenme gerekmektedir. Görüntü ön işleme adımları sırasında görüntü arındırma, özellik etkinliğini azaltabilir ve bu yüzden sınıflandırma yöntemleri hatalı olabilir, dolayısıyla sonuçlar iyi olmayacaktır. Ayrıca bazı filtreler görüntü işleme sonrasında özelliklerini kaybettiği için bize optimum sonuçları verememektedir. Bu tezde, kolon hastalığının kapsamlarını ortaya çıkarmak için insanların eğitimi ile sinir ağı öğreniminin birleştirilmesi gibi makine öğrenme süreçlerini kombine etme girişiminde bulunulmuştur. Kolon hastalığı fotoğraflarından özellikleri çıkarmak için önerilen yöntemin ilk adımında AlexNet, SqueesNet, ResNet-50 ve Google Net ile birlikte evrişimli sinir ağı kullanılmıştır. Bu fotoğraflardaki özellik sayılarının yüksek olması, bunların hastanın durumunu kategorize etmek amacıyla makine öğreniminde kullanılmasını uygunsuz hale getirir; bu nedenle özellik sayısının azaltılması gerekmektedir. Çekirge optimizasyon süreci kullanılarak özellik sayısı azaltılmıştır. Çekirge optimizasyonu, özelliklerin seçiminde uygunluk fonksiyonunu hızlı bir şekilde yakınsamakta en iyi tekniklerden biri olduğu için seçilmiştir. Sınıflandırma adımında destek vektör makinesi (SVM), k-en yakın komşu (KNN) ve karar ağacı (DT) kullanılmıştır. Sonuçları değerlendirmek için F1 puanı metodolojisi ve karışıklık matrisi kullanılmıştır. Dünya çapında pek çok insan birçok kanser türünden dolayı hayatını kaybetmektedir. En tehlikeli kanser türlerinden biri de kolon kanseridir. Bu kanser türü çoğunlukla yaşlı bireylerde, özellikle de erkeklerde tespit edilmiştir. Dünyada kanser tanısında ve takibinde sorunları azaltacak yöntemlerin bulunması hayati önem taşımaktadır. Bu tezde, kolon kanserini histopatolojik görüntülerden bulmak ve sınıflandırmak için otomatik bir süreç sunmak amaçlanmıştır.

Meta-sezgisel tekniklere dayalı en iyi özellik seçme stratejisinin kullanılmasıyla elde edilebilecek olan bu çalışmanın birincil amacı sınıflandırma doğruluğunu artırmaktır.

Bu tezin temel katkısı şu şekilde özetlenebilir:

- Görüntünün içerdği bilgi ve bilgileri geliştirmek için bileşen azaltma yönteminin kullanılması (Bu tezde GOA kullanılmıştır),
- GOA ile birlikte önemli görüntü piksellerini seçmek için yapay zekanın kullanılması,
- Kolon kanseri hastalığı görüntülerinden özellik çıkarımı için CNN'nin kullanılması,
- Görüntülerin analiz edilmesi ve kolon kanseri hastalığı görüntülerinin doğru bir şekilde sınıflandırılması.

Kolonik polipler çoğunlukla ve belli özelliklerine dayanarak kolon ve rektum kanserlerine neden olmaktadır. Dünya çapında her yıl yaklaşık bir milyon kişiye kolon ve rektum kanseri teşhisi konulmaktadır. Hastalık en çok can kaybına neden olan kanser türlerinden biri olması nedeniyle oldukça önemlidir ve üzerine çalışmalar ciddi manada devam etmektedir.

Kalın bağırsak veya tıbbi ismiyle kolorektal kanser (CRC); yaşam boyu risk tayini bakımından değerlendirildiğinde kadınlara göre erkeklerde biraz daha yüksektir. Bu oran erkeklerde %4,5 iken kadınlarda ise %3,2'dir. CRC çoğunlukla adenomatöz poliplerden gelişir.

Kolon veya rektum mukozasından köken alan bu benign ancak pre-kanseröz özellik taşıyan lezyonlar, uzun yıllar semptom ve bulgu vermedikleri için çoğu zaman fark edilememektedir. Adenom görülme sıklığı yaşla birlikte artmaktadır. Ancak adenomdan kanser gelişim süreci büyük ölçüde aydınlatılmış olmasına rağmen bu süreci etkileyen dış faktörler halen tartışılmakta ve ciddi etkinliği olduğu düşünülen epigenetik risk faktörleri de yeterli aydınlatılamamıştır.

1.2 Kolorektal Kanser (CRC) Önleme Yolları

Kolorektal kanserlerden korunmanın temel koşulu gerekli tarama testlerinin ihmal edilmemesidir. Özgeçmiş ve soygeçmişi değerlendiren hekimin önerdiği şekilde gaitada gizli kan testi, kolonoskopi veya rektosigmoidoskopi tetkiklerinin yapılması kolorektal kanserleri önlemede kanıtlanmış öncelikli yoldur ve tarama programları şeklinde sağlık politikalarına da dahil olmuştur.

Öte yandan tütün veya tütün ürünleri ve alkol kullanımı, spor ve egzersiz açısından aktif bir yaşam tarzının benimsenmeyip sedanter yaşam tarzı, aşırı trans yağ ve kırmızı et tüketiminin yapılması, tam tahıllar ve lifli besinlerden zengin bir beslenme düzeninin benimsenmemesi de kolorektal kanserler de suçlanan bazı risk faktörlerinden ön planda tutulmaktadır.

1.3 Kolon Kanseri

Yaklaşık 1,5 metre uzunluğunda olan kolonun mukozasından (iç döşeme epitelinden) oluşan kanserlere kolon kanseri adı verilmektedir. Bu tip kanser, kalın bağırsağın iç yüzeyini kaplayan tabakanın içindeki hücrelerin ve hücre topluluklarının kontrolden çıkması yani kontrolsüz büyüme ve çoğalmasından ortaya çıkar.

Kalın bağırsağın son 15-20 cm'lik kısmına rektum adı verilir ve burada ortaya çıkan kanserlere rektum kanseri denir. “Kolorektal kanserler” aynı zamanda iki kanser türünü tanımlamak için kullanılan çok yaygın bir terimdir.

T.C. Sağlık Bakanlığı verilerine göre kolorektal kanserler ülkemizde en sık görülen 5 kanser arasında yer almaktadır.

1.3.1 Risk Faktörleri

1.3.1.1 Yaş

Kolon kanseri her yaşta ortaya çıkabilir. Ortalama başlangıç yaşı 63'tür. Ancak yapılan çalışmalara göre kolorektal kanser tanısı alan hastaların üçte biri 55 yaşın altındadır.

1.3.1.2 Cinsiyet

Erkekler ve kadınlar arasında görülme sıklığı açısından düşük bir oranda olsa erkek cinsiyette artmış riskten bahsedilmektedir.

1.3.1.3 Diğer risk faktörleri

Kolorektal kanserin kesin nedeni bilinmemekle birlikte kolorektal kanser gelişimini arttıran risk faktörleri şunlardır:

- İleri yaş,
- Bağırsakta polip varlığı (özellikle adenomatöz patolojisi olanlarda),
- Ailede kolorektal kanser hastasının bulunması,
- Genlerde önemli değişikliklere neden olan, kolon ve rektumda kalıtsal poliplerle karakterize bazı genetik bozuklukların (kalıtsal olmayan polipozis kolon kanseri hastaları) ve/veya ailesel polipozis sendromlarının varlığı,
- Belirli bir süre içerisinde bağırsak içi hücre tipini bozarak kansere yol açabilen iltihabi bağırsak hastalığına (Ülseratif kolit veya Crohn hastalığı) sahip olmak,
- Kadınlarda yumurtalık, meme ve rahim kanseri öyküsüne sahip olmak,

- İşlenmiş ve hayvansal gıdaların aşırı tüketimi, daha az meyve ve sebze tüketimi ve tütün veya tütün kullanımı.

Bu risk faktörlerine sahip kişilerin daha erken yaşlardan itibaren bağırsak kanseri açısından taranması gerekmektedir.

1.3.2 Kolon Kanseri Belirtileri

Kolon kanserinin başlangıcı bağırsakta anormal hücre çoğalması yani poliplerdir. Ancak polipler, çoğu zaman ilk etapta herhangi bir şikâyetle neden olmaz. Polipler kanserleşmeye başladıkça, boyutları büyüdükçe veya sayıları arttıkça kişinin bağırsak alışkanlıklarında şu değişikliklere neden olurlar;

- Yeni başlayan kabızlık veya tam tersi, dışkı kokusunda veya kıvamında (ishal lehine) değişiklik,
- Demir eksikliğinden kaynaklanan anemi,
- Dışkı kalınlığının incilmesi, dışkıya kan karışması veya tuvalete gittikten sonra anüsten kanama, karın ağrısı, iştahsızlık ve istemsiz kilo kaybı.

Yukarıdaki bulgular tek başına kolorektal kanseri göstermez. Ancak bu şikayetlerin mevcut olması durumunda hastanın gerekli kontroller için hekime başvurması gerekmektedir. Ayrıca hastanın ailesinde bağırsak kanseri, meme, yumurtalık veya rahim ağzı kanseri öyküsü veya bu belirtilerden biri varsa mutlaka hekime başvurmayı ihmal etmemesi gerekir.

Özellikle gençlerde, kronik kabızlığı olanlarda, belirli şikâyeti olmayanlarda (kilo kaybı, iştahsızlık, kansızlık gibi) kolorektal kanser belirtilerinden ziyade hemoroidal hastalık veya anal fissür hastalığı nedeniyle rektal kanama da görülebilmektedir. Bu şikayetlerin gerçek sebebini daha fazla araştırma yapılmadan yani ileri tetkik edilmeden söylemek çoğu zaman mümkün olmamaktadır.

1.3.3 Kolon Kanseri Gelişiminde İnflamatuvar Bağırsak Hastalığı

Ülseratif kolit veya Crohn hastalığı, kalın bağırsağı kaplayan dokuların kronik iltihaplanmasıdır. Her ikisi de kolorektal kanser hastalığının gelişimi için risk faktörleridir. Her iki hastalık içinde iltihabi (inflamatuvar) bağırsak hastalığı (IBD – inflammatory bowel disease) terminolojisi kullanılmaktadır.

Özellikle 10 yıldan uzun süredir IBD olan kişilerde (tedaviye yanıt vermiş olsalar dahi) kolorektal kansere yakalanma olasılığı oldukça artmaktadır. Bu nedenle hastalığa bağlı şikâyeti olsun ya da olmasın bu hastalarda rutin tarama kolonoskopilerinin yapılması gerekmektedir.

IBD’de bu hastalığa bağlı striktür olan bölgelerde kolorektal kansere yakalanma olasılığı artar. Bu iki hastalığın varlığında sigara içmeye devam etmek kolorektal kansere yakalanma riskini kanıtlanmış şekilde arttırmaktadır.

Kolon kanserinin erken taramasına yönelik testler şunları içermektedir:

- Kolonoskopi,
- Gaitada gizli kan testi,
- Bilgisayarlı tomografi (BT) kolonografisi,
- Fleksibl rektosigmoidoskopi,
- Gaitada moleküler DNA testleri.

Kolonoskopi, daha önceden dışkıyı temizlenmiş olan kalın bağırsağa, ucunda ışık ve kamera bulunan bir aletle anüsten girilerek, bağırsağın hava verilerek hafifçe şişirilmesi ve bağırsağın içinin incelenmesidir. Genellikle 30-45 dakika sürer.

İşlem sırasında gerekli görülmesi halinde bağırsağın mukoza zarından ve anormal görünümdeki dokulardan da biyopsi alınabilmektedir. Polip görülmesi halinde aynı

seansta çıkarılabilir ya da çıkarılamayacak özelliklere sahipse örneklenebilir. Kolonoskopi sırasında mevcut kanama odakları da durdurulabilir. Kolonoskopi gibi işlemlere hastalardan tarafından çekince ile yaklaşılabilir. Kolonoskopi işlemleri hastalardan tarafından çekince ile yaklaşılabilir.

Kolonoskopi, ağrı azaltıcı ilaçlar verilerek ya da anestezi ekibi eşliğinde kişiye hafif uyku verilerek yapılabilir. Bu nedenle, kolonoskopi üzerine oluşan çekinceler işlemin tanısai kıymeti ve işlem yapılırken hasta konforu için yapılabilecekler sebebiyle oluşmamalıdır.

Kolonoskopi işleminin en zahmetli kısmı kolonoskopiden bir gün önce çeşitli ilaçlarla ve bol sulu yiyeceklerle beslenerek bağırsağın temizlenmesidir (kolonoskopiye hazırlık). Bu hazırlık süreci ve işlemin yapıış şekli işlem öncesi hekim/hemşire/sağlık personeli tarafından detaylı bir şekilde anlatılarak hastaların korkuları azaltılabilir. Ailesinde bağırsak kanseri öyküsü olmayan ve bağırsak şikâyeti olmayan kişilerde kolonoskopi taramasına 50 yaş civarında başlanır, polip bulunmadığı durumlarda 10 yılda bir tekrarlanmalıdır. Birinci derece akrabasında 65 yaşından önce bağırsak kanseri veya meme, rahim ve yumurtalık kanseri olan kişilerde kolonoskopi ile tarama yaşı 40'tır. Kişinin 1. derece akrabasının yaşı 40 yaşından küçük ise taramanın erken yaşta yapılması gerekmektedir. IBD hastalarında tanı anında ve eğer yeni problemler gelişmediyse hastalık yaşı 10 yılı aştığında her yıl kolonoskopi kontrolü gerekmektedir. Ailede genetik aktarmalı polipozis sendromları bulunan kişilerde taramaya 15-18 yaşlarında başlanabilmektedir. Tarama kolonoskopisinde tespit edilen poliplerin sayısına ve patolojik tiplerine göre 1-3-5 veya 10 yıl aralıklarla kontrol kolonoskopisi yapılır. Tarama sadece sol kolon tümörlerine yönelikse, uzun kolonoskopi muayeneleri arasında tarama için 2-3 yılda bir fleksibl rektosigmoidoskopi kullanılabilir. Gerekli koşullar olmadığı sürece "her yıl kolonoskopi yapılmalı" ifadeleri tanı ve takip algoritmalarına oturmuş söylemler değildir. Hastanın kolonoskopiye tercih etmediği durumlarda 5 yılda bir BT kolonografi yapılabilir. Ancak BT kolonografilerde sadece tanı konulabilir, herhangi bir polip veya kitle görüldüğünde bu lezyonlardan biyopsi alınması için kolonoskopi yapılması gerekecektir. Ayrıca, BT kolonografilerde tanısai duyarlılık konvansiyonel kolonoskopilere oldukça düşüktür.

Gaitada gizli kan testi ilk kolonoskopi taramasına kadar yılda bir kez yapılmalıdır. Gaitada DNA testleri de 2-3 yılda bir yapılan tarama testleri arasındadır. Kolon kanserinden korunmak için sağlıklı beslenmek ve belirtilen öneriler çerçevesinde doğru zaman aralıklarında tarama testlerini yaptırmak gerekir. Sebze, meyve ve lif açısından zengin beslenmek, işlenmiş ve hayvansal protein bazlı gıdalardan kaçınmak, düzenli egzersiz yapmak ve sigara içmemek bağırsak kanserinden korunma yöntemleridir. Görüntüleme teknikleri çeşitli hastalıkların, Alzheimer, Multiple Skleroz (MS) ve kolorektal kanserin teşhisinde hayati bir rol oynamaktadır (Ashraf vd., 2021; Burggraaff vd., 2021; Gonzalez vd., 2021; Zhang vd., 2021). Kolon kanseri, insanların karşılaştığı ve her yıl dünya çapında milyonlarca insanın ölümüne neden olan hastalıklardan biridir (Shang vd., 2021). Bu hastalığı teşhis etmenin pratik bir yolu, BT taramaları ve MRI gibi tıbbi görüntüleri kullanmaktır. Kolon kanseri, kanser hücrelerinin veya kolonun bir kısmının anormal büyümesi ve çoğalmasıdır. Bu hücrelerin anormal büyümesi, vücuttaki sağlıklı dokuların kötü huylu hücreler tarafından saldırıya uğramasına neden olur. Kolon kanserinin nedenleri yaşam tarzı, yaşlanma ve genetik bozukluklardır. Bu hastalıkta diyet, obezite, sigara kullanımı, fiziksel aktivite azlığı gibi risk faktörleri yeterlidir. Çalışmalar, işlenmiş et ve alkol tüketimi ile hastalık ve kanser arasında bir bağlantıya sahip olduğunu göstermektedir (Grass vd., 2020). Kolorektal kanserde erken dönemde iyi huylu ancak prekanseröz bir tümör gelişir. Bu tümörler zamanla kötü huylu yani kanserli tümörlere dönüşür. Kolon kanserini teşhis etmenin bir yolu kolonoskopi kullanmaktır. Kolonoskopi genellikle sınırlı kalan bir işlemdir. Çoğu durumda, hastalığın boyutunu teşhis etmek için tıbbi görüntüleme yapılır. BT taramasının kullanımı kolon kanserinden ölüm riskini azaltmada çok etkilidir. Çünkü, lokal ileri/metastatik hastalığı saptamada önemli bir tanısal araçtır (Javan vd., 2021). Tıbbi görüntüleme teknikleri, hekimlerin hastalık sürecini ve hastaların vücutlarındaki hastalık yayılımını yakından izlemelerine yardımcı olur. Bu hastalığın tedavileri arasında ameliyat, radyasyon tedavisi, kemoterapi ve ilaç tedavisi yer alır. Araştırmalar hastalığın gelişmiş ülkelerde daha sık görüldüğünü göstermektedir. Yapılan bilimsel çalışmalar, vakaların %65'inin bu ülkelerde bulunduğunu belirlemiştir. Bu hastalığın yaygınlığı kadınlarda erkeklere göre daha düşüktür (Achilli vd., 2021). Tıbbi görüntü analizi vücuttaki hastalığı teşhis etmenin etkili bir yoludur. Görüntü işleme teknikleri, hekimlerin kolon kanserinin ciddiyetini tıbbi

görüntülere dayanarak teşhis etmesine olanak tanımaktadır. BT taramaları da dahil olmak üzere tıbbi görüntüleri analiz etmek için çeşitli çalışmalar geliştirilmiştir. Hastalığı teşhis etmenin çoğu yöntemi makine öğrenimi ve derin öğrenmedir (Ahmed vd., 2021a, 2021b; Jia vd., 2019; Tulum vd., 2019). Yapay sinir ağları, destek vektör makinesi, bulanık yöntemler ve uzman sistemler gibi yöntemler, tıbbi görüntüleri kullanarak hastalığın teşhisine yönelik kullanılan yöntemler arasındadır (Jerebko vd., 2005; Gonzalez vd., 2021; Pagès vd., 2016; Viji vd., 2021). Çoğu yöntemde görüntüler bölümlere ayrılmakta ve ardından hastalık alanları belirlenmektedir. Bu tezin ana katkısı, BT görüntüleri için özellik seçiminin kullanılmaması veya özelliğin seçilmesi için temel bileşen analizi (PCA) gibi istatistiksel yöntemlerin kullanılmasıdır. Tezin avantajları, akıllı özellik seçme yönteminin kullanılması ve sınıflandırma yöntemlerinin öğrenilmesi için temel özelliklerin kullanılmasıdır. Özellik seçimi kolon kanseri tanısının doğruluğunu artırır.

1.4 Önerilen Araştırma

Önerilen yöntemlerde, özellik seçimi için grup öğrenme optimizasyon algoritmasının ikili bir versiyonu önerilmektedir (Zhang ve Jin, 2020). İkinci aşamada sinir ağı öğrenilerek ve seçilen özellikler kullanılarak, iyi huylu ve kötü huylu görüntüler ayrıştırılır. Tezin başarılarından biri de özellik seçimi için bir GOA algoritması kullanmak, kolon kanseri hastalığını sınıflandırmak için sinir ağı öğrenme yeteneğini kullanmak ve kolon kanseri hastalığı görüntülerinin doğru teşhisini sağlamaktır.

1.5 Araştırmanın Yaklaşımı

Kolon kanseri hastalığı tanısı genellikle görüntü işleme yöntemleriyle yapılır ve bu görüntüleri analiz etmek için dikkatli bir öğrenme gerekir. Görüntü ön işleme adımlarında görüntü arındırma, özneliliklerin etkinliğini azaltabileceği gibi, sınıflandırma yöntemleri de hataya düşebilir ve sonuçların iyi oluşmamasına sebep olabilir. Ayrıca görüntü işlemede bazı filtreler özelliklerini kaybettiği için bize optimum sonuçları verememektedir.

Bu tezde, kolon kanseri hastalığının olduğu bölgeleri ortaya çıkarmak amacıyla makine öğrenimi becerilerini sinir ağına öğrenme ve öğretme ile birleştirmeye yönelik bir girişimde bulunulmuştur. Önerilen yöntemde öncelikle AlexNet, SqueesNet, ResNet-50 ve Google Net'ten oluşan evrişimli sinir ağı, kolon hastalığı görüntülerinden özellikleri çıkarmak için kullanılmıştır. Bu görüntülerdeki özelliklerin sayıları fazladır ve hastalığı sınıflandırmak için makine öğreniminde kullanılmaya uygun değildir. Bu nedenle özellik sayısının azaltılması gerekmektedir. Özellik sayısını azaltmak için çekirge optimizasyon algoritması kullanılmıştır. GOA, özellikleri seçmek için en güçlü algoritmalarından biridir ve bu algoritma, uygunluk fonksiyonu sonuçlarını yakınsamada hızlıdır. Son olarak, sınıflandırma adımıda destek vektör makinesi (SVM), karar ağacı (DT), Topluluk, k-en yakın komşular (K-NN) gibi makine öğrenmesi yöntemleri kullanılmıştır. Sonuçları değerlendirmek için karışıklık matrisi, ROC analizi ve F1 puanı yöntemleri uygulanmıştır.

1.6 Araştırmanın Motivasyonu

Son dönemde dünya genelinde birçok insan birçok kanser türünden dolayı hayatını kaybetmektedir. En tehlikeli kanserlerden biri kolon kanseri hastalığıdır. Bu kanser türü ileri yaştaki kişilerin çoğunda, özellikle erkeklerde tespit edilmiştir. Bu konuda dünyadaki kanser sorunlarını azaltacak yöntemlerin bulunması hayati önem taşımaktadır. Bu tezde kolon kanserinin histopatolojik görüntülerden bulunması ve sınıflandırılması için otomatik yöntem tanıtılmıştır.

1.7 Araştırmanın Katkısı

Bu çalışmanın temel katkısı, meta-sezgisel yöntemlere dayalı optimum öznetelik seçme yönteminin kullanılması ve sınıflandırmanın doğruluk performansının artırılmasıdır. Karınca kolonisi optimizasyonu, parçacık sürüsü optimizasyonu, genetik algoritma gibi meta-sezgisel yöntemlerden farklı yöntemler kullanılmış, test edilmiş ve sonuçları elde edilmiştir. Ayrıca daha önce kullanılmayan çekirge optimizasyon yöntemi kullanılmıştır.

Çalışmanın katkısı şu şekilde vurgulanabilir:

- Görüntünün içerdği bilgileri geliştirmek için bileşen azaltma yönteminin kullanılması (Bu tezde GOA kullanılmıştır)
- GOA ile birlikte önemli görüntü piksellerini seçmek için evrişimli sinir ağının kullanılması
- Kolon hastalığı görüntülerinden özellikleri çıkarmak için CNN'in kullanılması
- Görüntülerin incelenmesi, analiz edilmesi ve kolon kanseri hastalığı görüntülerinin doğru bir şekilde sınıflandırılmasının sağlanması

1.8 Tezin Düzenlenmesi

Bu tez çeşitli bölümlere ayrılmıştır. Sorun ilk bölümde tanıtılmıştır. Araştırmanın ikinci bölümü kolon kanseri hastalığı alanındaki araştırmalara odaklanmaktadır. Üçüncü bölümde, özellik seçiminde kullanılan yeni öğrenim ve kolon kanseri hastalığı teşhisi için önerilen yaklaşım, öğrenimin ikili versiyonu kullanılarak formüle edilmiştir. Dördüncü bölüm ve son bölümde, uygulamalar ve deneyler, önerilen yaklaşım ve mevcut yaklaşımların karşılaştırılması, araştırma bulguları ve kolon kanseri hastalığının teşhisinde önerilen bir algoritmanın geliştirilmesine yönelik gelecekteki fikirler anlatılmıştır.

Tezin geri kalanı şu şekilde organize edilmiştir: Bölüm 2'de literatürdeki çalışmalar gözden geçirilmektedir. Bölüm 3'te bu çalışmada kullanılan materyal ve yöntemler açıklanmakta, Bölüm 4'te tahmin algoritması ve deneysel sonuç hakkında bilgi verilmektedir ve son olarak Bölüm 5'te sonuçlar sunulmaktadır.

2. LİTERATÜR TARAMASI

2.1 Makine Öğrenimi ve Kanser Tespiti

Rastgele orman, destek vektör makineleri, CNN'ler ve Bayes ağları, kanser teşhisi için en yaygın kullanılan makine öğrenme algoritmalarıdır. Bazazeh ve Shubair (2016) tarafından gösterildiği gibi destek vektör makineleri ve rastgele orman tekniği kullanılarak meme kanserini tanımlamak için mamogram resimlerinden yararlanılabilmektedir. Başka bir çalışmada Alam vd., (2018), akciğer kanseri sınıflandırması için destek vektör makinelerini ve bilgisayarlı tomografi taramalarını kullanmışlardır.

Yakın zamanda kanser teşhis sürecinde CNN'lerden yararlanılmıştır. Tan vd., (2017) tarafından meme kanseri tespiti için CNN'ler ile elde edilen gri tonlamalı mamografi resimleri kullanılmıştır. Ayrıca, Godkhindi ve Gowda (2017) rastgele orman işlemlerini, CNN'leri ve K-en yakın komşu (KNN) algoritmalarını kullanarak gri tonlamalı bilgisayarlı tomografi kolonografi görüntüleri yardımıyla kolon kanserini tespit etmek için yöntemler geliştirmişlerdir. Chiang vd., (2018) tarafından, 3 boyutlu ultrasonografi görüntülerini kullanarak meme kanserinin tanısını iyileştirmek için bir 3D CNN'den yararlanılmıştır.

Hiperspektral görüntüleme, tıbbi teşhis aracı olarak yeni görüntüler içerirken ticari ve araştırma uygulamalarında giderek yaygınlaşmaktadır. Lu ve Fei (2014)'ya göre hiperspektral görüntüleme, hastalıkların teşhisi ve görüntü kılavuzluğu için ameliyatlarda kullanılmaktadır. Ayrıca meme, rahim ağzı, prostat, cilt ve mide kanserleri de dahil olmak üzere çeşitli kötü huylu tümörleri test etmek için birçok farklı hiperspektral tanımlama sistemlerini tartışmışlardır. Çok sayıda kanser tespit uygulaması, spektrumun görünür kısımlarıyla, özellikle mavi ve yeşil dalga boylarıyla ilgilenir. Örneğin Leavesley vd., (2016)'nın araştırmasına göre spektrumun mavi-mor bölgesinin (390-450 nm) kolon kanseriyle güçlü bir şekilde bağlantılı olduğu bulunmuştur.


Makine öğrenimi hiperspektral görüntüleme ile birleştirildiğinde bazı yeni, invazif olmayan kanser tespit yöntemleri geliştirilmiştir (Lu ve Fei, 2014; Leavesley vd., 2016; Nathan vd., 2018). PCA yardımıyla özellik azaltımı için hiperspektral veri analizi yöntemleri geliştirilmiştir. Bu amaçla minimal kapsamlı ormanlar ve destek vektör makineleri de uygulanmıştır. Rathore vd., (2013)'nin belirttiği gibi hiperspektral kolon kanseri tanısı için doğrusal diskriminant analizi ve destek vektör makineleri kullanılmaktadır. Lu vd., (2014), invazif olmayan boyun ve baş kanseri tespit yöntemlerinin etkinliğini artırmak için spektral ve uzaysal verilere sahip destek vektör makinelerini kullanmışlardır. Xu vd., (2015), baş ve boyun kanserlerinin hiperspektral sınıflandırmasını değerlendirmek için tümör taşıyan farelerden yaralanmışlardır. Gopi ve Reshmi (2017), birçok hayvandaki kanserleri tanımlamak için destek vektör makinelerini minimal kapsamlı ormanlarla birleştiren bir teknik yaratmışlardır.

Ayrıca sinir ağı modelleri yardımıyla sık hiperspektral görüntüleme, kanser tespit yöntemlerinin iyileştirilmesinde kullanılmıştır. Örneğin Leavesley vd., (2018), kolon kanseri görüntülerini kategorize etmek için hiperspektral floresans ve ANN kullanmışlardır. Leavesley vd., (2014) tarafından yapılan çalışmada, kanser verilerini sınıflandırmak için hiperspektral görüntüleri kullanan ANN'ler araştırılmıştır. Ma vd., (2017), CNN ve piksel sınıflandırmasını kullanarak baş ve boyun kanserlerini tanımlamışlardır. Her pikselin görüntü spektrumunu alarak ve bunu bir CNN'ye besleyerek 16x16'lık bir yama oluşturmuşlardır.


2.2 Kolon Kanseri

Kolorektal kanserli hastaların tedavisinde görüntüleme ve tıbbi görüntülerin kullanılması hayati öneme sahiptir. Klinik muayene ve kolonoskopiden sonra hastanın pelvisinin manyetik rezonans görüntülemesi gereklidir (D'Souza vd., 2020). Kolon kanserinin semptomları çeşitlidir ve çeşitli enfeksiyonlar, ateş, hemoroidal hastalık ve inflamatuvar bağırsak hastalığını içerir. Bireyler bu faktörlerden herhangi birini gözlemleyerek ilk tedaviye başlamak için bir hekime başvurabilirler (Catalano vd., 2021). Bu hastalığın tedavisinde tedaviye erken dönemde başlanması hastaların iyileşme şansını artırmaktadır. Bazı durumlarda birey kansere sahip olabilir ancak


hiçbir belirti göstermeyebilir, bu nedenle yaşlılar gibi yüksek risk altındaki kişilerde tarama yapılması önemlidir. Kolorektal kanser, tarama yoluyla erken evrelerde önlenabilir ve tedavi edilebilir. Tarama yöntemlerinden biri de tıbbi görüntülerin kullanılmasıdır. Kolon kanseri, genel anlamda poliplerin (adenom) büyümesinden kaynaklanır. Daha büyük adenomlar, bu sorunların kanserli olma olasılığının daha yüksek olduğunu göstermektedir (Richards vd., 2020). Kolon kanserini teşhis etmenin pratik bir yolu tıbbi görüntüleme tekniklerini kullanmaktır. Şekil 2.1, bir renkli kesitte mukozal adenokarsinomun histopatolojisini göstermektedir. Bu görüntü, kırmızı oklarla gösterilen alanlarda dairesel olarak kanserli dokuların varlığını göstermektedir. Mikroskopik inceleme hastalığın teşhisinde kullanılan adımlardan biridir. Başka bir yöntem manyetik rezonans görüntüleme veya kolon taraması kullanmaktır. Şekil 2.2 bağırsaktaki tümör alanlarını tespit etmek için manyetik rezonans görüntüleme kullanımını göstermektedir. Şekil 2.3, kolondaki kanserli dokuların analizi için BT tarama yöntemini göstermektedir (Ataka vd., 2020; Luo vd., 2019).



Şekil 2.1 Kolon dokusunun mukozal bölgesinin ve yoğunluğu kırmızı oklarla gösterilen kanser hücrelerinin resmi



Şekil 2.2 Soldan sağa sırasıyla T2 ve T3 manyetik rezonans görüntüleri



Şekil 2.3 Abdominal BT tarama görüntü örnekleri (daha parlak noktalara sahip alanlar tümörlü alanlardır)

2.2.1 Kolon Kanseri Hastalığının Teşhisi

Masud vd., (2021) tarafından yapılan çalışmada, derin öğrenme kullanarak akciğer ve kolon kanserini teşhis etmek için bir makine öğrenme yaklaşımı önerilmiştir. Araştırmalarına göre kanser dünyada ikinci önde gelen ölüm nedenidir. Her altı kişiden biri kanser sebebiyle ölmektedir. Çeşitli kanserler arasında akciğer ve kolon kanserleri en yaygın ve ölümcül olanlardır. Kolon kanserleri dünya genelinde tüm kanserlerin yaklaşık %25'ini oluşturmaktadır. Modern derin öğrenme tekniklerini ve dijital görüntü işlemeyi kullanan bu tez, histopatolojik görüntüleri analiz ederek beş tip akciğer ve kolon dokusunu iki iyi huylu ve üç kötü huylu olarak ayırt etmeye yönelik bir sınıflandırma sunmaktadır. Sonuçlar, önerilen yöntemin kanserli dokuları

%96,33 maksimum doğrulukla tanımlayabildiğini göstermektedir. Bu modelin uygulanması, tıp profesyonellerinin farklı akciğer ve kolon kanseri türlerini tanımlamak için otomatik ve güvenilir bir sistem oluşturmaya yardımcı olacaktır.

Daye vd., (2021) tarafından yapılan çalışma, kolorektal kanserli hastalarda makine öğrenimine dayalı bir prognostik yöntem sunmuştur. Tek değişkenli regresyon analizi, hastanın hayatta kalmasını tahmin etmede yararlanılan 110 özelliği değerlendirmek için kullanılmaktadır. Standart prognozun karakteristik vektörü ve klinik ve patolojik değişkenleri üzerinde rastgele orman tabanlı bir makine öğrenme yöntemi uygulanmıştır. Bu veri seti %75 öğrenme ve %25 test verisi oranlarında ayrılmaktadır. Sınıflandırma performansını değerlendirmek için ROC analizi ve bulanık matris analizi kullanılmıştır. Bilimsel çalışmalar, çalışılan popülasyonun ortalama hayatta kalma süresinin $39 \pm 3,9$ ay olduğunu göstermektedir. Görüntüleme tabanlı heterojenlik özelliklerine sahip bir model, model performansını yaşaya bilirliliği 0,94'e kadar tahmin edecek şekilde geliştirmiştir.

Masud vd., (2021) tarafından yapılan çalışmada, kolorektal kanser için global etiketler kullanarak derin öğrenme ile histopatolojik bir sınıflandırma yöntemi önermişlerdir. Günümüzde histopatolojik görüntüleme kolon kanserinin klinik tanısı için hayati bilgiler sağlamak ve kanser sınıflandırmasının iyileştirilmesinde derin öğrenme teknikleri yaygın olarak kullanılmaktadır. Bu tezde, sadece global etiketler kullanarak kolorektal kanserin derin öğrenme ile teşhisi için yeni bir yöntem geliştirilmiştir. Yakın zamanda hastanelerden toplanan 50 kolon kanseri örneği üzerinde yapılan bağımsız testler, yöntemlerinin yaklaşık %92 oranında doğruluğa sahip olduğunu göstermektedir.

Qi vd., (2021) tarafından gerçekleştirilen çalışma, histopatolojik görüntülerde derin öğrenmeyi kullanarak kolon kanseri tanısında prognostik mekânsal özelliklerin tanımlanmasını önermiştir. Amaçları, histopatolojik görüntülerde prognostik mekânsal özellikleri belirlemek için güçlü ve akıllı bir yapay sistem oluşturmaktır. 107,180'lik iki görüntü grubu kullanarak, doğru doku sınıflandırması için derin evrişimli bir sinir ağını eğitmiş ve doğrulamışlardır.

Zhao vd., (2020) yaptıkları çalışmada makine öğrenimini kullanarak kolon kanseri teşhisine yönelik bir yöntem önermişlerdir. Amaçları, kolon kanseri teşhisini daha doğru bir şekilde tahmin etmek için makine öğrenimini kullanmaktır. Yöntem, Ulusal Kanser Veri tabanını (2014-2019) kullanarak kolon kanserini teşhis edebilmektedir.


Pacal vd., (2020) tarafından gerçekleştirilen çalışmada, kolon kanseri tanısında derin öğrenmeyi kapsamlı bir şekilde ele almışlardır. Yazarlar, kolorektal kanser analizine yönelik derin öğrenme uygulamalarını gözden geçirerek ilerlemeye ışık tutmayı amaçlamışlardır. Bu çalışma kolorektal kanser analizinde kullanılan derin öğrenme mimarilerine genel bir bakış sunmaktadır. Çeşitli çalışmalar; kolorektal kanser analizini, kolorektal kanser ve derin öğrenme bağlamında incelemiştir. Bu araştırmalarda kanser tanısı, sınıflandırma, segmentasyon, sağkalım tahmini ve inflamatuvar bağırsak hastalığı tanısına yönelik çalışmalar tartışılmış ve analiz edilmiştir.

2020 yılında bir araştırmada, makine öğrenimi ve uzaysal özellikleri kullanarak endoskopik görüntülere dayalı kolon poliplerinin teşhisi tanıtılmıştır. Kolon kanseri kolondaki poliplerle başlar. Erken önleyici tedbirler, kanserde polip gelişiminin önlenmesinde hayati bir rol oynar. Poliplerin tıbbi görüntülere dayalı erken teşhisi, örnek faktörleri ve kullanılan teknik faktörleri içerdiğinden oldukça zordur. Bu çalışma, polip büyümesine ilişkin bir otomasyon sistem sınıflandırması oluşturmayı amaçlamaktadır. Bu yöntemin amacı patologların ve hekimlerin insan bağırsağındaki poliplerin teşhisinde çok dikkatli olmalarını sağlamaktır. Bu çalışma, polip görüntüsünden önemli özellikleri çıkarmak için uzaysal özellik çıkarımı kullanan endoskopik kolon veri setine ve hastalık sınıfını belirlemek için reperfüzyon sinir ağının gizli bir katmanla sınıflandırma fonksiyonuna dayanmaktadır. Yapılan deneylere dayanarak, önerilen sistemin polip sınıflarını %93,94 doğruluk seviyesi ve %6,05 yanlış pozitiflik oranıyla tespit edebildiğine ulaşılmıştır.

2.3 Yapay Sinir Ağı (ANN)

2.3.1 Arka plan

ANN, bireylerin beyinlerindeki, birbirine bağlı nöron adı verilen çok sayıda sinir hücresinden oluşan NN'lerin sayısal bir temsilidir. İnsan beynindeki ortalama nöron sayısı yaklaşık 86 milyardır. Nöronlar arasındaki bağlantılar, hücrenin katman olarak adlandırılan kümesi tarafından üretilen elektrik sinyallerinin geçici uyarıları ile sağlanır. Bu bilgi, bir nörondan diğerine nörotransmitter adı verilen elektrokimyasal kesişmeler olarak iletilir; bu kesişmeler, sinyalleri çok sayıda nörondan sinir hücresinin gövdesine kadar taşıyan ve dendritler olarak adlandırılan, onları hücrenin gövdesine bağlayan dallar üzerinde bulunur. Burada özellikler, akson olarak adlandırılan nöronlar için, "Ateş" olarak da adlandırılan elektriksel bir işaret oluşturulup oluşturulmayacağına karar verilmek amacıyla işlenir. Bir nörondan diğerine aktarılan bir sinyal, alıcı nöron üzerinde iki etkiden birine sahip olabilir: uyarıcı veya engelleyici. İnhibitör etki alıcı nöronun ateşlenmesini engellerken, uyarıcı etki onun ateşlenmesine neden olur. Her durumda, çeşitli bilgi kaynaklarını hücre gövdesine taşıyan elektrokimyasal kesişme noktalarının iletkenliği, bunların etkilerini sınırlar. Şekil 2.4 bir nöronun temel bileşenlerinin uyarlanmış bir türünü göstermektedir.




Şekil 2.4 Nöronun temel bileşenleri

ANN’lerde katkıların nöron üzerindeki etkisi, yük olarak adlandırılan matematiksel özellikler kullanılarak değiştirilir. Nöronlara iletilmeden önce, her bir bilgi parçası karşılaştırma ağırlığı aracılığıyla çoğaltılır. Daha sonra, bir nöron, böyle bir yatkınlık değeri olmasına rağmen, bu ağırlıklı özellikleri toplar ve toplamının sonuçlarını nöronun çıktısını belirlemek için etkinleştirme işi aracılığıyla geçirir. Ayrıca, yatkınlık değerleri, nöronun çıktı değerini değiştirmekte daha fazla esneklik sağlar, bu da algılaması gereken özelliklere bağlı olarak çıktı değerini değiştirme yeteneği sunar. Yatkınlık kullanılmadığı durumda, örneğin, girişler 0 olduğunda nöronun çıktısı 0 olur çünkü ağırlıklar bu girişlerle çarpılır. Sonuç olarak, yatkınlık değerinin varlığı, nöronların gerekli çıktıyı özelliklere bağlı olarak değerlendirmesine olanak tanır. Denklem 2.1 girdilerin özetini (S) ve nöron j’nin yatkınlığını göstermektedir.

$$s_j = \sum_i x_i w_{ij} + b_j \quad (2.1)$$

x_i , bu nöronun katkılarını temsil eder, w_i , bu ilişkili yüklerdir ve b_j , nöronların yatkınlığını temsil eder. Nöronun işlemek için girişleri nasıl ele aldığının görsel düzeni Şekil 2.5’te gösterilmiştir.



Şekil 2.5 Nöronun hesaplama işlemlerinin görsel temsili

Toplam sonuçları bir etkinleştirme çabasına dönüştürerek nöron, bağımsız yönde doğrusal olmayan sınırlar belirleme yeteneği kazanır. Bir nöronun hesaplaması işlemi çıkarıldığında, bir veri kümesindeki demetleri sınıflara ayırmak için kullanabileceği tek olası sınır, nöronun daha kesin tahminler yapma yeteneğini sınırlayan doğrusal bir sınırdır. Ayrıca, NN’de daha derin katmanlarda bulunan nöronlar, her bir sınıf için daha karmaşık sınırlar oluşturabilir, bu da NN’in tahminlerinin doğruluğunu artırabilir. Dahası, nöronlardan önceki nöron sınırlarını bağlayarak oluşturulan karmaşık sınırların her parçasının alanlarını değiştirerek, her nöron için eğim değerlerinin kullanımı bu karmaşık sınırların geliştirilmesine yardımcı olabilir. Hiperbolik Tanjant (TanH), Sigmoid ve Düzeltilmiş Doğrusal Birim (ReLU), Şekil 2.6’da gösterildiği gibi üç sık kullanılan başlatma fonksiyonudur. ReLU başlatma fonksiyonlarına sahip NN’lerin performans açısından diğer başlatma fonksiyonlarından çok daha üstün olduğu görülmüştür. Sonuç, hesaplamaların doğrusallığı olmamasından kaynaklanan gerekli öğeleri belirleyerek katkılar üzerinden hesaplanabilir. Ancak bir NN belirli bir sonuca ulaşmak için farklı yollar izleyebileceğinden sonuç, çeşitli özelliklerin bir karışımına ait tek bir elementin sonucu olabilir, bu tür ağlar, verileri temsil etmek için karmaşık sınırlar üretilirken kullanılan tek yönlü kapasiteler olarak kullanılırken, ancak karmaşık

sınırlar ilk bilgileri kurtarmak için kullanılamaz (Abdoun vd., 2018; Turčaník, 2017; Turčaník ve Javurek, 2016).


İsim	Grafik	Denklem	Türevi
Birim		$f(x) = x$	$f'(x) = 1$
İkili basamak		$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ 1 & \text{eğer } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{eğer } x \neq 0 \\ ? & \text{eğer } x = 0 \end{cases}$
Lejistik (Hafif basamak)		$f(x) = \frac{1}{1 + e^{-x}}$	$f'(x) = f(x)(1 - f(x))$
Tanh		$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$	$f'(x) = 1 - f(x)^2$
Arctan		$f(x) = \tan^{-1}(x)$	$f'(x) = \frac{1}{x^2 + 1}$
Düzeltilmiş Doğrusal Birim (ReLU)		$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ 1 & \text{eğer } x \geq 0 \end{cases}$
Parametrik Düzeltilmiş Doğrusal Birim (PReLU)		$f(x) = \begin{cases} \alpha x & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} \alpha & \text{eğer } x < 0 \\ 1 & \text{eğer } x \geq 0 \end{cases}$
Üstü Doğrusal Birim (ELU)		$f(x) = \begin{cases} \alpha(e^x - 1) & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} f(x) + \alpha & \text{eğer } x < 0 \\ 1 & \text{eğer } x \geq 0 \end{cases}$
Hafif Artış		$f(x) = \log_e(1 + e^x)$	$f'(x) = \frac{1}{1 + e^{-x}}$

Şekil 2.6 Nöronların aktivasyon fonksiyonu

2.3.2 İleri Beslemeli Sinir Ağları (FFNN)

FFNN'deki nöronlar katmanlara yayılır ve her katmandaki nöronların sonuçları, sonraki katmandaki nöronlara bağlanmıştır. Çıktı, bilgi ve gizli katmanlar ağdaki 3 katman türüdür. Bilgi katmanları, dış dünyadan gelen katkılarla ilişkilendirilen ana katmandır. Bu katmandaki nöronların sayısı, yapay sinir ağı (NN) tarafından yapılan sayısına karşılık gelir, çıktı katmanındaki nöronların sayısı ise sistemin gereksinim duyduğu sonuçların sayısına karşılık gelir. Dolayısıyla, bu katmanlardaki nöronların sayısı, bir NN'nin gerçekleştirilmesi için gereken işlem miktarıyla sınırlıdır. Ayrıca, her durumda yalnızca bilgi ve sonuç katmanlarının kullanılması, doğru tahminleri

sağlamak amacıyla NN'nin tanıyabileceği öğelerin miktarını ve karmaşıklığını sınırlaması nedeniyle gerekli görevi tamamlamak için yetersizdir. Şekil 2.7 tamamen ilişkilendirilmiş bir ileri beslemeli derin nöron mimarisinin bir örneğini göstermektedir.




Şekil 2.7 İleri beslemeli yapay sinir ağı örneği

NN'lerin sunumu üzerinde çalışırken, çoğu katman, bilgi ve sonuç katmanları arasına eklenir. Bu katmana gizli katman denir çünkü dış dünyaya görünmez, bilgi ve sonuç katmanları ise sistemin veri kaynakları ve sonuçları ile ilişkilidir. Gizli katmanlardaki nöron sayısı dış etkenlerle sınırlandırılmasa da gizli katmandaki nöron sayısını veya gizli katman sayısını artırmak, bilginin bir sınıfını tahmin etmek için gereken hesaplamaların karmaşıklığını artırır ve bu da tahmin için gereken süreyi uzatır. Katman sayısı artırılırken gizli katmandaki nöron sayısının artırılması, o katmanda tanımlanabilecek özelliklerin yani gizli katmandaki nöronları ateşleyen sayısının artmasına neden olur. Örneğin, ağın derinliği arttıkça, daha derin katmanlarda tanımlanabilecek öğelerin karmaşıklığı da artar. Sonuç olarak, birden fazla gizli katmana sahip ve derin NN'ler olarak adlandırılan ağlar, daha karmaşık özelliklerin tanımlanmasını sağlayabilir.

Aşırı uyum özelliği, beklentilerin NN'deki belirli öğelere bağlı olduğu durumlarda, bu tür tahminlerin bu öğelerle sınırlı kalmasına neden olur; bu da derin NN'lerle

araştırılan başlıca zorluklardan biridir. Sonuç olarak, o sınıfa uyacak ancak bu öğelerle ilişkilendirilen nöronları ateşlemeyen ek veri kaynaklarının yanlış bir şekilde sınıflandırılma olasılığı yüksektir. Bu sorunun üstesinden gelmek için, gizli katmandaki belirli bir oranda nöron, her hazırlık aşaması döngüsü sırasında ayrılmaz gözlemeksizin düşürülür, bu da NN'yi aynı tahmini yapmak için alternatif yollar bulmaya zorlar ve belirli öğelere olan bağımlılığı azaltır. Bu yaklaşıma "Atlama" denir ve Şekil 2.8'de görüldüğü gibi NN tahminlerinde önemli bir iyileşme sağlamıştır.



Şekil 2.8 Atlamalı sinir ağı modeli

Bir NN tarafından sağlanan tahminler, bilgi katmanından sonuç katmanına kadar olan her bir nöronun gerçekleştirdiği hesaplamaların sonucudur; bunlar, bilgi katmanlarının bilgi yönlerine rağmen çoğunlukla NN'nin eğilimleri ve yüklerine dayanır. Öğrenme aşaması, bu ağlar tarafından sağlanan tahminlerin doğruluğunu artırmak için NN'nin eğilimlerini ve yüklerini ayarlamayı içerir, çünkü bilgi değerleri bu ağların yönetimi gerisindedir. Denklem 2.2'de gösterilen Karesel Hataların Toplamı (SSE) yaklaşımını kullanarak bu güncelleme, maliyet olarak adlandırılan, gerekli ve beklenen kalite arasındaki farkın tahmin edilmesiyle tamamlanır.

$$C = \sum_i \frac{1}{2} (y_i - \hat{y}_i)^2 \quad (2.2)$$

Burada y beklenen değeri temsil eder ve $\hat{y}$, sonuç katmanındaki i çıktıları için gerçek zorunlu teşvikleri temsil eder (Kingma ve Ba, 2014).

Eğilimler ve yükler, geri yayılma ile NN boyunca dağılarak ve düşme hesaplaması ışığında eğim düşüşü hesaplamasına dayalı olarak güncellenir. Bu hesaplama, her bir ağırlık ve yatkınlık için bir önceki katmanda belirlenen hataya ilişkin kısmi birinci türevi ele alır. Her türevden hesaplanan özellikler daha sonra o eğilimin veya ağırlığın ilk değerinden çıkarılır. Güncellenen özellikler, türevin değerinin pozitif olduğu durumda hata oranını azaltır, çünkü bu sınırın etkisi hataya neden olur. Ayrıca, türevin değeri negatif olduğunda, bu değerin artırılması hata oranını artırır ve güncelleme koşulundaki kesintiyle birlikte yeni değeri artırarak hata oranını düşürür ve NN'nin beklentilerini daha da geliştirir (Glorot ve Bengio, 2010).


Önceki NN'lerde yapılan bu tür katkıları ele almak için, görüntüler gibi iki katmanlı bilgi kaynakları, tek katmanlı vektörlere dönüştürülmüştür. Bu değişiklik, iki katmanlı bilgide bir veri eksikliğine yol açar, burada yönlerden birindeki özellikler, o yönün boyutuna göre genişletilir. Örneğin, bir görüntüdeki piksellerin eşit şekilde düzleştirilmesi ve bir resmin sütunlarının birbirine yakın sıralanması durumunda, dikey yönde bitişik 2 piksel arasındaki mesafe resmin genişliğine eşit olduğundan dikey piksellerin oluşturduğu öğeler kaybolur. Bu sorunun üstesinden gelmek için, iki katmanlı veri kaynaklarında özellikleri bulmakta NN'ler kullanılır ve bu, verideki öğelerin yönüne bakılmaksızın yakınlık özelliklerinin bulunmasına olanak tanır (Krizhevsky vd., 2017).

İnsanların görsel düzeninde, NN'ler inferotemporal yolu tekrarlamak için kullanılır. Bu ağlar, özellikleri ayırt etmek için görüntü etrafında dolanmış iki katmanlı kanallar kullanır; her kanal, her katman için belirli bir bileşeni tanımlar. Kanallar 2 katmanlı olduğundan tanınan öğeler de iki katmanlıdır. Bu yaklaşım, girdinin durumunu etkilemeden özelliklerin 2 katmanlı ayrılmasına olanak tanır (Shin vd., 2016).

Katmandaki kanallar aslında 2 katmanlı kümeler halinde taşınan ve veri seti hazırlığı sırasında güncellenen yüklerdir, bu da bilgi kaynaklarına ve geleneksel PC görüşü yaklaşımlarından temel farkı köşeler ve kenarlar gibi açık öğe türlerini algılamak olan NN'nin gereksinim duyduğu göreve bağlı olarak farklı özellikleri tanıma

yeteneğine sahip kanallarla sonuçlanır. Bunlar, her bir yöne doğru hareketin ilerleme boyutunu gösteren adımlarla birlikte, resmin tamamı boyunca karmaşıktır. Yük sonuçlarının bilgi değerleriyle birleştirilmesiyle, karşılaştırılma katmanı için tanımlanan adımlarla belirlenen yeni kümenin boyutuyla başka bir seri oluşturulur (Szegedy vd., 2016).

NN’lerdeki bir diğer önemli katman türü, maksimum havuzlama ve normal havuzlama katmanlarına ayrılan havuzlama katmanlarıdır. Bununla birlikte, maksimum havuzlama katmanları, nitelikleri bir sonraki katmana aktarmadan önce bir kanalın sonuçlarının boyutunu azaltarak aşırı uyumdan kaçınma konusunda güçlü bir kararlılık göstermiştir. Maksimum havuzlama katmanları, katmanın bir sonucu olarak birbirine karışan iki katmanlı kanallara sahiptir. Bununla birlikte, kanallardan sonra, her bir maksimum havuzlama kanalında tanımlanan en sert özelliklere sahip başka bir küme oluşturmak için maksimum havuzlama katmanları kullanılır. Bu tür kanalların evrişim başına hareket ettiği ilerleme boyutunu düzenleyen adımlar, bu katmanlardaki kanalların boyutuna benzer şekilde belirlenmelidir. Şekil 2.9, (2x2) kanal boyutu ve (2x2) adımlarla maksimum havuzlama katmanının örneğini göstermektedir.



Şekil 2.9 Maksimum havuzlama çıktısına bir örnek

Bir kanal veya maksimum havuzlama katmanı olabilen son katmanın çıktısı, tek bir vektöre eşitlenir ve tamamen FFNN ile ilişkilendirilir. Katmanlardaki kanalların çeşitli kombinasyonlarına dayanarak, tamamen bağlantılı katmanlardaki nöronlar artık bilgidaki gelişmiş iki katmanlı yakınlık özelliklerini ayırt edebilir. Verilerin iki katmanlı seri katmanlarına bölündüğü NN'ye üç katmanlı bir işlemek de mümkündür. Bundan sonra NN, her katman için birçok kanal düzeni oluşturur ve daha derin seviyeler, birçok katmandan gelen özellikleri birleştirme yeteneği kazanır (Konda, 2016).

2.3.3 Yapay Sinir Ağlarının Öğretimi

Organik sinir ağlarının coğrafyasının ve nöro-vericilerin iletkenliklerinin zihin tarafından yapılan seçimleri karakterize ettiği insan beyni gibi, NN'ler de gereken seçeneğe karar vermek için nöronların dağılımına ve aralarındaki yüklere bağlıdır. Birbirinden ayırt edilemeyen iki NN, nöronları arasında farklı yük değerleri kullanılarak farklı kararların üretildiği tamamen farklı görevlerde kullanılabilir. Etkinin türü, önceki katmandaki nöronun bir sonraki katmandaki nöron üzerindeki çıktısı ve bu etkinin sonraki katmandaki nöronun çıktısı üzerindeki önemi, iki nöron arasındaki yükün değeri ile belirlenir (Jain ve Sethi, 2014).

Geri yayılım, NN'lerin yaygınlığında önemlidir çünkü bu süreç, ağı yük değerlerini güncelleme amacıyla kullanıldığında ağı performansının önemli ölçüde iyileştirilmesine olanak tanır. Bir NN'in w yüklerini güncellemek amacıyla geri yayılım, Denklem 2.3'te görülebileceği gibi 3 özelliğe ihtiyaç duyar; hatanın yenilenmesine ilişkin ağı sonucunun ilerleme hızı $\frac{\partial O}{\partial w}$, ağı sonucu ile ondan beklenen arasındaki hata E ve öğrenme oranı L (Hecht-Nielsen, 1992).

$$\hat{w} = w - \frac{\partial O}{\partial w} \times E \times L \quad (2.3)$$

Çapraz entropi ve Ortalama Karesel Hata (MSE) kapasiteleri gibi, bir NN tarafından kullanılan hata çalışmasının türüne rağmen, bu tür kapasiteler, NN'nin mevcut yükleme değerlerini kullanarak elde edilen sonucu ile ağdan elde edilen nitelikler arasındaki farkı ele alan bir değer hesaplar. NN'nin sonucu, hazırlık veri setindeki bir

kümenin test girdilerini işlemek için NN'nin ileri geçişi kullanılarak elde edilirken, gerçek sonuçlar doğrudan hazırlık veri setinden veya önceden tanımlanmış bir kapasite kullanılarak bilgi kaynaklarının işlenmesi yoluyla elde edilir. Geri yayılımı, belirlenen hata değeri kullanılır. Bununla birlikte, büyük hata değerleri büyük delta değerlerine yol açabileceğinden, yük güncellemelerinde daha düşük aralıklardaki delta değerlerini kontrol etmek amacıyla bir öğrenme oranı kullanılmıştır. Bu delta değerlerinin kontrolü, ateşleyici yük değerlerinden kaçınılmasını sağlayarak, temel hataya neden olan yük değerlerinin tespit edilmesini sağlar (Miikkulainen, 2019).

Sonuç hata hızının, ağırlık değerlerine bağlı olarak belirlenmesiyle 3 olası özellik üretilebilir:

1. Pozitif değer, ağırlık değerini artırmanın hata artışına yol açtığını gösterir. NN ile gereken sonuçlar arasındaki farkı azaltmak için, ağırlık değeri bu şekilde bir delta değeriyle azaltılmalıdır.
2. Negatif değer, hatanın ağırlık değerinin artmasıyla azaldığını gösterir. Hata değerini azaltmak ve daha doğru sonuçlar elde etmek için, mevcut ağırlık değeri seçilen delta değeri ile artırılmalıdır.
3. Sıfır değer, mevcut ağırlık değerinin değiştirilmesine gerek olmadığını gösterir.

Yapay sinir ağlarındaki yüklerin avantajları, bu potansiyel değerlere dayanarak ve NN'nin beklentileri ile gereken gerçek sonuç arasındaki farkı azaltmak için Denklem 2.3'te gösterilen formülü kullanarak güncellenebilir. Ancak, ağırlık değerlerinin güncellemesinde kullanılan delta değerini azaltmak için, hata miktarını sınırlayarak oluşturulan optimal NN performansı, optimal yük değerlerinin belirlenmesi için iterasyonlar gibi bir dizi döngü gerektirir (Schmidhuber, 2015).

2.3.4 Transfer Öğrenimi

NN hazırlığı, sinir ağının mevcut yetkinlikleri ve yükleri kullanılarak üretilen nitelikler ve bu bilgi için gereken sonuçlar arasında belirlenen kayıplara bağlıdır.

Ancak bu sınırlar dünya çapındaki en az kaybı elde etmek için hızlı bir şekilde güncellenemez. Ayrıca, çıkış katmanından bilgi katmanına doğru güncelleme başlarken, diğer bir deyişle geri yayılım, katmanların sınırlarına güncellemeler yapılır. Bilgi katmanına daha yakın olanlar anlamlı değildir. Bu nedenle derin sinir ağının hazırlanması, gerekli performansların elde edilmesi için büyük kaynaklar ve testlerin hazırlanmasını gerektirir (Kong vd., 2018; Torrey ve Shavlik, 2010).

Bilgi katmanına daha yakın olan katmanlar, ham özelliklerin tanımlanmasından sorumludur ve bu özellikler, NN'lerin kullanıldığı farklı uygulamalar arasında bölünebilir. Örneğin, bir Evrimsel NN'nin yüz özelliklerini veya farklı iz özelliklerini algılaması gerektiğinde, bilgi katmanına daha yakın katmanlardaki kanallar, dikey, yatay ve eğik çizgiler gibi öğeleri tanımlayabilir. Bu öğelerin sonraki katmanda birleştirilmesi, gerekli görevlerin yerine getirilmesiyle daha fazla ilgilenen karmaşık özelliklerin tanımlanmasına yol açar. Bununla birlikte, öğrenme sırasında sonuç katmanına daha yakın olan katmanlar daha hızlı güncellemeler alır. Bu nedenle, hazırlık süreci, son zamanlarda tanımlanmış ham özelliklerle başlanarak önemli ölçüde hızlandırılabilir (Ravishankar vd., 2016; Yin vd., 2019).

Transfer öğrenmede NN hazırlığı hiçbir hazırlık olmadan başlamaz; örneğin yükler ve eğitimler rastgele ayarlanmaz. Bunun yanı sıra, NN yapısı, katmanların sayısı, her bir katmandaki nöron sayısı ve katmanların birbirine nasıl bağlı olduğu şeklinde farklılık gösterebilir; bu farklılık, her bir karmaşıklık seviyesinde tanınacak öğe sayısı ve beklenen sonuçlara ulaşmak için tanınması gereken öğelerin karmaşıklığı açısından uygulamadan uygulamaya değişebilir. Daha sonra, bir önceden öğretilmiş sinir ağı, benzer bir uygulama için öğretilmiş olsa bile, başka bir uygulama için hazırlık amacıyla kullanılabilir.

Hazırlık, tıpkı kullanılmış yapıların uygulamalar için uygun olduğundan emin olmak gibi, sinir ağının zaten bildiği basit özellikleri kullanır. Böylece, transfer öğrenme, gerekli performansların sağlanmasıyla hazırlık süresinin önemli miktarda azaltılmasına olanak sağlamasıyla sonuçlanmıştır (Gopalakrishnan vd., 2017; Yu vd., 2017).

3. MATERYAL VE METOT

Bu tezde özellik seçimi için üç farklı yöntemi içeren üç senaryo kullanılmıştır. Bu yöntemler çekirge optimizasyon algoritması, parçacık sürüsü optimizasyonuna dayalı karınca kolonisi ve balıkçı peygamber devesi optimizasyon algoritmasıdır.

3.1 Çekirge Optimizasyon Algoritmasının Arkaplanı

Doğadan ilham alan akıllı algoritmalar, optimizasyon sorunlarını çözmenin en etkili yöntemleri arasındadır. Çekirge algoritması adı verilen popülasyon tabanlı akıllı sistem, çekirge sürülerinin sosyal etkileşimini ve davranışını taklit etmektedir. Saremi vd., bu algoritmayı 2017 yılında oluşturmuştur. Çekirgeler mahsullere zarar veren zararlılar arasındadır. Larva ve yetişkinlik dönemi, çekirgelerin geçtiği iki aşamadır. İlk aşamadaki bir larva, yoluna çıkan bitkilerle beslenirken yavaş yavaş özgürlüğe kavuşur. Çekirgeler sonunda havada sürüler oluşturarak geniş alanlara doğru hareket etmek için kanatlar geliştirirler. Sonuç olarak çekirgeler, çeşitli türlerde çok büyük sürüler oluşturdukları için ayrı ayrı gözlemlenirler. Çekirgenin amacı, şekil 3.1’de gösterildiği üzere, her biri farklı bir oranına sahip olan iki farklı yaklaşımla besin kaynakları bulmaktır: sömürü ve keşif.



Şekil 3.1 Gerçek çekirge ve çekirgenin yaşam döngüsü

Bu yönteme uygun sayıda çekirge ile başlanır. Çekirgelerin hareketini üç faktör etkiler: sosyal etkileşim, yer çekimi kuvveti ve rüzgârın salınımı. Bu faktörler matematiksel bir modelle açıklanabilir.

$$Xi = Si + Gi + Ai \quad (3.1)$$

Matematiksel denklemdeki Xi değişkeninin değeri i 'inci çekirgenin konumunu belirtirken, Si , Gi ve Ai değişkenleri sırasıyla çekirgeler arasındaki sosyal etkileşimleri, onlara etki eden yerçekimi kuvvetini ve rüzgârın salınımını temsil eder.

$Xi = r1Si + r2Gi + r3Ai$ de, $r1$, $r2$ ve $r3$ rastgele sayılar olacak şekilde, rastgele bir yaklaşım sağlamak için kullanılır.

3.1.1 Mesafe ve Hareket

Burada d_{ij} , i 'inci ve j 'inci çekirgeler arasındaki mesafeyi temsil eder ve $d_{ij} = |Xj - Xi|$ denklemi kullanılarak hesaplanabilir. S , $\widehat{d}_{ij} = \frac{x_j - x_i}{d_{ij}}$ denklemi kullanılarak en geniş sosyal etkileşimi tanımlamak için kullanılır. Aşağıda gösterildiği gibi “ i 'nci” ile “ j 'inci” çekirge arasındaki taşıyıcı birimi temsil eder:

$$Si = \sum_{\substack{i=1 \\ i \neq j}}^N S(d_{ij}) \widehat{d}_{ij} \quad (3.2)$$


3.1.2 Güncelleme Aşaması

Çekirgelerin çekimini belirleyen piksel aydınlatmasının aslında standart fonksiyona bağlı olduğu varsayıldığında, ışık emilim katsayısı aşağıdaki fonksiyonda gösterildiği gibi S olarak hesaplanabilir:

$$Sr = f e^{\frac{-r}{l}} - e^{-r} \quad (3.3)$$


Burada l , ışık emilim faktörünü, f ise ışık kaynağının yoğunluğunu göstermektedir.

Çekirgelerin sosyal etkileşimini etkileyebilecek iki faktör çekme ve itme faktörleridir. 0'dan 15'e kadar olan mesafeleri gösteren S fonksiyonu Şekil 3.2'de gösterilmiştir.



Şekil 3.2 $f = 0,5$ ve $l = 1,5$ iken, X sınırları 1-4 (solda) olduğundaki S fonksiyonu (sağda 0)


İtme işleminin aralığı 0-2,079'dur. Şekil 3.2'de görüldüğü gibi iki çekirge arasındaki mesafenin 2,079 olduğu konfor alanında herhangi bir itme veya çekme işlemi başlatılmamıştır. Çekme birim değeri önce 2,079'dan neredeyse 4'e çıkmış, ardından kademeli olarak azalmıştır. Şekil 3.3, itme parametrelerinin (l ve f) değiştirilmesinin yapay çekirgelerde nasıl çeşitli sosyal davranışlara yol açtığını göstermektedir.



Şekil 3.3 f veya l değerlerinin değişmesi durumunda S fonksiyonu

Bazı durumlarda, çekme ve itme alanlarındaki değerler minimum düzeyde olabilir (l veya $f = 1,0$). Tüm değerlerden $l = 1,5$ ve $f = 0,5$ 'in seçildiğine dikkat etmek önemlidir. S fonksiyonu, çekirgeler arasındaki mesafeleri farklı bölgelere veya aşamalara (örneğin itme bölgesi, yerçekimi alanı ve konfor alanı) bölebilir. Şekil 3.4'te konfor alanındaki çekirgeler arasındaki etkileşimler gösterilmektedir. Ayrıca, 10'dan büyük mesafelerde bu fonksiyonun değerleri 0 ile sınırlıdır, bu durum Şekil

3.2 ve Şekil 3.3'te gösterilmiştir. Sonuç olarak çekirgeler arasında büyük boşluklar olduğunda bu fonksiyon uygulanacak uygun kuvvetleri hesaplayamaz.



Şekil 3.4 Bir çekirge sürüsünde primitif düzeltme eğilimleri

Bu zorluğa çözüm bulmak amacıyla (1, 4) aralığındaki çekirgeler arasındaki mesafe haritalanmıştır. Bu periyoda ait fonksiyon S , Şekil 3.3'te (sağda) gösterilmektedir.

G değişkeninin hesaplanmasında kullanılan Denklem 3.4 aşağıdaki gibidir:

$$Gi = -g\widehat{e}_g \quad (3.4)$$

g , dünyanın merkezindeki yerçekimi sabitini ve $\widehat{e}_g$ birim vektörü temsil eder. Denklem 3.1 aracılığıyla A değişkeni şu şekilde hesaplanabilir:

$$Ai = u\widehat{e}_w \quad (3.5)$$

Burada u , rüzgâra doğru sürekli erozyonu temsil eder $\widehat{e}_w$ birim vektörüdür.

Larva çekirgelerin kanatları yoktur, bu nedenle rüzgârın yönünden etkilenirler. Değişkenler S , G ve A , Denklem 3.1'de birleştirilir, böylece denklem aşağıdaki gibi olur:

$$Xi = \sum_{j=1, j \neq i}^N S(|X_j - X_i|) \frac{X_j - X_i}{d_{ij}} - g\widehat{e}_g + u\widehat{e}_w \quad (3.6)$$

Bu noktada, $S(r) = f e^{\frac{-r}{l}} - e^{-r}$ fonksiyonu ve N , çekirge sayısını temsil eder. Çekirgeler yere düşebilir ve konumlarının eşik altına inmemesi gerekir. Bu nedenle sürüyü simüle eden ve iyileştiren algoritma bu denklemi kullanmaz, bu da araştırma alanının bir çözüm için keşif ve sömürsünü engeller. Denklem 3.6, sürüdeki çekirgeler arasındaki etkileşimi simüle eden, boş alanda sürüyü ödüllendiren kullanıcı modelidir.

$$X_i^d = c \left(\sum_{j=1, j \neq i}^N c \frac{ub_d - lb_d}{2} s(|X_j^d - X_i^d|) \frac{x_j - x_i}{d_{ij}} \right) + \widehat{T_d} \quad (3.7)$$

Burada ub_d , d'inci boyuttaki maksimumu, lb_d , d'inci boyuttaki minimumu temsil etmektedir. $S(r) = f e^{\frac{-r}{l}} - e^{-r} \widehat{T_d}$ fonksiyonu, T_d ise hedefteki boyut d'nin değerini temsil etmektedir, bu, en iyi çözüm olarak kabul edilmektedir ve faktör c , uyumsuzluk alanını, çekimi ve konfor bölgesini azaltmak için azalmaktadır. S değişkeni, Denklem 3.1'deki S değişkeniyle hemen hemen aynıdır. Bu prensibi kullanarak yerçekimi dikkate alınmaz ve daima hedefe (T_d) doğru olduğu varsayılır. Şekil 3.4 mevcut çekirgenin konumuna, hedefin diğer çekirgelere göre konumuna ve geri kalan çekirgelerin konumuna bağlı olarak bir sonraki çekirgenin konumunun belirlenmesini göstermektedir. Her GOA arama ajanının tek bir konum vektörü vardır. GOA, arama ajanının konumunu ve ayrıca diğer arama ajanlarının konumunu, en iyi mevcut arama ajanının yerine dayanarak günceller. Denklem 3.7'de c faktörü iki kez kullanılmıştır; ilk c (solda) atalet ağırlığını gösterir. Çekirgelerin hedefe doğru hareketlerini azaltır. İkinci aşamada çekirgeler arasındaki alanları (dinlenme, çekim ve itme) azaltır. Denklem 3.7, çekirgelerin keşif ve sömürüdeki mesafelerini doğrusal olarak azaltır, bu da Denklem 3.7'deki bileşen $c \frac{ub_d - lb_d}{2}$ tarafından gösterilir. Çekirgeler, $s(|x_j - x_i|)$ bileşeni kullanılarak keşif veya çekim (sömürü) konumundan hedef konuma sürülür.

İç kısım çekirgeler arasındaki itme ve çekme kuvvetlerini tekrar sayısı ile eşit oranda azaltır. Bunun aksine, tekrarların artmasıyla dış kısım, hedefe yönelik araştırmalarda kapsama oranını azaltır. Denklem 3.7'nin ilk aşaması, doğadaki çekirge reaksiyon durumunu uygulayan ve diğer çekirge durumunu ele alan toplamı temsil eder. İkinci aşama (T_d), besin kaynağına doğru hareket etme uygunluklarını temsil eder. c

parametresi, çekirgelerin besin kaynaklarına yaklaşp bunları tükettiğindeki yavaşlamasını temsil eder. Denklemden iki terimin varlığı daha rastgele bir yaklaşım sağlar. Denklem 3.7 birden fazla rastgele değerle sonuçlanabilir. Çekirgelerin etkileşiminde veya besin kaynağına doğru yönelme durumunda, her bir terimin rastgele değerlerle çarpılması ile rastgele davranış sağlanabilir. Arama ajanlarının keşif ve sömürü düzeylerini koordine etmesini gerektiren bir yaklaşım olmalıdır. Doğal olarak çekirgeler larva döneminde kanatları olmadığından yiyeceklerini yerel olarak küçük bir alanda ararlar. Erginlik döneminden sonra havada hareket ederek daha geniş alanları keşfederler. İlk başta, rastgele iyileştirme algoritmaları, araştırma alanındaki geniş alanları bulmak için keşif yaparlar. Geniş alanlar kullanıma sunulduktan sonra, sömürü, arama ajanlarını küresel yöntemin en doğru yaklaşımını bulmak için yerleştirilmiş bir format aramaya zorlar.


3.1.3 Küçülme Faktörü

Bu süreç keşif ve sömürü arasında denge kurar; bu nedenle yineleme sayısı ile ilişkili c parametresinin azaltılması gerekir. Bu yöntemde daha fazla sayıda tekrar, daha iyi sömürüye yol açar. Aşağıdaki denklem, c faktörünün yineleme sayısı ile ilişkili konfor bölgesinden azaldığını göstermektedir:

$$c = c_{\max} - l \frac{c_{\max} - c_{\min}}{L} \quad (3.8)$$

Burada l mevcut frekansı, $c_{\max}$ ve $c_{\min}$ sırasıyla en yüksek ve en düşük değerleri ve L , maksimum kümülatif tekrar sayısını temsil etmektedir.

Şekil 3.5 önerilen yöntemin akış şemasını göstermektedir.



Şekil 3.5 Kolon kanseri hastalığı tanısı için önerilen yöntemin akış şeması

3.2 Karınca Kolonisi Optimizasyon Algoritması

Karıncaların, en uygun yiyecek kaynaklarını bulmalarına ve kat ettikleri mesafeyi en aza indirmelerine olanak tanıyan akıllı yiyecek arama davranışı sergiledikleri gözlemlenmiştir. Bu davranıştan ilham alan bu çalışma, en iyi sonuçları elde etmek için değiştirilmiş bir ACO-PSO algoritması sunmaktadır (Birattari vd., 2006; Kanan vd., 2007).

İlk olarak veri kümesindeki tüm özellikleri temsil edecek bir grafik model tanıtılmıştır. Grafiksel model, her düğümün bir özelliği temsil ettiği, birbirine bağlı düğümlerden oluşan bir ağıdır. Daha sonra karıncaların miktarı ve yineleme sayısı belirlenmiştir (Kanan vd., 2007). τ parametresi feromon izini temsil eder ve başlangıç değeri tüm özellikler için 1'e ayarlanır. η parametresi sezgisel bilgiyi temsil eder ve

öznitelikler arasındaki mesafeyle ters orantılıdır (Tabakhi vd., 2014; Yu ve Liu, 2004). Başlangıç değerleri belirlendikten sonra KKO algoritması uygulanabilir. Her adımda bir karıncaya rastgele bir düğüm atanır. Sonraki düğümü tanımlamak için Denklem 3.9 ile verilen geçiş olasılığı uygulanır:

$$P_i^k(t) = \frac{|\tau_i(t)|^{\alpha} \cdot |\eta_i(t)|^{\beta}}{\sum_{u \in j^k} |\tau_i(t)|^{\alpha} \cdot |\eta_i(t)|^{\beta}} \text{ eğer } (q > q_0) \quad (3.9)$$


$$j = \max_{u \in j^k} (\tau_i(i)^{\alpha} \cdot \eta_i(i)^{\beta}) \text{ eğer } (q < q_0) \quad (3.10)$$

τ ve η değerleri, α ve β değerleri belirlenerek etkinliklerini artıracak şekilde ayarlanır. j^k kümesi, karıncanın henüz karşılaşmadığı özellikleri temsil eder ve karınca tarafından daha önce gözlemlenen özelliklere sıfır değeri atanır. q_0 parametresi hem karşılaşmış hem de olasılıksal yöntemleri etkileyerek seçim sürecini önemli ölçüde etkiler. q , 0 ile 1 arasında rastgele bir sayıdır.

N'inci karınca düğüm taramasını tamamladığında, düğüm feromon seviyeleri Denklem 3.11 kullanılarak güncellenir:

$$\tau_i(t+1) = (1 - \rho)\tau_i(t) + \sum_{i=1}^n \Delta\tau_i^k(t) \quad (3.11)$$

Etkinin azaltılması için ρ parametresinin oluşturulması gerekir. $\Delta\tau_i^k$, Wrapper yöntemi kullanılarak elde edilen hatanın tersini temsil eder ve Filter yönteminde ortalama olarak seçilen düğüm sayısına karşılık gelir (Akhlaghian vd., 2014). Şekil 3.6'da karınca kolonisi optimizasyon algoritmasının çalıştığı akış şeması gösterilmektedir.



Şekil 3.6 ACO algoritmasının şematik gösterimi

3.3 Parçacık Sürü Optimizasyon Algoritması ile Özellik Seçimi

Bilim adamları uzun zaman kuşların göç sırasında yön bulmak için ay, güneş ve yıldızlar gibi gök cisimlerini kullandıklarına inanmışlardır. Ancak son araştırmalar kuşların başlangıçta rastgele yönlerde uçtuğunu göstermiştir. Daha sonra birbirleriyle etkileşimler yoluyla ortak bir yol üzerinde anlaşırlar. Bu, kuş göçünün büyük kuş gruplarının hareketini içeren kolektif bir çaba olduğunu göstermektedir (Beni, 2020; Tam Cho, 2017; Fernandez-Viagas vd., 2017; Nguyen vd., 2020).

Parçacık sürüsü optimizasyonunun (PSO) amacı, sürünün tamamı ve her parçacık için en iyi çözümü bulmaktır. PSO bunu, optimizasyon süreci boyunca parçacıkların konumlarını ve hızlarını değiştirerek başarır. Aşağıda verilen hız denklemine

dayanan denklemler, stokastik varyasyonu tanımlamak için 0 ile 1 arasında değişen tekdüze rastgele değişkenlerin eklenmesiyle parçacık konumlarını ve hızlarını yinelemeli olarak güncellemek için kullanılır.

Bu bağlamda atalet faktörü $v_{i,k}$ ile temsil edilir ve α bireysel öğrenme parametresini, β ise sürü etkisi öğrenme parametresini ifade eder. Aynı zamanda $r1$ ve $r2$, 0'dan 1'e kadar değişen rastgele değişkenlerdir. Ayrıca $v_{i,k}$, k yinelemesi sırasında i parçacığının hızına karşılık gelir. i parçacığının hiçbir zaman PB 'den daha elverişli bir durumu ulaşmadığını ve popülasyonun hiçbir üyesinin GB 'den daha üstün bir duruma ulaşmadığını belirtmekte fayda vardır. Bu nedenle algoritma şu şekilde formüle edilebilir:


$$v_{t+1} = v_t + \varphi_1 \beta_1 (p_i - x_i) + \varphi_1 \beta_1 (p_g - x_i) \quad (3.12)$$

$$v_{i,k+1} = w * v_{i,k} + \alpha * r_1 * (PB - x_{i,k}) + \beta * r_2 * (GB - x_{i,k}) \quad (3.13)$$

$$x_{t+1} = v_t + v_{t+1} \quad (3.14)$$


$$x_{i,k+1} = x_{i,k} + v_{i,k} \quad (3.15)$$

Şekil 3.7'de diyagram, p_i 'nin en iyi yerel sonucu ve p_g 'nin optimal küresel sonucu temsil ettiği parçacık konumlarının ve hızlarının güncellenmesini göstermektedir. Amponsah vd., (2021) ve Hassan vd., (2005) tarafından yürütülen kapsamlı araştırmalarda, parçacık sürülerinin, genetik algoritmalarla karşılaştırıldığında benzer çözümlere doğru belirgin şekilde daha hızlı ve daha etkili bir yakınsama sergilediği gösterilmektedir.



Şekil 3.7 PSO'da hız ve konum güncellemelerini gösteren diyagram

Arama alanının alt ve üst sınırları daralma parametresini belirlemiştir. Önerilen PSO tabanlı yöntemde maksimum yineleme sayısı bir değişken olarak ayarlanmıştır. Şekil 3.8, algoritmanın nasıl çalıştığına dair genel bir bakış sağlayan akış şemasını göstermektedir.



Şekil 3.8 PSO algoritmasının şematik gösterimi

PSO algoritmasının denklemi aşağıdaki gibidir (Too vd., 2019):

$$v_i^d(t+1) = wv_i^d(t) + c_1r_1(pbest_i^d(t) - x_i^d(t)) + c_2r_2(gbest^d(t) - x_i^d(t)) \quad (3.16)$$

Her yineleme boyunca, her parçacık güncelleme olarak iki ‘en iyi’ değer alır. Bu bağlamda v ; w_{max} ve w_{min} tarafından belirlenen limitlerle sınırlandırılan hızı temsil

eder, ayrıca w atalet ağırlığını, x ise çözümü temsil eder. t yineleme sayısına karşılık gelir, I popülasyon içindeki düzenin uygulanabilirliğini belirtir ve arama alanı d ile gösterilir. c_1 ve c_2 ivme faktörlerini temsil ederken, r_1 ve r_2 bağımsız olarak rastgele değerler üretir. PSO bağlamında küresel çözüm, tüm popülasyondaki herhangi bir parçacığın şimdiye kadar elde ettiği en iyi sonucun bir kayıdır; p_{best} ise bireysel bir parçacığın kendi en iyi sonucunu yansıtan kişisel en iyi çözümünü temsil eder.

Bu adımın ardından sonraki formülde de belirtildiği gibi, hız bir olasılık değerine dönüştürülür:

$$s(v_i^d(t+1)) = \frac{1}{1+\exp(-v_i^d(t+1))} \quad (3.17)$$

Gerçekçi pozisyon ve p_{best} , bu denklemler kullanılarak g_{best} ile ilişkilendirilir:

$$x_i^d(t+1) = \begin{cases} 1, & \text{eğer } rand < S(v_i^d(t+1)) \\ 0, & \text{yoksa} \end{cases} \quad (3.18)$$

Burada $rand$, 0 ile 1 arasında rastgele bir sayıdır.

$$p_{best}_i(t+1) = \begin{cases} x_i(t+1), & \text{eğer } F(x_i(t+1)) < F(p_{best}_i(t)) \\ p_{best}_i(t), & \text{yoksa} \end{cases} \quad (3.19)$$

$$g_{best}(t+1) = \begin{cases} p_{best}_i(t+1), & \text{eğer } F(p_{best}_i(t+1)) < F(g_{best}(t)) \\ g_{best}(t), & \text{yoksa} \end{cases} \quad (3.20)$$

Burada F uygunluk fonksiyonudur.

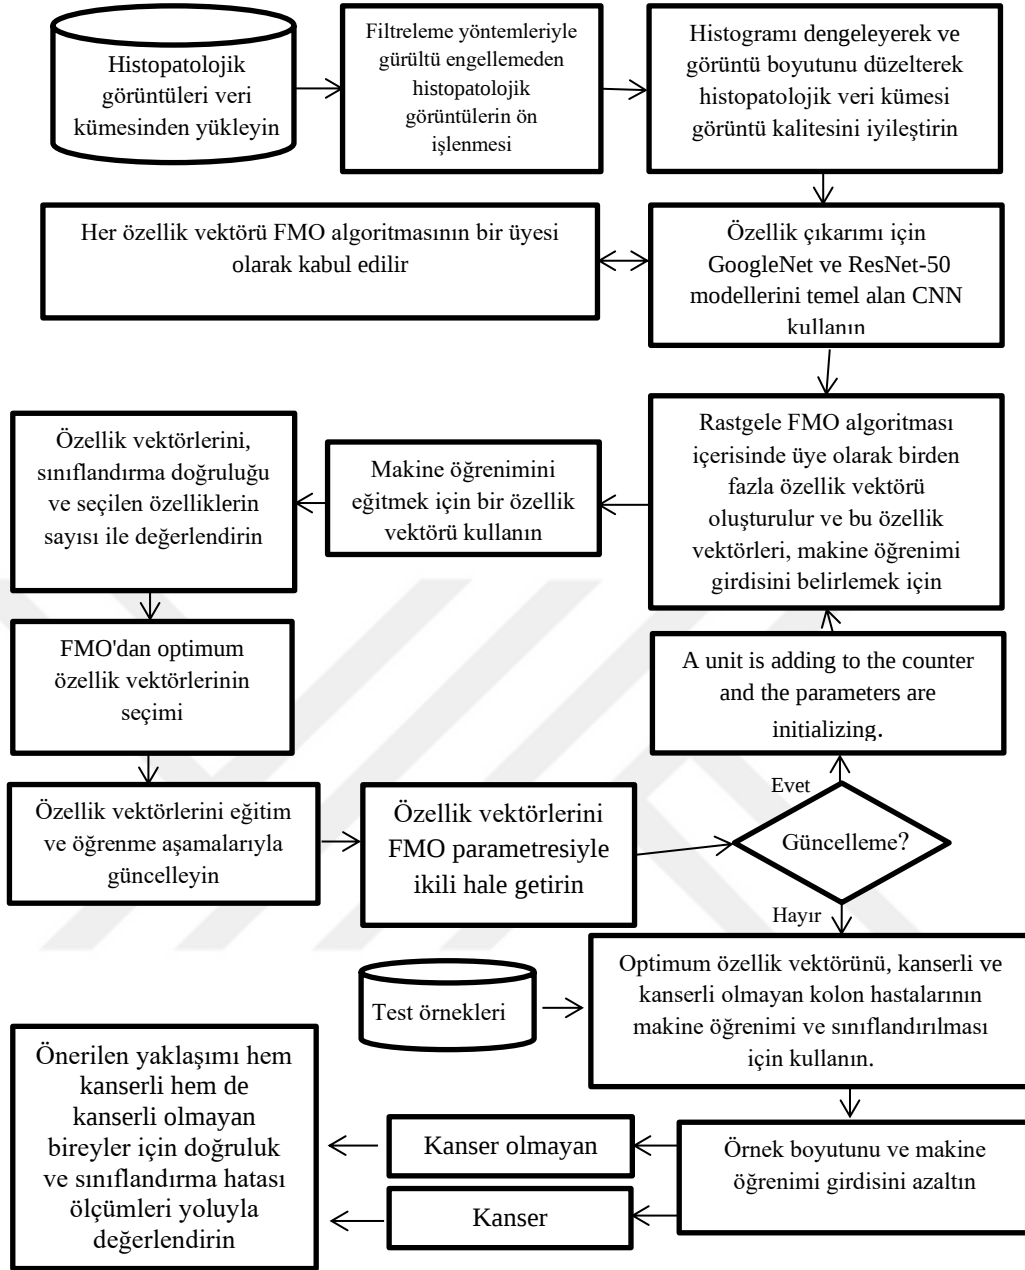
$$w = w_{max} - (w_{max} - w_{min}) \left(\frac{t}{T_{max}} \right) \quad (3.21)$$

Önerilen bir diğer yöntemin kavramsal temeli hem kanserli hem de kanserli olmayan hastaların tanısı için tasarlanmış olup Şekil 3.9'da gösterilmektedir. Bu tezde kullanılan yöntem birkaç adımdan oluşmaktadır. Başlangıçta kolon hastalıkları veri kümesinden örnek görüntüler toplanmış ve ardından ön işleme tabi tutulmuştur. Ön işlem için öncelikle görüntülerin gürültüsü giderilmiş ve ayarlanmıştır. Histogram

dengelemeyi de içeren görüntü kalitesi iyileştirme yöntemleri kullanılmıştır. Bu araştırmada, her kanal için 0 ila 255 ışık yoğunluğu aralığına sahip renkli görüntülerden yararlanılmıştır. Sunulan sisteme dayanarak önerilen yöntem birkaç temel adımdan oluşmaktadır.

İlk aşama, kolon hastalığının tanısında kullanılan uygun veri kümesinin toplanıp ön işleme tabi tutulmasını içermektedir. Bölgedeki benzer görüntüleri toplamak için Kvasir kullanılmıştır. Önerilen yöntemde, histopatolojik görüntülerden özelliklerin çıkarılması için GoogleNet ve ResNet-50 tabanlı evrişimli sinir ağı kullanılmaktadır. Görüntülerin dokusal özellikleri CNN yöntemleriyle çıkarılmıştır. Sonraki aşamada, histopatolojik görüntülerin makine öğrenimi için temel özellikleri hesaplanır; özellik seçimi, sıfırlar ve birlerle temsil edilen ikili bir zorluktur. N boyutlu bir özellik vektörü, her bir elemanın sıfır veya bir olduğu n kadar özelliğin varlığını belirtir. Önerilen yaklaşımda sıfır değeri hiçbir özellik seçiminin yapılmadığını, bir değeri ise özellik seçimini ifade etmektedir. Önerdiğimiz yöntemde özellik vektörü, Balıkçı Peygamber Devesi Optimizasyon (FMO) algoritmasının bir üyesi olarak ele alınmaktadır. Aşağıdaki nedenlerden dolayı özellik seçimi için FMO algoritması kullanılmıştır:

- Bu zamana kadar tanıtılan evrişimli öğrenme algoritmaları arasında öne çıkmakta ve evrişimli öğrenme davranışını simüle etmektedir.
- 2023 yılında tanıtılan FMO algoritması hem küresel hem de yerel aramaları aynı anda en iyi şekilde gerçekleştirme becerisi olarak belirtilen doğruluk açısından Parçacık Sürü Optimizasyon Algoritması ve Genetik Algoritma gibi meta-sezgisel optimizasyon yöntemlerini geride bırakmaktadır.
- Birçok meta-sezgisel tekniğin aksine, bu yöntem yalnızca en iyi çözümü aramamakta, aynı zamanda en iyi çözümü ortaya çıkarma olasılığı olan bölgeleri de araştırmaktadır.



Şekil 3.9 Kolon kanseri hastalığı olan hastaların tanısı için önerilen metodolojinin yapısı

Sonraki aşamada, kanserli ve kanserli olmayan histopatolojik görüntülerin sınıflandırılmasında optimal özellik vektörü kullanılarak makine öğrenmesi algoritması eğitilmiştir. Üçüncü adımda önerilen yöntem, optimal bir özellik vektörünün oluşturulmasını ve boyut azaltımı ve sınıflandırma için makine öğreniminin kullanılmasını içermektedir. Son aşamada, önerilen yöntem test verileri kullanılarak değerlendirilmiştir. Kanserli ve kanserli olmayan kolon görüntülerini ayırt etmek için önerilen yöntemin aşamaları şu şekildedir:

- Kolon hastalıklarına ilişkin histopatolojik örneklerin toplanması,
- Görsellerin ön işlemlerinin yapılması, ardından tüm özelliklerin numaralandırılarak makine öğrenmesine uyumlu hale getirilmesi,
- Makine öğrenimi yöntemleri arasında SVM, karar ağacı, K-NN ve topluluk yöntemlerinin oluşturulması ve sınıflandırma yöntemi olarak kullanılması,
- Her özellik vektörünün, balıkçı peygamber devesi optimizasyon (FMO) algoritmasının bir üyesi olarak kabul edilmesi,
- İlk rastgele yinelemede FMO algoritmasının bir popülasyonu olarak birçok özellik vektörünün oluşturulması,
- Her aşamada FMO algoritmasının kullanılarak özellik vektörlerinin güncellenmesi,
- Son yineleme sırasında, optimal özellik vektörünün, evrimsel sinir ağı için nihai girdi olarak kabul edilmesi. Bu girdiyi kullanarak sinir ağının örnekleri, kolon kanseri olan bireyler veya sağlıklı olanlar olarak sınıflandırması,
- Önerilen yöntemin, kanserli ve kanserli olmayan kolon hastalarında doğruluk ve sınıflandırma hatası göstergeleri gibi farklı metrikler kullanılarak değerlendirilmesi ve diğerleriyle karşılaştırılması.

Veri Ön İşleme:

Tekdüzeliliği sağlamak ve modelin genelleme yeteneğini geliştirmek için yeniden boyutlandırma, normalleştirme ve büyütme içeren tıbbi görüntüler üzerinde ön işleme gerçekleştirilmesidir.

Veri Kümesi Bölme:

Veri kümesinin öğrenme, doğrulama ve test kümelerine bölünmesidir. Bu, modelin öğrenme sürecine, hiperparametrelerin ince ayarına ve yeni veriler üzerindeki performansının değerlendirilmesine yardımcı olmaktadır.

Model Mimarisi Tasarımı:

Kolon kanseri tanısı için Evrişimli Sinir Ağı (CNN) mimarisinin tasarlanmasıdır. Katman sayısı, filtre boyutları ve etkinleştirme işlevleri tanımlanır. Mümkünse transfer öğrenimi için önceden eğitilmiş CNN modelleri kullanılmalıdır.

Balıkçı Peygamber Devesi Optimizasyon Entegrasyonu:

Balıkçı peygamber devesi optimizasyonunun CNN'in eğitim sürecine dahil edilmesidir. Öğrenme oranı, popülasyon büyüklüğü ve yakınsama kriterleri dahil optimizasyon parametreleri tanımlanır.

Model Öğretimi:

Öğrenme veri kümesini kullanarak CNN-FMO modelinin öğretilmesidir. Yakınsamayı sağlamak için öğretim sırasında kayıp fonksiyonu ve doğruluğu izlenmelidir. Modelde aşırı uyumun önlenmesi için erken durdurma kullanılmalıdır.

Hiperparametre Ayarı:

Doğrulama kümesini kullanarak öğrenme hızı ve optimizasyon algoritması parametreleri gibi hiper parametrelere ince ayar yapılmasıdır. Bu adım, önerilen modelin performansını optimize etmeye yardımcı olur.

Model Değerlendirmesi:

Duyarlılığı, özgüllüğü, doğruluğu ve diğer ilgili ölçümleri ölçerek modelin test veri kümesindeki performansının değerlendirilmesidir. Kapsamlı bir analiz için karışıklık matrisleri ve ROC eğrileri kullanılmalıdır.

Temel Modellerle Karşılaştırma:

CNN-FMO modelinin üstünlüğünün gösterilmesi için önerilen yaklaşımın temel modeller veya geleneksel teşhis yöntemleriyle karşılaştırılmasıdır.

Sağlamlık Testi:

Modelin sağlamlığının ve performansının harici veri kümeleri üzerinde test edilerek veya giriş görüntülerinde farklılıklar ekleyerek değerlendirilmesidir. Bu aşama, modelin farklı senaryolara genellenmesini sağlar.

Yorumlanabilirlik ve Görselleştirme:

Modelin karar verme sürecini yorumlamak için görselleştirme tekniklerinin (örneğin etkinleştirme haritaları) kullanılmasıdır. Bu adım, model tarafından yapılan tahminlere katkıda bulunan özelliklerin anlaşılmasında yardımcı olur.

Değerlendirme ve Doğrulama:

Metodolojiyi ve sonuçları doğrulamak için alanın uzmanlarından ve meslektaşlardan geri bildirim istenmesidir. Önerilen yaklaşımın sağlamlığını ve güvenilirliğini artırmak için yapıcı geri bildirim dahil edilmelidir.

Bu metodoloji takip edilerek, kolon kanseri teşhisi için CNN-FMO modeli sistematik olarak geliştirebilir, eğitebilir ve değerlendirilebilir; böylece gerçek dünyadaki sağlık hizmetleri ortamında etkinliği ve güvenilirliği garanti edilebilir.

3.4 Balıkçı Peygamber Devesi Optimizasyon Algoritması

Peygamber devesi yırtıcı bir böcek olarak kabul edilir. Şekil 3.10 (a)'da gösterilen güveler, uzun bacaklar, büyük kafalar ve iki çift kanatla karakterize edilen yeşil, çekirge benzeri böceklerdir (Rahebi, 2023). Peygamber develeri tropikal ve bazı ılıman bölgelerde yaşar. Dinlenirken, dua pozisyonundaki katlanmış elleri andıracak şekilde ön bacaklarını ileri doğru tutarlar. Çiftleşmeden sonra dişiler erkekleri avlar ve tüketir. Bazı peygamber develeri çevrelerini taramak için başlarını 180 dereceye kadar döndürebilirler. Genellikle ağaç yapraklarında yaşarlar ve avlarını kandırmak için dal gibi kamufle olurlar. Peygamber develeri yetenekli eklem bacaklı avcılardır ve yakınlardaki canlı avlarla beslenmek için genellikle pusu taktikleri kullanırlar. Avın yaklaşmasını sabırla, hareketsiz kalarak beklerler. Peygamber develeri kasıtlı, yavaş hareketlerle avlarını takip edebilir ve daha küçük bireyleri veya kertenkele, kurbağa, balık ve kuş gibi küçük omurgalıları tüketebilir. Balık yiyen peygamber develeri gibi bazı peygamber develeri, balık yakalamak için beş güne kadar göllerde saklanabilirler. Günde iki abanoz balığını başarıyla avlayabilirler ve beş gün içinde dokuzaya kadar balık yakalayabilirler. Balık yiyen peygamber devesinin avlanırken kamuflej kullandığını gösteren bir örnek Şekil 3.10 (b)'de gösterilmiştir.



Şekil 3.10 (a) Doğal ortamındaki bir peygamber devesinin görüntüsü ve (b) Balık yiyen bir peygamber devesinin avlanma durumundaki görüntüsü

Balıkçı peygamber devesi, çeşitli senaryoları göz önünde bulundurarak ve konumunu buna göre ayarlayarak akıllı avlanma davranışları sergiler. Av veya balık için en uygun yeri arar. Buna ek olarak, balıkçı peygamber devesi, saldırmak veya mevcut

avlanma durumunu terk etmek için hazırlıklar da dahil olmak üzere tek tip davranışları benimser.

3.4.1 Başlangıç Durum Popülasyonunun Oluşturulması

FMO algoritmasında, yetenekli bir peygamber devesi problem alanındaki rastgele senaryoları araştırır ve her birini potansiyel bir çözüm olarak ele alarak en iyi çözüme yaklaştırmaya çalışır. Başlangıç noktaları veya çözümler Denklem 3.22’de tanımlanmıştır ve Denklem 3.23’teki amaç fonksiyonu kullanılarak her senaryo değerlendirilmiştir.

$$\text{Peygamber devesi} = \begin{bmatrix} X_{11}, X_{12}, X_{13}, \dots, X_{1d} \\ X_{21}, X_{22}, X_{23}, \dots, X_{2d} \\ X_{31}, X_{32}, X_{33}, \dots, X_{3d} \\ \vdots \\ X_{n1}, X_{n2}, X_{n3}, \dots, X_{nd} \end{bmatrix} \quad (3.22)$$

Burada X_{ij} , i’nci yineleme ve j’inci senaryonun değerini temsil etmektedir. İlk yineleme sırasında, Denklem 3.23’te tanımlandığı gibi çözümlerden rastgele bir popülasyon oluşturulmuştur (Patibandla ve Narayana, 2021).

$$F(\text{Peygamber devesi}) = \begin{bmatrix} Uygunluk(X_{11}, X_{12}, X_{13}, \dots, X_{1d}) \\ Uygunluk(X_{21}, X_{22}, X_{23}, \dots, X_{2d}) \\ Uygunluk(X_{31}, X_{32}, X_{33}, \dots, X_{3d}) \\ \vdots \\ Uygunluk(X_{n1}, X_{n2}, X_{n3}, \dots, X_{nd}) \end{bmatrix} \quad (3.23)$$

Bu denklemde Peygamber devesi ve F (Peygamber devesi), çözüm veya senaryo matrislerini ve bunlara karşılık gelen yeterlilik seviyelerini temsil etmektedir. Denklem içerisinde X_i , son i’ye karşılık gelir ve bu çözüm, $X_{i1}, X_{i2}, X_{i3}, \dots, X_{id}$ olarak gösterilen d boyutlarını kapsar. Denklem 3.24 rastgele çözümler üretmek için kullanılır.

$$X_i = L + (U - L) \times rand(0,1) \quad (3.24)$$

Burada $rand(0,1)$, tekdüze bir dağılım izleyen, sıfır ile bir arasında değişen rastgele bir vektörü temsil eder. L ve U değişkenleri sırasıyla problem uzayının alt ve üst sınırlarını belirtir.

3.4.2 Durum Hatırlatıcıları

FMO algoritmasında peygamber develeri avlanmak için yeni bir konum seçer, o konuma yerleşir ve kendilerini kamufle ederler. Peygamber devesi birçok farklı durumu ezberleyebilir ve bir matristeki bu optimal durumlar m olarak tanımlanır. Durum $m < n$ 'dir ve Denklem 3.25'teki gibi tanımlanır:

$$Durum = \begin{bmatrix} S_{11}, S_{12}, S_{13}, \dots, S_{1d} \\ S_{21}, S_{22}, S_{23}, \dots, S_{2d} \\ S_{31}, S_{32}, S_{33}, \dots, S_{3d} \\ \vdots \\ S_{m1}, S_{m2}, S_{m3}, \dots, S_{md} \end{bmatrix} \quad (3.25)$$

Durum matrisi vaziyetleri içerir. Optimumluk değerinin maksimum çözümle orantılı olduğu varsayılmaktadır. Peygamber devesinin bu sınırlı koşulları hafızasında tuttuğu ve ağırlıklı olarak bu bölgelerde avlandığı varsayılmaktadır.

3.4.3 Optimum Konumlara Doğru Hareket

Durum matrisi her güncellendiğinde, peygamber devesinin matriste konumlandırılması için daha iyi koşullar bulunur. Bir peygamber devesi rastgele bir optimal durumu seçip Denklem 3.26'da olduğu gibi ona doğru hareket edebilir ve içinde bir pozisyon alabilir:

$$X_i^{yeni} = X_i + Hareket. (Durum(j) - X_i) \times rand(0,1) \quad (3.26)$$

X_i bir peygamber devesinin mevcut konumunu, X_i^{yeni} peygamber devesinin yeni konumunu, $Durum(j)$ rastgele bir durumu belirtir ve j , Denklem 3.27'de hesaplanan rastgele bir üyedir:

$$j = 1 + [rand \times (m - 1)] \quad (3.27)$$

Hareket, peygamber devesinin istenilen çözüme doğru attığı adımların büyüklüğünü ifade eder. Hareket parametresinin değeri, peygamber devesinin adım boyutunu küçülttüğü varsayıldığı için, FMO algoritmasının yinelenmesiyle azaltılır. Bunun aksine, peygamber devesi avı veya en uygun çözümü yaklaştıkça adım boyutunu azaltır. Denklem 3.28’de hareket parametresinin değişimi gösterilmektedir:

$$Hareket = \left[1 - \frac{it}{MaxIt} \right] \quad (3.28)$$

Bu bakımdan it mevcut yineleme sayısını temsil etmektedir. $MaxIt$ değeri, algoritmanın son yineleme sayısıdır. Daha rastgele bir davranış uygulamak için Chebyshev rastgele fonksiyonu kullanılır ve istenilen fonksiyonun kriteri Denklem 3.29’a göre belirlenir. Adım ilişkisi Denklem 3.30’da formüle edilmiştir:

$$u_{i+1} = \cos(\cos^{-1}(u_i)), u_1 = 0.7 \quad (3.29)$$

$$Hareket = \cos(\cos^{-1}(u_i)), u_1 = 0.7 \quad (3.30)$$

3.4.4 Optimum Konumlara Doğru Hareketi Geçersiz Kılma

Herhangi bir çözüm veya peygamber devesi, önceki optimal durumları göz ardı edebilir ve rastgele bir konum arayabilir. Rastgele konum seçimi, algoritmanın küresel aramasını iyileştirir ve yerel optimizasyona takılma riskini azaltır. Bu davranışı modellemek için Denklem 3.31 kullanılabilir:

$$X_i^{yeni} = \begin{cases} L + (U - L) \times rand(0,1) & r < 0.5 \\ \frac{L+U}{2} + (X^* - \frac{L+U}{2}) \times rand(0,1) & 0.5 \leq r \end{cases} \quad (3.31)$$

r değişkeni sıfır ile bir arasında rastgele bir değer alır.

3.4.5 Tüm Optimal Durumları Kullanma

Her çözüm veya mantis önceki optimal koşulları göz önünde bulundurabilir ve hepsinin bilgisini kullanabilir. Ayrıca Denklem 3.32’de olduğu gibi ortalama ile şu ana kadar elde ettiği optimal durum arasındaki boşluğu da arar:

$$X_i^{yeni} = \begin{cases} Hareket.X_i + (\overline{Durum} - X^*) \times rand(0,1) & rand < 0.5 \\ Hareket.X_i + (X^* - \overline{Durum}) \times rand(0,1) & rand \geq 0.5 \end{cases} \quad (3.32)$$

Burada $\overline{Durum}$ optimal sonuçların ortalama sayısını sembolize eder ve Denklem 3.33'te gösterildiği gibi hesaplanır.


$$\overline{Durum} = \frac{\sum_{i=1}^m Durum_i}{m} \quad (3.33)$$

Önerilen yöntemde yineleme sayacı artırılarak ve peygamber devesi ava yaklaştırılarak, Denklem 3.34'te olduğu gibi algoritmanın yinelemesine bağlı olarak durum sayısı azaltılmaktadır. m 'nin değeri başlangıç durumlarının sayısıdır ve $m(t)$, t yinelemesindeki durumların sayısıdır:

$$m(t) = m - \frac{m.it}{MaxIt} \quad (3.34)$$

Özellik vektörü X_i^{yeni} , kolon görüntülerinin kanserli ve kanserli olmayan kategorilere sınıflandırılması için makine öğreniminde kullanılacaktır.

Kolon görüntülerini kanserli ve kanserli olmayan kategorilere ayırmaya yönelik bu yaklaşımın görsel bir temsili Şekil 3.11'de sunulmaktadır.



Şekil 3.11 Kolon kanseri hastalığının teşhisi için önerilen metodolojinin özeti

3.5 Veri Kümesi

Veri kümesi özellikle akciğer ve kolon kanseriyle ilgili histopatolojik görüntülerin bir koleksiyonunu içermektedir (Borkowski vd., 2019). Veri kümesindeki görüntülerin, akciğer ve kolon kanseri hastalarından elde edilen doku örneklerinin mikroskobik görüntüleri olması beklenir. Bu görüntüler kanserli farklılıkların hücresel ve doku düzeyindeki ayrıntılarını gösterebilir. Patologlar bu tür görüntüleri kanser hücrelerini tanımlamak, kötü huy derecesini değerlendirmek ve tümörlerin histolojik özelliklerini anlamak için kullanırlar. Veri kümesi, kanserli hücrelerin bulunduğu alanlar, normal doku ve potansiyel olarak tanı ve araştırmayla ilgili diğer özellikler gibi ilgilenilen bölgeleri belirten ek açıklamalar veya etiketler içerebilir. Veri kümesi, bu kanser türleri içindeki histolojik çeşitlilik göz önüne alındığında, akciğer ve kolon kanserinin farklı alt türlerini kapsayabilir. Görüntü çözünürlüğü ve

boyutu deęiřebilir ancak ayrıntılı analize olanak saęlamak için bunların yüksek çözünürlüklü görüntüler olması önemlidir. Hasta demografisi, klinik geçmiři ve potansiyel tedavi sonuçları gibi bilgiler veri kümesine dahil edilebilir. Bu ek veriler kapsamlı araştırma ve analiz için deęerlidir (Borkowski vd., 2019).

Bu tezde, açık erişimli veri seti kütüphanesinden elde edilen çok bilinen “Akcięer ve Kolon Kanseri Histopatolojik Görüntüleri” veri kümesi kullanılmıştır. Veri kümesi řu adresten elde edilmiştir: <https://www.kaggle.com/datasets/andrewmvd/lung-and-colon-cancer-histopathological-images>

Veriler beř sınıflandırmada 25.000 histopatoloji görüntüsünden oluşmaktadır. Her görüntü, 768x768 piksellik bir görüntü biçiminde saklanan bir jpeg dosyasıdır.

Genel olarak, HIPAA uyumlu kaynakların geçerli örnekleri kullanılarak 750 akcięer dokusu görüntüsü (250 akcięer adenokarsinomu, 250 akcięer skuamöz hücreli karsinomu ve 250 iyi huylu akcięer dokusu) ve 500 kolon dokusu görüntüsü (250 kolon adenokarsinomu ve 250 iyi huylu kolon dokusu) oluşturulmuřtur ve Augmentor paketi kullanılarak 25.000’e çoęaltılmıştır.

5.000’er adetlik beř grupta toplam 25.000 renkli görüntü olmak üzere bir koleksiyon oluşturulmuřtur. LC25000.zip isimli 1,85 GB’lık bir zip dosyası veri kümemizi içermektedir (Borkowski vd., 2019). Dosyayı açtıktan sonra, ana akcięer_colon_image_set klasöründe iki alt klasör koloni_image_sets ve akcięer_image_sets bulunur. Colon_image_sets alt klasöründe, koloni_aca (kolon adenokarsinomlarının 5.000 görüntüsü) ve kolon_n (iyi huylu kolonik dokuların 5.000 görüntüsü) dahil olmak üzere iki alt klasör daha bulunabilir. Lung_image_sets alt klasörüne üç alt klasör daha eklenmiştir: her biri iyi huylu akcięer dokusunun 5.000 fotoğrafını içeren akcięer_scc, akcięer_n ve akcięer_aca’dır. Lung_aca alt klasöründe akcięer adenokarsinomlarının 5.000 görüntüsü bulunur.

Veri kümesi, her biri 5.000 görüntü içeren beř sınıftan oluşur; 1) İyi huylu akcięer dokusu 2) Akcięer skuamöz hücreli karsinomu; 3) Akcięer adenokarsinomu; 4) İyi huylu kolon dokusu ve 5) Kolon adenokarsinomu.


Bu tezde son iki veri kümesi kullanılmıştır: Kolon iyi huylu dokusu ve Kolon adenokarsinomu. Bu veri kümeleri kolonun histopatolojik görüntülerini içerir. Bu araştırmada 5.000'i kanserli ve 5.000'i kanserli olmayan olmak üzere 10.000 görüntü kullanılmıştır.

Burada veri kümesinden altı histopatolojik görüntü örneği verilmiştir (colon_n_ sağlıklı bir görüntüyü, colon_ca_ kolon kanseri görüntüsünü belirtir). Kullanılan veri kümesinin açıklaması Tablo 3.1'de gösterilmiştir.

Tablo 3.1 Veri kümesinin açıklaması.

Görüntü Türü	Sınıf ID	Sınıf Adı	Toplam Görüntü
Colon Adenocarcinoma	0	Col_Ad	5.000
Colon Benign Tissue	1	Col_Be	5.000
Toplam Görüntü			10.000

Şekil 3.12 de ilk satırdaki görüntüler kolon kanseri görüntülerini, ikinci satırdaki görüntüler ise kanser olmayan görüntüleri temsil etmektedir.



Şekil 3.12 Veri kümesinden örnek görüntüler

4. SONUÇLAR VE TARTIŞMA

4.1 Arka plan

Bu bölümde sonuçlar gösterilmiş ve önerilen sonuçlar diğer yöntemlerle ve farklı CNN türleriyle karşılaştırılmıştır. Son olarak, önerilen yöntemi uygulamak için histopatolojik görüntüler kullanılmıştır.

4.2 Veri Kümesi

Bu çalışmada LC25000 kullanılmıştır ve bu veri kümesi 5.000 kanserli ve 5.000 kanserli olmayan görüntü içermektedir.

4.3 Değerlendirme

Bu çalışmada görüntülerin sınıflandırılması, doğruluk (ACC), hassasiyet (Gerçek Pozitif Oran (TPR)), özgüllük (Gerçek Negatif Oran (TNR)), kesinlik (Pozitif Tahmini Değer (PPV)), Negatif Tahmini Değer (NPV) ve F1 puanı kullanılarak yapılmıştır. Sırasıyla Denklemler 4.1–4.7, göstergelerin her biri için kriterleri tanımlar (Al-Rahlawee ve Rahebi, 2021; Al-Safi vd., 2021, 2022; Al Shalchi ve Rahebi, 2022; Iswisi vd., 2021):

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (4.1)$$

$$\text{Hassasiyet (Gerçek Pozitif Oran (TPR))} = \frac{TP}{TP+FN} \times 100\% \quad (4.2)$$

$$\text{Özgüllük (Gerçek Negatif Oran (TNR))} = \frac{TN}{TN+FP} \times 100\% \quad (4.3)$$

$$\text{Kesinlik (Pozitif Tahmini Değer (PPV))} = \frac{TP}{TP+FP} \times 100\% \quad (4.4)$$

$$\text{Negatif Tahmini Değer (NPV)} = \frac{TN}{TN+FN} \times 100\% \quad (4.5)$$

$$F1 \text{ puanı} = \frac{2PPV \times TPR}{PPV + TPR} \times 100\% \quad (4.6)$$

$$\text{Yanlış Sınıflandırma Oranı (MR)} = \frac{FP + FN}{TP + TN + FP + FN} \times 100\% \quad (4.7)$$

Bu göstergeler sırasıyla pozitif ve negatif sınıflandırmaları temsil eden Yanlış Pozitif (FP), Gerçek Pozitif (TP), Gerçek Negatif (TN) ve Yanlış Negatif (FN) kullanılarak hesaplanır. Burada sırasıyla,

Doğruluk: Doğruluk, bir modelin tahminlerinin genel doğruluğunun bir ölçüsüdür. Doğru tahminlerin (hem gerçek pozitif hem de gerçek negatif) sayısının toplam tahmin sayısına oranı olarak hesaplanır. Doğruluk, modelin ne kadar iyi performans gösterdiğine dair genel bir fikir verir, ancak özellikle dengesiz sınıfların olduğu durumlarda (bir sınıfın diğerinden önemli ölçüde fazla olduğu durumlarda) tek başına yeterli olmayabilir.

Hassasiyet (Geri Çağırma veya Gerçek Pozitif Oranı): Model tarafından doğru şekilde tanımlanan gerçek pozitif vakaların oranını ölçer. Gerçek pozitiflerin (doğru şekilde tahmin edilen pozitif vakalar), gerçek pozitiflerin ve yanlış negatiflerin (yanlış bir şekilde negatif olarak tahmin edilen gerçek pozitif vakalar) toplamına oranı olarak hesaplanır. Hastalık tespiti gibi tüm pozitif vakaların belirlenmesinin önemli olduğu bağlamlarda hassasiyet kritik öneme sahiptir.

Özgüllük (Gerçek Negatif Oranı): Model tarafından doğru şekilde tanımlanan gerçek olumsuz vakaların oranını ölçer. Gerçek negatiflerin (doğru tahmin edilen negatif vakalar), gerçek negatiflerin ve yanlış pozitiflerin (yanlış bir şekilde pozitif olarak tahmin edilen gerçek negatif vakalar) toplamına oranı olarak hesaplanır. Yanlış pozitifleri en aza indirmek ve negatif vakaların yanlışlıkla pozitif olarak sınıflandırılmamasını sağlamak için yüksek özgüllük önemlidir.

Kesinlik (Pozitif Tahmin Değeri): Gerçekten doğru olan olumlu tahminlerin oranını ölçer. Gerçek pozitiflerin, gerçek pozitiflerin ve yanlış pozitiflerin (yanlış bir şekilde pozitif olarak tahmin edilen durumlar) toplamına oranı olarak hesaplanır. Hassasiyet,

tıbbi teşhis veya sahtekarlık tespiti gibi hatalı pozitif sonuçların maliyetinin yüksek olduğu senaryolarda özellikle önemlidir.


Negatif Tahmin Değeri (NPV): Gerçekten doğru olan negatif tahminlerin oranını ölçer. Gerçek negatiflerin, gerçek negatiflerin ve yanlış negatiflerin (yanlış bir şekilde negatif olarak tahmin edilen durumlar) toplamına oranı olarak hesaplanır. NPV, negatif bir test sonucunun güvenilirliğini değerlendirmede önemlidir ve bir rahatsızlığı olmadığı söylenen kişilerin gerçekten negatif olduğundan emin olunmasını sağlar.

F1 Puanı: Kesinlik ve hatırlamanın (hassasiyet) harmonik ortalamasıdır. Hem yanlış pozitifleri hem de yanlış negatifleri hesaba katan tek bir ölçüm sağlayarak iki ölçümü dengeler. F1 puanı özellikle dengesiz veri kümeleriyle uğraşırken veya uygulama için hem kesinlik hem de hatırlamanın önemli olduğu durumlarda kullanışlıdır.

Bu çalışmada kolon hastalıklarını kategorize etmek için destek vektör makineleri, k-en yakın komşu ve karar ağaçları kullanılmıştır. Önerilen yaklaşım aynı zamanda çeşitli yapay sinir ağlarına da uygulanmıştır. Çekirge optimizasyon algoritmasının optimal özellikleri seçebilmesi için önerilen yöntemdeki yinleme sayısı 80 olup popülasyon büyüklüğü 25'tir. Bu çalışma MATLAB 2022a ortamı ve 4GHz CPU'lu Intel Core I7 işlemci kullanılarak simüle edilmiştir.

4.3.1 Amaç Fonksiyonu Analizi

Önerilen stratejiyi değerlendirmenin bir yolu, özellik seçiminde amaç fonksiyonunun değerini hesaplamaktır. Şekil 4.1 ortalama özellik seçim fonksiyonunu göstermektedir. Özellik seçimi için amaç fonksiyonu, GOA algoritmasına kıyasla daha az tekrarlı olma eğilimindedir. Bu azalma, GOA algoritmasının sinir ağı için en iyi ve en uygun özellik vektörünü seçerek görüntüleri doğru şekilde kategorize ettiğini göstermektedir. Analize göre amaç fonksiyonunun düşme eğilimine iki faktör neden olmaktadır. Özellik boyutlarının küçültülmesi ilk sebeptir. İkinci sebep ise kolon hastalığına bağlı görüntü sınıflandırma hatalarının azalmasıdır.




Şekil 4.1 GOA algoritması yinelemeleri bakımından özellik seçme fonksiyonunun azaltılması

Analiz, amaç fonksiyonunun 0,05481'den 0,00649'a düşmesi nedeniyle özellik vektörlerinin sayısı arttığında optimal özellik vektörünü keşfetme olasılığının arttığını ortaya koymaktadır. Bu azalma yaklaşık 8,44 kat civarındadır.

4.3.2 GOA Algoritmasını Kullanarak Sınıflandırma Doğruluğu Analizi

Şekil 4.2, bir deneydeki kolon hastalarının fotoğraflarını sınıflandırmada GOA algoritmasının doğruluğunu göstermektedir. Uygulama için dört CNN yöntemi kullanılmış ve değerlendirilmiştir. Bu yöntemler GoogleNet, SqueezeNet, Resnet-50 ve AlexNet'tir.



Şekil 4.2 Önerilen yöntemin farklı CNN yöntemlerindeki sonuçları

Analiz ve değerlendirmeler, SqueezeNet yaklaşımının görüntü doğruluğu sınıflandırılmasında oldukça iyi performans gösterdiğini ortaya koymaktadır. GOA algoritmasının özellik vektörünü dikkatli bir şekilde seçmesi doğrulukta iyileşmeye yol açmıştır. Ayrıca SqueezeNet yaklaşımı, dağıtılmış öğrenme sırasında sunucudan sunucuya aktarımı azaltır. SqueezeNet'ten GOA'nın en iyi özelliğinin seçilmesi, kolon kanseri ve kanser olmayan verilerin tanınmasında daha az hata yapılmasını sağlar.

GOA algoritmasının işlevi, makine öğrenimi için en iyi özellik vektörünü seçmektir. Özellik seçme algoritması, makine öğrenimi ve öğretimi için kolon hastası görüntülerinden en önemli özellikleri seçmeyi amaçlamaktadır. Bu deneyde GoogleNet'in doğruluğu %98,12, SqueezeNet'in doğruluğu ise %98,23'tür. Özellik vektörlerinin popülasyonu arttığında, deney 80'de SqueezeNet'in kolorektal veri kümesi doğruluğunda ortalama %99,12'lik bir iyileşme elde edilmiştir.

4.3.3 Karşılaştırma

Başlangıçta, önerilen yaklaşımı uygulamak için kolorektal veri kümesi seçilmiş ve etkinliği görüntüler aracılığıyla değerlendirilmiştir. Tablo 4.1’te, önerilen yöntemin hassasiyet, özgüllük ve doğruluk indeksi bulguları, SqueezeNet yöntemlerine dayalı aynı CNN’ye sahip diğer meta-sezgisel yöntemler olan karınca kolonisi optimizasyonu (ACO), parçacık sürüsü optimizasyonu (PSO), genetik algoritma (GA) ve gri kurt optimizasyonu (GWO) algoritmaları ile karşılaştırılmaktadır. Önerilen yöntemin diğer yaklaşımlarla karşılaştırıldığındaki hassasiyet, özgüllük ve doğruluk ortalama değerleri aşağıda Tablo 4.1’de verilmiştir.

Tablo 4.1 Hassasiyet, özgüllük, doğruluk ve F1 puanlarının karşılaştırılması

Metot	Hassasiyet	Özgüllük	Doğruluk	F1Puanı
ACO	%97,21	%96,79	%95,58	%96,21
PSO	%97,89	%96,34	%94,67	%97,34
GA	%97,18	%95,79	%93,90	%96,01
GWO	%98,45	%97,18	%98,34	%97,99
Önerilen Yöntem	%99,34	%99,41	%99,12	%98,94

Analiz, önerilen yöntemin ortalama hassasiyet, özgüllük ve doğruluk indeksinin sırasıyla %99,34; %99,41 ve %99,12 olduğunu göstermektedir. Önerilen yöntem hassasiyet, özgüllük, doğruluk ve F1 puanı bakımından diğer meta-sezgisel yöntemlerle karşılaştırıldığında kolon hastalarının görüntülerinin analizinde ve sınıflandırılmasında daha iyi bir performansa sahiptir.


GA yönteminde doğruluk indeksi %93,90’a eşittir. Önerilen yöntemde bu indeks %99,12’dir. Tablo 4.1’den görüldüğü gibi en kötü sonuçlar GA algoritmasından elde edilmektedir. GA algoritması için elde edilen hassasiyet, özgüllük, doğruluk ve F1 puanı sonuçları sırasıyla %97,18; %95,79; %93,90 ve %96,01’dir.

Sonuçlar, Tablo 4.2 ve Şekil 4.3’te, çeşitli çalışmalardan elde edilen sonuçlarla karşılaştırılmıştır.

Tablo 4.2 Farklı yöntemlerin ortalama hassasiyet, özgüllük, doğruluk, kesinlik ve F1 Puanı karşılaştırması

Kaynak	Metot	Hassasiyet	Özgüllük	Doğruluk	Kesinlik	F1 Puanı
Hadiyoso vd., 2023	Evrişimsel sinir ağı ve CLAHE sistemi	-	-	%98,96	-	-
Mangal vd., 2020	Evrişimsel sinir ağları	-	-	%96,00	-	-
Masud vd., 2021	Derin öğrenme tabanlı makine öğrenimi yaklaşımı	%96,37	-	%96,33	%96,39	%96,38
Provath vd., 2023	Derin Öğrenme Yöntemi	%97,00		%97,00	%97	%97,00
Stephen ve Sain, 2023	Bayesian-Gaussian'dan Esinlenen Evrişimsel Nöral Mimari Arama ile Derin Öğrenme	%93,00	-	%97,92	%97	%97,00
Naga Raju ve Srinivasa, 2023	Hybrid principal component analysis network and extreme learning machine Hibrit temel bileşen analiz ağı ve ekstrem öğrenme makinesi	%99,12	%99,38	%98,97	%98,87	%98,84
Abdallah vd., 2022	Evrişimsel Sinir Ağı	%99,00	-	%99,00	%98,6	%98,8
Mehmood vd., 2022	Sınıf seçicili görüntü işlemeyle transfer öğrenimi	-	-	%98,40		
Bukhari vd., 2020	Kısmi öz denetimli öğrenme	%95,74	%80,95	%93,04	%95,74	%95,74
Önerilen Yöntem	SqueezeNet ve GOA tabanlı CNN	%99,34	%99,41	%99,12	%98,91	%98,94

Önerilen stratejinin başlıca dört göstergesi vardır: doğruluk, hassasiyet, kesinlik ve F1 puanı; DropBlock, 7 katmanlı CNN, Rastgele Orman ve 9 katmanlı CNN gibi bazı yöntemler kolon kanseri ve kanser olmayan görüntüleri sınıflandırmada daha başarılı olmuştur.



Şekil 4.3 Önerilen yöntem ve diğer yöntemlerdeki hassasiyet, özgüllük, kesinlik, doğruluk ve F1'in ortalama indeksi

Önerilen yöntemin görüntüleri sınıflandırmadaki hassasiyeti, özgüllüğü, kesinliği, doğruluğu ve F1 değerleri sırasıyla %99,34; %99,41; %98,91; %99,12 ve %98,94'tür. 7 katmanlı CNN yönteminin, önerilen yöntemden sonra ikinci en yüksek görüntü sınıflandırma doğruluğuna sahip olduğu ancak 9 katmanlı CNN yönteminin en kötü performansa (%91,88) sahip olduğu tespit edilmiştir. Ayrıca önerilen yöntem en yüksek hassasiyet indeksi değerini göstermiş ancak 7 katmanlı CNN en kötü performansı göstermiştir. Önerilen yöntem kesinlik indeksinde en iyi performansı göstermiş, bunu en yüksek hassasiyet indeksine sahip DropBlock CNN yöntemi izlemiştir. 7 katmanlı CNN yöntemi en kötü performansı göstermiştir. Genel olarak önerilen yöntem F1 puanında en iyi performansı gösterirken, 7 katmanlı CNN yöntemi bu endekste en kötü performansı göstermiştir.

4.4 ACO-PSO İin ğrenilebilir Sınıflandırıcılar Kullanarak Sınıflandırma

En iyi kombine tekniğın seçilmesi için kapsamlı bir alışma yapılmıştır. Bu alışma için, Karınca Kolonisi Optimizasyonu (ACO) ve Paracık Sürüsü Optimizasyonu (PSO) birlikte kullanılarak özellik azaltma teknikleri uygulanmıştır. İlk aşamada, giriş öğrenme veri kümesinden önemli özellikleri sırasıyla çıkarmak ve seçmek için kolon hastalığı veri kümelerine PSO algoritmasıyla birleştirilmiş bir otomatik kodlayıcı yöntemi uygulanmıştır. Diğer yandan, ilk modelde kullanılan aynı veri kümelerinin her ikisini de sınıflandırmak için PSO algoritması ile önceden ğretilmiş CNN uygulanmıştır. Karışıklık matrisinden türetilen modellerin performansı, doğruluk, kesinlik, geri ağırma, F1 puanı vb. gibi bir dizi temel kriter kullanılarak ölçülmüştür. ok sınıflı sınıflandırma için genel doğruluk, sınıf tespit oranı ve sınıf FP oranı kullanılmaktadır. Temel terimlerimiz; pozitif olarak sınıflandırılan pozitif örnekleri ifade eden Gerek Pozitif (TP), negatif olarak sınıflandırılan negatif örnekleri ifade eden Gerek Negatif (TN), pozitif olarak sınıflandırılan negatif örnekleri ifade eden Yanlış Pozitif (FP) ve negatif olarak sınıflandırılan pozitif örnekleri ifade eden Yanlış Negatif (FN)'tir.

4.4.1 Kolon Kanseri Hastalığı Veri Kümesi İin PSO'lu Otokodlayıcı

Bu alışmada, önerilen tekniğın etkinliğini doğrulamak ve bu modelin performansının farklı kombinasyonlarını ve kapsamlı karşılaştırmayı yapmak için eşitli senaryolar geliştirilmiş ve değ erlendirilmiştir. İlk aşamada otokodlayıcı, beş farklı sınıflandırıcı tipine sahip bir kolon kanseri hastalığı veri kümesi sunmuştur.

Otokodlayıcı ve PSO algoritması kullanılarak bulunan kolon kanseri hastalığı veri kümesi sonuçları Tablo 4.3'te sunulmaktadır.

Tablo 4.3 PSO özellik seçim algoritmasını kullanan otokodlayıcıya ait kolon kanseri hastalığı veri kümesi

Metot	ACC	TPR	TNR	FPR	FNR	PPV	NPV	F1-puanı	MR
Karar Ağacı	68,61	68,75	68,75	33,15	33,15	69,01	69,01	68,74	3,01
SVM	79,21	74,64	74,64	35,83	35,83	80,61	80,61	72,44	2,41
KNN	76,16	77,86	77,86	26,96	26,96	79,31	79,31	76,91	5,46
Topluluk	73,81	75,44	75,44	29,23	29,23	77,11	77,11	74,67	7,81
Naive Bayes	67,41	73,55	73,55	37,74	37,74	80,91	80,91	71,38	4,21

Bu sınıflandırma modelinin değerlendirilmesindeki en önemli faktör, sınıflandırılan test görüntülerinin gerçek değerlerine dayanan doğruluktur. SVM sınıflandırıcı %79,21’lik daha yüksek bir doğruluk oranına ulaşarak %2,41’lik bir yanlış sınıflandırma oranı elde etmiştir.

4.4.2 Kolon Kanseri Hastalığı Veri Kümesi İçin Otokodlayıcıyı ACO-PSO ile Kullanma

Beş farklı sınıfı (kansere dışı akciğer dokusu, akciğerin skuamöz hücreli karsinomu, akciğerin adenokarsinomu, kansersiz kolon dokusu ve kolonun adenokarsinomu) içeren kolon bozuklukları için bu ikinci en iyi bilinen veri kümesini kullanarak model, tıbbi görüntüleri başarılı bir şekilde sınıflandırmıştır. Tablo 4.4, ACO-PSO algoritmasının kullanımıyla kolon kanseri hastalığı veri kümesine uygulanan otokodlayıcıdan elde edilen sonuçları sunmaktadır.

Tablo 4.4 Kolon kanseri hastalığı veri kümesi için otokodlayıcı ve ACO-PSO özellik seçiminin kullanımı

Metot	ACC	TPR	TNR	FPR	FNR	PPV	NPV	F1-puanı	MR
Karar Ağacı	78,86	79,1	79,1	32,99	32,99	79,51	79,51	79,07	21,95
SVM	78,41	84,21	84,21	36,71	36,71	90,81	90,81	81,98	22,4
KNN	82,36	83,47	83,47	30,27	30,27	84,81	84,81	83,04	18,45
Topluluk	82,76	84,96	84,96	30,69	30,69	87,31	87,31	83,98	28,05
Naive Bayes	74,56	89,28	89,28	31,75	31,75	100,41	100,41	82,01	26,25


Topluluk sınıflandırıcı, optimum özelliklerin seçilmesi için ACO-PSO algoritmasının sınıflarının kategorizasyonunda %82,76 doğruluk elde etmiştir.

4.4.3 Kolon Kanseri Hastalığı Veri Kümesi İçin ACO-PSO ile Önceden Öğretilmiş CNN

İkinci senaryo için, önceden öğretilmiş iki CNN (GoogleNet ve Resnet50) uygulanmıştır; CNN, öncelikle piksel girişini işlemek için oluşturulmuş, görüntü işleme ve algılamada kullanılan bir yapay sinir ağı biçimidir. Basit işlem talepleri için tasarlanmış çok katmanlı algılayıcı benzeri bir teknoloji kullanır. Bu çalışmada CNN, kullanılan bu özellik seçme yönteminin gücünü doğrulamak amacıyla PSO ile birlikte de uygulanmıştır. Bunun yanı sıra, sınıflandırma modelini hesaplamak için 4

tip sınıflandırıcı kullanılmıştır. Tablo 4.5 kolon hastalığı veri kümesi için PSO’lu dört önceden öğretilmiş CNN’nin sonucunu göstermektedir.

ACO-PSO ile önceden öğretilmiş CNN’nin değerlendirilmesi, kolon hastalıklarına ilişkin veri kümesi kullanılarak gerçekleştirilmiştir. Şekil 4.4 bu modelde kolon hastalığına yönelik teşhis oranlarını göstermektedir. Önceden öğretilmiş ResNet-50 ağıyla birlikte karınca kolonisi optimizasyon yöntemini kullanan simülasyonun sonucu, Şekil 4.4’te gösterilmektedir.




Şekil 4.4 ResNet-50 ve ACO-PSO’yu temel alan simülasyonun sonucu

Şekil 4.4, karar ağacı, SVM, KNN ve topluluk yöntemlerinin doğruluğunun sırasıyla %97,63; %100,00; %99,97 ve %99,97 olarak elde edildiğini göstermektedir. SVM sınıflandırma yöntemi %100 doğruluk elde etmiştir ve en iyi sonuçtur. DVM’ler, KNN, karar ağaçları ve topluluk yöntemleri gibi diğer yöntemlerden daha kesin doğrusal sınıflandırıcılardır. Ek olarak bu senaryoda, ACO-PSO algoritması ve önceden öğretilmiş bir ResNet-50 ağı kullanılarak elde edilen özelliklere sahip SVM sınıflandırıcı kullanılarak en yüksek doğruluk elde edilmiştir. Ayrıca bu çalışma, karar ağacı, SVM, KNN ve topluluk yöntemlerinin performansını F1 puan metriği ile değerlendirmiş ve bu algoritmalar için sırasıyla %97,64; %100,00; %99,97 ve %99,97 puanlar elde edilmiştir. F1 puanı sonuçlarından görüldüğü üzere DVM’nin

diğer yöntemlere göre daha yüksek doğruluğa sahip olduğu anlaşılmaktadır. ResNet-50 ve ACO-PSO kullanılarak yapılan SVM'nin uyumsuzluk oranı %0 olarak kaydedilmiştir.

Önceden öğretilmiş GoogLeNet ağıyla birlikte ACO-PSO yöntemini temel alan simülasyon sonuçları, Şekil 4.5'te gösterilmektedir.



Şekil 4.5 ACO-PSO ile GoogLeNet'i temel alan simülasyon sonucu

Şekil 4.5'te gösterildiği gibi karar ağacı, DVM, KNN ve topluluk yöntemlerinin doğruluğu sırasıyla %99,50; %99,93; %99,97 ve %99,97 olarak elde edilmiştir. Doğruluk açısından en iyi sonuç KNN ve topluluk sınıflandırıcı yöntemlerinden elde edilen %99,97'dir. Bu senaryoda KNN ve topluluk yöntemi diğer yöntemlere göre daha yüksek performansa sahiptir. KNN ve topluluk ile yapılan sınıflandırma ve ACO-PSO ve GoogLeNet ile önceden öğretilmiş ağ kullanılarak elde edilen özelliklerin en yüksek doğruluğu elde ettiği anlaşılmaktadır. Bu çalışmada da F1 puanı uygulanmış ve karar ağacı, SVM, KNN ve topluluk yöntemlerine ait sonuçlar sırasıyla %99,50; %99,93; %99,97 ve %99,97 olarak elde edilmiştir. F1 puanı sonucundan görüldüğü gibi KNN ve topluluk yönteminin diğer yöntemlere göre en yüksek doğruluğa sahip olduğu anlaşılmaktadır. GoogLeNet ve ACO-PSO'ya dayalı KNN ve topluluk yöntemi için uyumsuzluk oranı %0,03 olarak elde edilmiştir.

4.5 Kolon Kanseri Hastalığı Veri Kümesi İçin Otokodlayıcıyı FMO ile Kullanma

Önerilen tekniğin etkinliğini doğrulamak ve farklı kombinasyonları karşılaştırmak için çeşitli senaryolar geliştirilmiş ve değerlendirilmiştir. İlk aşamada, kolon kanseri hastalığına ilişkin bir veri kümesi, beş farklı sınıflandırıcı türüyle birlikte otokodlayıcı tarafından işlenmiştir. Otokodlayıcı ve FMO tekniğini kullanan kolon kanseri hastalığı veri kümesinin sonuçları Tablo 4.5'te gösterilmektedir.


Tablo 4.5 FMO özellik seçim algoritmasını kullanan otokodlayıcının kolon hastalığı veri kümesi

Metot	ACC	TPR	TNR	PPV	NPV	F1-puanı
Karar Ağacı	67,80	67,94	67,94	68,20	68,20	67,93
SVM	68,40	73,83	73,83	79,80	79,80	71,63
KNN	75,35	77,05	77,05	78,50	78,50	76,10
Topluluk	73,00	74,63	74,63	76,30	76,30	73,86
Naive Bayes	66,60	72,74	72,74	80,10	80,10	70,57

Bu sınıflandırma modelinin değerlendirilmesindeki en önemli faktör, sınıflandırılan test görüntülerinin gösterdiği doğruluktur. KNN sınıflandırıcısı %75,35 gibi daha yüksek bir doğruluk oranına ulaşmıştır.

4.6 Kolon Kanseri Hastalığı Veri Kümesi İçin FMO'lu Önceden Öğretilmiş CNN


Önceden öğretilmiş CNN'nin FMO ile değerlendirilmesi kolon hastalıklarına ilişkin veri kümesi kullanılarak yapılmıştır. Şekil 4.6 bu modelde kolon hastalığına yönelik teşhis oranlarını göstermektedir. Önceden öğretilmiş ResNet-50 ağıyla birlikte FMO yöntemini kullanan simülasyon sonucu, Şekil 4.6'da sunulmaktadır.



Şekil 4.6 ResNet-50 ve FMO'ya dayalı simülasyonun sonucu

Şekil 4.6, Karar Ağacı, SVM, KNN ve topluluk yöntemlerinin doğruluğunun sırasıyla %90,82; %95,01; %95,04 ve %93,46'ya ulaştığını göstermektedir. KNN sınıflandırma yöntemi %95,04 doğruluk oranıyla en iyi sonucu elde etmiştir. KNN metodu, SVM, karar ağacı ve topluluk yöntemleri gibi diğer yöntemlerden daha doğru olan, parametrik olmayan, denetimli öğrenme sınıflandırıcısıdır. Ek olarak bu çalışma, karar ağacı, SVM, KNN ve topluluk yöntemlerinin performansını F1 puan metriği ile değerlendirmiş ve bu algoritmalar için sırasıyla %68,54; %94,25; %97,74 ve %94,97 puanları elde edilmiştir. F1 puanı sonuçlarından görüldüğü gibi KNN'nin diğer yöntemlere göre daha yüksek doğruluğa sahip olduğu anlaşılmaktadır.

Önceden öğretilmiş GoogLeNet ağıyla birlikte FMO yöntemini temel alan simülasyon sonuçları, Şekil 4.7'de gösterilmektedir.



Şekil 4.7 FMO'lu GoogLeNet'i temel alan simülasyonun sonucu


Şekil 4.7'de görüldüğü gibi karar ağacı, DVM, KNN ve topluluk yöntemlerinin doğruluğu sırasıyla %89,84; %95,80; %97,65 ve %96,70 olarak elde edilmiştir. Doğruluk açısından en iyi sonuç KNN sınıflandırıcı yöntemiyle elde edilen %97,65'tir. Bu senaryoda KNN yöntemi diğer yöntemlere göre daha yüksek performansa sahiptir. KNN ile yapılan sınıflandırma ve FMO ve önceden öğretilmiş ağ ile GoogLeNet kullanılarak elde edilen özelliklerin en yüksek doğruluğu elde ettiği anlaşılmaktadır. Bu çalışmada da F1 puanı uygulanmış ve karar ağacı, SVM, KNN ve topluluk yöntemlerine ait sonuçlar sırasıyla %92,54; %95,49; %96,76 ve %96,52 olarak elde edilmiştir. F1 puanı sonucundan görüldüğü üzere KNN'nin diğer yöntemlere göre en yüksek doğruluğa sahip olduğu anlaşılmaktadır. Yapılan incelemede önerilen yaklaşımın hassasiyet, özgüllük ve doğruluk indekslerinin sırasıyla %94,87; %96,19 ve %97,65 olduğu belirlenmiştir. Önerilen yaklaşımın hassasiyet indeksi ve özgüllüğü, Tablo 4.6'da gösterildiği gibi kolon hastalarının görüntülerinin incelenmesi ve sınıflandırılmasında Shin ve Balasingham (2017),

Poudel vd., (2020), Stidham vd., (2019) ve Zhang vd., (2016)'nin yaptıkları çalışmalarda incelenen yöntemlerden daha iyi performans göstermektedir.

Tablo 4.6 Önerilen yöntem ile karşılaştırılabilir yaklaşımlar arasındaki ortalama hassasiyet, özgüllük ve doğruluk karşılaştırması

Kaynak	Hassasiyet	Özgüllük	Doğruluk
Zhang vd., 2016	85	87	83
Shin ve Balasingham, 2017	83	84	83
Stidham vd., 2019	89	89	89,4
Poudel vd., 2020	93	92,8	93,2
Önerilen Yöntem	94,87	96,19	97,65

Poudel vd., (2020)'nin çalışmasında açıklanan yöntemin doğruluk puanı %93,2 olarak kaydedilmiştir. Buna karşılık, önerilen yöntem %97,65'lik bir doğruluk puanına ulaşmaktadır. Önerilen yaklaşımın kapsamlı bir değerlendirmesini yapmak için sonuçlar, Şekil 4.8'de gösterildiği gibi, sahadaki çeşitli araştırmalarla karşılaştırılmıştır.




Şekil 4.8 Önerilen yöntemde ve karşılaştırılabilir yaklaşımlarda ortalama doğruluk, hassasiyet, kesinlik ve F1 puanının karşılaştırmalı analizi

Değerlendirme önerilen yaklaşımın, doğruluk, kesinlik, hassasiyet ve F1 puanı ölçümlerinin, kolon hastalığı görüntü sınıflandırmasında 6 Katmanlı CNN, 3 Katmanlı CNN, Rastgele Orman ve CNN DropBlock gibi yöntemlerden daha iyi performans gösterdiğini öne sürmektedir. Önerilen yaklaşım, kolon kanseri hastalığı veri kümesi görüntüleri sınıflandırmasında sırasıyla %97,65; %93,89; %94,87 ve %96,76 oranlarında doğruluk, kesinlik, hassasiyet ve F1 puanı değerleri sergilemektedir. Değerlendirmeler, önerilen yaklaşımdan sonra 3 katmanlı CNN yönteminin görüntü sınıflandırmasında en yüksek doğruluğu elde ettiğini göstermektedir. Doğruluk metriği açısından CNN 6Layer yaklaşımı yaklaşık %91,4 doğrulukla sınıflandırmada en düşük sonucu vermiştir. Bunun aksine, önerilen yöntem görüntü sınıflandırmada en yüksek doğruluk indeksine ulaşmaktadır. Hassasiyet indeksi açısından önerilen yaklaşım en iyi performansı sağlarken, hemen ardından en büyük hassasiyet indeksine sahip CNN DropBlock yaklaşım tekniği gelmektedir.

CNN 3Layer tekniği, karşılaştırılan yöntemler arasında en zayıf hassasiyet indeksini göstermektedir. Karşılaştırılan yöntemler arasında önerilen yaklaşım F1 puanı indeksinde en iyi performansı gösterirken, 3 Katmanlı CNN yöntemi bu indekste en kötü performansı sergilemektedir.

Bu araştırmada hassasiyet, özgüllük, doğruluk, kesinlik, F1 puanı ve ROC diyagramlarını kapsayan çeşitli değerlendirme kriterleri kullanılmıştır. ROC diyagramı Şekil 4.9'da gösterilmektedir.



Şekil 4.9 AUC sayısal sonuçlarını içeren ROC diyagramı

Şekil 4.9’da görüldüğü gibi en iyi sonuçlar FMO algoritmasına dayalı GoogleNet için elde edilmiştir. GoogleNet mimarisi, bir araya getirilmiş birden fazla başlangıç modülünden oluşur ve bunun sonucunda dikkate değer derinlik ve doğruluğa sahip bir ağ ortaya çıkar. Ayrıca, FMO algoritması tarafından seçilen özellikler ara katmanlarda yardımcı sınıflandırıcılar olarak görev yapabilir, böylece kaybolan gradyan problemine çözüm bulunabilir.

Bu çalışmanın avantajı şu şekilde özetlenebilir:

Yüksek Doğruluk:

Evrişimli Sinir Ağının (CNN) kullanımı, tıbbi görüntülerden karmaşık özelliklerin çıkarılmasına olanak tanıyarak kolon kanseri teşhisinde yüksek doğruluğa katkıda bulunur.

Balıkçı Peygamber Devesi Optimizasyonu'nun entegrasyonu, optimizasyon sürecini geliştirerek potansiyel olarak daha ince ayarlı ve doğru bir modele ulaşılmasını sağlar.

Otomatik Teşhis:

Önerilen yaklaşım, kolon kanseri teşhisi için otomatik bir çözüm sunarak manuel muayeneye olan bağımlılığı azaltır ve potansiyel olarak teşhis sürecini hızlandırır.

Gelişmiş Görüntü Analizi:

CNN'ler görüntü tanımada başarılıdır ve bu da onları tıbbi görüntülerin analizi için çok uygun hale getirir. Bu durum, modelin kolon kanserine işaret eden karmaşık kalıpları ve yapıları öğrenmesini sağlar.

Doğadan Esinlenen Optimizasyon:

Balıkçı Peygamber Devesi Optimizasyonu, potansiyel olarak geleneksel optimizasyon teknikleriyle ilgili zorlukların üstesinden gelen, biyolojik ilhamlı bir optimizasyon algoritması sunar. Bu, yakınsamanın ve parametre ayarlarının iyileştirilmesini sağlayabilir.

Zamanında Müdahale:

Önerilen yaklaşımın kolaylaştırdığı otomatik ve doğru teşhis, zamanında müdahale ve tedaviye katkıda bulunarak potansiyel olarak hasta sonuçlarını ve prognozu iyileştirebilir.

Bu çalışmanın dezavantajları şu şekilde özetlenebilir:

Veri Bağımlılığı:

CNN'lerin başarısı genellikle büyük ve çeşitli veri kümelerine bağlıdır. Öğrenme için kullanılan veri kümesi temsili değilse veya çeşitlilikten yoksunsa, model görünmeyen verilere iyi bir şekilde genelleme yapmayabilir.

Hesaplama Yoğunluğu:

Derin öğrenme modellerinin, özellikle de CNN'lerin eğitimi, hesaplama açısından yoğun ve zaman alıcı olabilir. Bu durum, özellikle sınırlı hesaplama kabiliyetine sahip kurumlar için kaynak gereksinimleri açısından zorluklar yaratabilir.

Karmaşık Model Mimarisi:

CNN mimarisinin karmaşıklığı, modelin yorumlanmasında ve açıklanabilirliğinde zorluklara yol açabilir. Modelin iç işleyişini anlamak, tıbbi uygulamalarda güven kazanmak için çok önemli olabilir.

Optimizasyon Zorlukları:

Balıkçı Peygamber Devesi Optimizasyonu, optimizasyona doğadan ilham alan bir yaklaşım getirirken, performansı hiperparametrelerin seçimine duyarlı olabilir. En uygun konfigürasyonu bulmak ek deneyler gerektirebilir.

Genelleme Sorunları:

Modelin yeni, görülmemiş veriler üzerindeki performansı, gerçek dünyaya uygulanabilirliği açısından çok önemlidir. Model, öğrenme verilerine gereğinden fazla uyuyorsa, çeşitli veri kümelerinde iyi performans göstermeyebilir ve genelleme yeteneklerini sınırlayabilir.

Özetle, önerilen yaklaşım çeşitli avantajlar sunsa da veri bağımlılıkları, hesaplama yoğunluğu, model karmaşıklığı ve etik hususlar gibi potansiyel zorlukların ve

sınırlamaların farkında olmak, teşhis sisteminin sorumlu bir şekilde geliştirilmesi ve uygulanması için önemlidir.



5. SONUÇ VE GELECEK ÇALIŞMALAR

5.1 Sonuç

Dünya çapında kansere bağlı ölümlerin üçüncü önde gelen nedeni kolorektal kanserdir (CRC). Başlangıçta iyi huylu olan ancak daha sonra kötü huylu poliplere dönüşebilen adenomatöz polipler (adenom olarak da bilinir) CRC'ye neden olabilir. Polip aramak için yapılan rutin tarama şu anda CRC'ye bağlı ölüm oranını azaltmak için önerilen yöntemdir ve tercih edilen tarama yöntemi kolonoskopidir. Bu tez, kolon kanseri hastalığı olan bölgeleri ortaya çıkarmak için, sinir ağı öğrenimi gibi makine öğrenimi ile insanlarda öğrenme ve öğretimi birleştirmeyi amaçlamaktadır. Önerilen yöntemde GOA algoritması, öğretme ve öğrenme algoritması optimizasyonu ile verilen özelliğin seçilmesi için öncelikle GOA tekniğinin doğruluğunu artırır. Daha sonra hastalıktan etkilenen alanlar sinir ağı tabanlı öğrenme ile ayrıştırılır. Bu tezde ayrıca görüntünün içerdiği bilgileri geliştirmek için bileşen azaltma yöntemi kullanılmıştır. Önerilen yöntem ACO, PSO, GA ve GWO yöntemleriyle karşılaştırılmıştır. En iyi performans, SVM sınıflandırma yöntemine dayalı olarak önerilen yöntemden elde edilmiştir.

Bu çalışmanın avantajları şu şekilde özetlenebilir; Yüksek Doğruluk; Evrimsel sinir ağının (CNN) kullanılması, tıbbi görüntülerden karmaşık özelliklerin çıkarılmasına olanak tanır ve kolon kanseri teşhisinde yüksek doğruluğa katkıda bulunur. Fishier Mantis Optimizer'in entegrasyonu, optimizasyon sürecini geliştirerek potansiyel olarak daha ince ayarlı ve doğru bir modele yol açar. Otomatik Teşhis; Önerilen yaklaşım, kolon kanseri teşhisi için otomatik bir çözüm sağlayarak manuel muayeneye olan bağımlılığı azaltır ve potansiyel olarak teşhis sürecini hızlandırır. Gelişmiş Görüntü Analizi; CNN'ler görüntü tanıma görevlerinde üstündür ve bu da onları tıbbi görüntülerin analizi için çok uygun hale getirir. Bu, modelin kolon kanserini gösteren karmaşık kalıpları ve yapıları öğrenmesini sağlar. Doğadan Esinlenen Optimizasyon; Fishier Mantis Optimizer, geleneksel optimizasyon teknikleriyle ilişkili zorlukların potansiyel olarak üstesinden gelen, biyo-ilhamlı bir optimizasyon algoritması sunar. Bu, yakınsamanın ve parametre ayarlamasının iyileştirilmesine yol açabilir. Zamanında Müdahale; Önerilen yaklaşımın kolaylaştırdığı otomatik ve doğru teşhis, zamanında

müdahale ve tedaviye katkıda bulunarak potansiyel olarak hasta sonuçlarını ve prognozu iyileştirebilir.

Bu çalışmanın dezavantajları şu şekilde özetlenebilir; Veri Bağımlılığı; CNN'lerin başarısı genellikle büyük ve çeşitli veri kümelerine bağlıdır. Eğitim için kullanılan veri seti temsili değilse veya çeşitlilikten yoksunsa, model görünmeyen verilere iyi bir şekilde genelleme yapmayabilir. Hesaplama Yoğunluğu; Derin öğrenme modellerinin, özellikle de CNN'lerin eğitimi, hesaplama açısından yoğun ve zaman alıcı olabilir. Bu, özellikle sınırlı hesaplama kapasitesine sahip kurumlar için kaynak gereksinimleri açısından zorluklar yaratabilir. Karmaşık Model Mimarisi; CNN mimarisinin karmaşıklığı, modelin yorumlanması ve açıklanabilirliğinde zorluklara yol açabilir. Modelin iç işleyişini anlamak, tıbbi uygulamalarda güven kazanmak açısından çok önemli olabilir. Optimizasyon Zorlukları; Fishier Mantis Optimizer, optimizasyona doğadan ilham alan bir yaklaşım getirirken performansı hiperparametrelerin seçimine duyarlı olabilir. En uygun konfigürasyonu bulmak ek deneyler gerektirebilir. Genelleştirme Sorunları; Modelin yeni, görülmemiş veriler üzerindeki performansı, gerçek dünyaya uygulanabilirliği açısından çok önemlidir. Model, eğitim verilerine gereğinden fazla uyuyorsa, çeşitli veri kümelerinde iyi performans göstermeyebilir ve genelleme yeteneklerini sınırlayabilir. Özetle, önerilen yaklaşım çeşitli avantajlar sunarken, teşhisin sorumlu bir şekilde geliştirilmesini ve uygulanmasını sağlamak için veri bağımlılıkları, hesaplama yoğunluğu, model karmaşıklığı ve etik hususlar gibi potansiyel zorluklar ve sınırlamaların farkında olmak önemlidir. Bu çalışma, CNN tabanlı kolon kanseri tanısı için umut verici sonuçlar verirken, modelin sağlamlığını ve klinik uygulanabilirliğini daha da geliştirmek için çeşitli yollar mevcuttur. Gelecekteki çalışmalarda, özellikle eğitim verilerinde sıklıkla yeterince temsil edilmeyen nadir patolojileri kapsayan çeşitli ve temsili veri kümelerinin toplanmasına öncelik verilmelidir. Ayrıca, model budama veya dağıtılmış hesaplama çerçeveleri gibi gelişmiş hesaplamalı optimizasyon tekniklerinin araştırılması, hesaplama yoğunluğunun getirdiği sınırlamaları giderebilir. Son olarak, harici veri kümeleri üzerinde ve gerçek dünyadaki klinik ortamlarda sıkı doğrulama yapılması çok önemlidir. Bu doğrulama aşamasında klinisyenler ve alan uzmanlarıyla iş birliği yapmak, modelin yorumlana bilirliğini sağlamak, etik hususları ele almak ve sonuçta yapay zekâ destekli teşhis araçlarına güven oluşturmak için çok önemli olacaktır.

Kolon kanseri, etkili tedavi sonuçları için zamanında ve kesin teşhis gerektiren, halk sağlığı için önemli bir tehdit oluşturmaktadır. Bu çalışma, kolon kanserinin sınıflandırılmasını otomatikleştirmek için evrimsel sinir ağlarını (CNN'ler) Fishier Mantis Optimizer (FMO) ile birleştiren yeni bir yaklaşım sunmaktadır. Derin öğrenme tekniklerinden, özellikle de CNN'lerden yararlanmak, tıbbi görüntüleme verilerinden karmaşık özelliklerin çıkarılmasını sağlar, böylece sağlam ve etkili bir teşhis modelinin geliştirilmesini kolaylaştırır. Mantis karideslerinin avlanma davranışından ilham alan FMO algoritması, CNN parametrelerine ince ayar yaparak model yakınsama hızını ve genel performansı artırır. Bu hibrit metodoloji hem derin öğrenmenin hem de doğadan ilham alan optimizasyonun güçlü yönlerinden yararlanmayı, böylece kolon kanseri teşhisinin doğruluğunu ve etkinliğini artırmayı amaçlıyor. Kapsamlı bir kolon kanseri görüntü veri seti üzerinde gerçekleştirilen deneysel doğrulama, önerilen yöntemin geleneksel teşhis yaklaşımlarına göre üstünlüğünü ortaya koymaktadır.

CNN-FMO modeli, kanserli ve kanserli olmayan kolon dokuları arasında ayrım yapmada olağanüstü hassasiyet, özgüllük ve genel doğruluk sergiler. Özellikle FMO tabanlı özellik seçimi, Genetik Algoritmalar ve benzetilmiş tavlama gibi geleneksel yöntemlerden daha iyi performans göstererek duyarlılık, özgüllük, doğruluk ve F1 puanı dahil olmak üzere üstün performans ölçümleri sağlar. Ayrıca, yerleşik veri ön işleme tekniklerinin FMO tabanlı özellik seçimi ve CNN eğitimi ile kusursuz entegrasyonu, histopatolojik görüntülerden kritik özelliklerin çıkarılmasını geliştirir. Bu entegrasyon, modelin yalnızca kanserli ve kanserli olmayan örnekler arasında ayrım yapma yeteneğini geliştirmekle kalmıyor, aynı zamanda yorumlanabilirliği de artırıyor. FMO ile eğitim sırasında CNN ağırlıklarının yinelemeli optimizasyonu, kolon kanseri için daha hassas ayarlanmış ve doğru bir teşhis modeline katkıda bulunur. Özellik bolluğuyla ilgili zorlukları ele alan FMO algoritmalarının dahil edilmesi hem model performansını hem de yorumlanabilirliği artırır. Genel olarak önerilen yöntem, kolon kanserinin erken tespitini ve teşhisini artırma, böylece zamanında müdahaleyi kolaylaştırma ve hasta prognozunu iyileştirme konusunda önemli bir potansiyel ortaya koymaktadır. Derin öğrenmeyi doğadan ilham alan optimizasyonla birleştiren bu çalışma, sağlık hizmetleri sonuçlarının iyileştirilmesinde yenilikçi yaklaşımların vadinin altını çiziyor.

5.2 Gelecek Çalışmalar

Gelecekteki çalışmalarda, Grasshopper Optimizasyon Algoritması (GOA) ile birlikte evrişimli sinir ağları (CNN'ler) kullanılarak kolon kanseri teşhisinin doğruluğunu ve verimliliğini artırmak için çeşitli iyileştirmeler araştırılabilir. Potansiyel yönlerden biri, farklı CNN mimarilerini denemek veya büyük tıbbi görüntüleme veri kümelerinde ince ayar yapılmış önceden eğitilmiş modellerden yararlanmak için transfer öğrenme tekniklerini entegre etmektir. Ek olarak hem CNN hem de GOA'nın hiperparametrelerinin Bayes optimizasyonu veya genetik algoritmalar gibi ileri teknikler yoluyla optimize edilmesi, model performansını daha da artırabilir. Keşif için başka bir yol, daha kapsamlı bir teşhis aracı oluşturmak için görüntüleme verilerinin genetik veya histopatolojik bilgilerle birleştirilmesi gibi çok modlu verilerin dahil edilmesidir. Son olarak, modeli gerçek dünyadaki klinik ortamlarda uygulamak ve farklı hasta popülasyonlarındaki etkinliğini değerlendirmek, genelleştirilebilirliği ve pratik uygulanabilirliği konusunda değerli bilgiler sağlayabilir. Ayrıca, evrişimli sinir ağı yönteminin uygulanması için bir cihaz geliştirilebilir. Bu modelleme ile diğer kanser timörlerinin yerlerini optimum düzeyde belirlemek için uygulanabilir.

KAYNAKLAR

- Abdallah, N., Marion, J. M., Oueidat, M., & Chauvet, P. (2022). Lung and colon cancer classification using medical imaging: a feature engineering approach. *Physical and Engineering Sciences in Medicine*, 45(3), 729-746. <https://doi.org/10.1007/s13246-022-01139-x>
- Abdoun, N., Assaf, R., Belghith, S., Déforges, O., El Assad, S., & Khalil, M. (2018). Design and implementation of robust Keyed Hash functions based on Chaotic Neural Network.
- Achilli, P., Crippa, J., Grass, F., Mathis, K. L., D'Angelo, A. L. D., Abd El Aziz, M. A., ... & Larson, D. W. (2021). Survival impact of adjuvant chemotherapy in patients with stage IIA colon cancer: analysis of the National Cancer Database. *International Journal of Cancer*, 148(1), 161-169. <https://doi.org/10.1002/ijc.33203>
- Ahmed, S., Frikha, M., Hussein, T. D. H., & Rahebi, J. (2021). Optimum feature selection with particle swarm optimization to face recognition system using Gabor wavelet transform and deep learning. *BioMed Research International*, 2021, 1-13. <https://doi.org/10.1155/2021/6621540>
- Ahmed, S., Frikha, M., Hussein, T. D. H., & Rahebi, J. (2021, June). Face recognition system using histograms of oriented gradients and convolutional neural network based on with particle swarm optimization. In *2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)* (pp. 1-5). IEEE. [10.1109/ICECCE52056.2021.9514139](https://doi.org/10.1109/ICECCE52056.2021.9514139)
- Al Shalchi, N. F. A., & Rahebi, J. (2022). Human retinal optic disc detection with grasshopper optimization algorithm. *Multimedia Tools and Applications*, 81(17), 24937-24955. <https://doi.org/10.1007/s11042-022-12838-8>
- Alam, J., Alam, S., & Hossan, A. (2018, February). Multi-stage lung cancer detection and prediction using multi-class svm classifie. In *2018 International conference on computer, communication, chemical, material and electronic engineering (IC4ME2)* (pp. 1-4). IEEE. [10.1109/IC4ME2.2018.8465593](https://doi.org/10.1109/IC4ME2.2018.8465593)
- Al-Rahlawee, A. T. H., & Rahebi, J. (2021). Multilevel thresholding of images with improved Otsu thresholding by black widow optimization algorithm. *Multimedia Tools and Applications*, 80(18), 28217-28243. [10.1007/s11042-021-10860-w](https://doi.org/10.1007/s11042-021-10860-w)
- Al-Safi, H., Munilla, J., & Rahebi, J. (2021, December). Harris hawks optimization (HHO) algorithm based on artificial neural network for heart disease diagnosis. In *2021 IEEE International Conference on Mobile Networks*

- and *Wireless Communications (ICMNBC)* (pp. 1-5). IEEE. [10.1109/ICMNBC52512.2021.9688348](https://doi.org/10.1109/ICMNBC52512.2021.9688348)
- Al-Safi, H., Munilla, J., & Rahebi, J. (2022). Patient privacy in smart cities by blockchain technology and feature selection with Harris Hawks Optimization (HHO) algorithm and machine learning. *Multimedia Tools and Applications*, 81(6), 8719-8743. [10.1007/s11042-022-12164-z](https://doi.org/10.1007/s11042-022-12164-z)
- Amponsah, A. A., Han, F., Ling, Q. H., & Kudjo, P. K. (2021). An enhanced class topper algorithm based on particle swarm optimizer for global optimization. *Applied Intelligence*, 51, 1022-1040. [10.1007/s10489-020-01856-4](https://doi.org/10.1007/s10489-020-01856-4)
- Ashraf, A., Naz, S., Shirazi, S. H., Razzak, I., & Parsad, M. (2021). Deep transfer learning for alzheimer neurological disorder detection. *Multimedia Tools and Applications*, 1-26. <https://doi.org/10.1155/2021/5425569>
- Ataka, R., Tanaka, H., Yagi, S., Yamane, K., Yoshino, K., Miyauchi, T., ... & Uemoto, S. (2020). Eosinophilic peritonitis with colon cancer: a case report. *BMC gastroenterology*, 20(1), 1-7. [10.1186/s12876-020-01500-y](https://doi.org/10.1186/s12876-020-01500-y)
- Bazazeh, D., & Shubair, R. (2016, December). Comparative study of machine learning algorithms for breast cancer detection and diagnosis. In *2016 5th international conference on electronic devices, systems and applications (ICEDSA)* (pp. 1-4). IEEE. [10.1109/ICEDSA.2016.7818560](https://doi.org/10.1109/ICEDSA.2016.7818560)
- Beni, G. (2020). Swarm intelligence. *Complex Social and Behavioral Systems: Game Theory and Agent-Based Models*, 791-818. https://doi.org/10.1007/978-3-642-27737-5_530-5
- Borkowski, A. A., Bui, M. M., Thomas, L. B., Wilson, C. P., DeLand, L. A., & Mastorides, S. M. (2019). Lung and colon cancer histopathological image dataset (lc25000). *arXiv preprint arXiv:1912.12142*. <https://doi.org/10.48550/arXiv.1912.12142>
- Bukhari, S. U. K., Syed, A., Bokhari, S. K. A., Hussain, S. S., Armaghan, S. U., & Shah, S. S. H. (2020). The histological diagnosis of colonic adenocarcinoma by applying partial self supervised learning. *MedRxiv*, 2020-08. <https://doi.org/10.1101/2020.08.15.20175760>
- Burggraaff, J., Liu, Y., Prieto, J. C., Simoes, J., de Sitter, A., Ruggieri, S., ... & MAGNIMS Study Group. (2021). Manual and automated tissue segmentation confirm the impact of thalamus atrophy on cognition in multiple sclerosis: A multicenter study. *NeuroImage: Clinical*, 29, 102549. <https://doi.org/10.1016/j.nicl.2020.102549>
- Catalano, O. A., Lee, S. I., Parente, C., Cauley, C., Furtado, F. S., Striar, R., ... & Rosen, B. (2021). Improving staging of rectal cancer in the pelvis: the role of PET/MRI. *European Journal of Nuclear Medicine and Molecular Imaging*, 48, 1235-1245. <https://doi.org/10.1007/s00259-020-05036-x>

- Chiang, T. C., Huang, Y. S., Chen, R. T., Huang, C. S., & Chang, R. F. (2018). Tumor detection in automated breast ultrasound using 3-D CNN and prioritized candidate aggregation. *IEEE transactions on medical imaging*, 38(1), 240-249. [10.1109/TMI.2018.2860257](https://doi.org/10.1109/TMI.2018.2860257)
- D'Souza, N., Lord, A. C., Shaw, A., Patel, A., Balyasnikova, S., Tudyka, V., ... & Brown, G. (2020). Ex vivo specimen MRI and pathology confirm a rectosigmoid mesenteric waist at the junction of the mesorectum and mesocolon. *Colorectal Disease*, 22(2), 212-218. <https://doi.org/10.1111/codi.14856>
- Daye, D., Tabari, A., Kim, H., Chang, K., Kamran, S. C., Hong, T. S., ... & Gee, M. S. (2021). Quantitative tumor heterogeneity MRI profiling improves machine learning-based prognostication in patients with metastatic colon cancer. *European Radiology*, 31, 5759-5767. [10.1007/s00330-020-07673-0](https://doi.org/10.1007/s00330-020-07673-0)
- Dorigo, M., Birattari, M., & Stutzle, T. (2006). Ant colony optimization. *IEEE Computational Intelligence Magazine*, 1(4), 28-39. [10.1109/MCI.2006.329691](https://doi.org/10.1109/MCI.2006.329691)
- Fernandez-Viagas, V., Ruiz, R., & Framinan, J. M. (2017). A new vision of approximate methods for the permutation flowshop to minimise makespan: State-of-the-art and computational evaluation. *European Journal of Operational Research*, 257(3), 707-721. <https://doi.org/10.1016/j.ejor.2016.09.055>
- Glorot, X., & Bengio, Y. (2010, March). Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics* (pp. 249-256). JMLR Workshop and Conference Proceedings. <http://proceedings.mlr.press/v9/glorot10a.html>
- Godkhindi, A. M., & Gowda, R. M. (2017, August). Automated detection of polyps in CT colonography images using deep learning algorithms in colon cancer diagnosis. In *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)* (pp. 1722-1728). IEEE. [10.1109/ICECDS.2017.8389744](https://doi.org/10.1109/ICECDS.2017.8389744)
- Gonzalez, Y., Shen, C., Jung, H., Nguyen, D., Jiang, S. B., Albuquerque, K., & Jia, X. (2021). Semi-automatic sigmoid colon segmentation in CT for radiation therapy treatment planning via an iterative 2.5-D deep learning approach. *Medical image analysis*, 68, 101896. <https://doi.org/10.1016/j.media.2020.101896>
- Gopalakrishnan, K., Khaitan, S. K., Choudhary, A., & Agrawal, A. (2017). Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection. *Construction and building materials*, 157, 322-330. <https://doi.org/10.1016/j.conbuildmat.2017.09.110>

- Gopi, A., & Reshmi, C. S. (2017, March). A noninvasive cancer detection using hyperspectral images. In *2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)* (pp. 2051-2055). IEEE. [10.1109/WiSPNET.2017.8300122](https://doi.org/10.1109/WiSPNET.2017.8300122)
- Grass, F., Behm, K. T., Duchalais, E., Crippa, J., Spears, G. M., Harmsen, W. S., ... & Larson, D. W. (2020). Impact of delay to surgery on survival in stage I-III colon cancer. *European Journal of Surgical Oncology*, 46(3), 455-461. <https://doi.org/10.1016/j.ejso.2019.11.513>
- Hadiyoso, S., Aulia, S., & Irawati, I. D. (2023). Diagnosis of lung and colon cancer based on clinical pathology images using convolutional neural network and CLAHE framework. *International Journal of Applied Science and Engineering*, 20(1), 1-7. [https://doi.org/10.6703/IJASE.202303_20\(1\).006](https://doi.org/10.6703/IJASE.202303_20(1).006)
- Hassan, R., Cohanin, B., De Weck, O., & Venter, G. (2005, April). A comparison of particle swarm optimization and the genetic algorithm. In *46th AIAA/ASME/ASCE/AHS/ASC structures, structural dynamics and materials conference* (p. 1897). <https://doi.org/10.2514/6.2005-1897>
- Hecht-Nielsen, R. (1992). Theory of the backpropagation neural network. In *Neural networks for perception* (pp. 65-93). Academic Press. <https://doi.org/10.1016/B978-0-12-741252-8.50010-8>
- Iswisi, A. F., Karan, O., & Rahebi, J. (2021). Diagnosis of multiple sclerosis disease in brain magnetic resonance imaging based on the Harris hawks optimization algorithm. *BioMed Research International*, 2021. <https://doi.org/10.1155/2021/3248834>
- Javan, N. A., Jebreili, A., Mozafari, B., Hosseinioun, M., & Ghahramani, S. (2021). Classification and Segmentation of Pulmonary Lesions in CT Images Using a Combined VGG-XGBoost Method, and an Integrated Fuzzy Clustering-Level Set Technique. *arXiv preprint arXiv:2101.00948*. <https://doi.org/10.48550/arXiv.2101.00948>
- Jerebko, A. K., Malley, J. D., Franaszek, M., & Summers, R. M. (2005). Support vector machines committee classification method for computer-aided polyp detection in CT colonography1. *Academic Radiology*, 12(4), 479-486. <https://doi.org/10.1016/j.acra.2004.04.024>
- Jia, X., Xing, X., Yuan, Y., Xing, L., & Meng, M. Q. H. (2019). Wireless capsule endoscopy: A new tool for cancer screening in the colon with deep-learning-based polyp recognition. *Proceedings of the IEEE*, 108(1), 178-197. [10.1109/JPROC.2019.2950506](https://doi.org/10.1109/JPROC.2019.2950506)
- Kanan, H. R., Faez, K., & Taheri, S. M. (2007). Feature selection using ant colony optimization (ACO): a new method and comparative study in the application of face recognition system. In *Advances in Data Mining. Theoretical Aspects and Applications: 7th Industrial Conference, ICDM 2007, Leipzig, Germany, July 14-18, 2007. Proceedings 7* (pp. 63-76).

Springer Berlin Heidelberg.

- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. <https://doi.org/10.48550/arXiv.1412.6980>
- Konda, K. R. (2016). *Unsupervised relational feature learning for vision* [Doctoral dissertation, Universitätsbibliothek Johann Christian Senckenberg].
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Leavesley, S. J., Deal, J., Hill, S., Martin, W. A., Lall, M., Lopez, C., ... & Boudreaux, C. W. (2018, February). Colorectal cancer detection by hyperspectral imaging using fluorescence excitation scanning. In *Optical Biopsy XVI: Toward Real-Time Spectroscopic Imaging and Diagnosis* (Vol. 10489, pp. 72-78). SPIE. <https://doi.org/10.1117/12.2290696>
- Leavesley, S. J., Walters, M., Lopez, C., Baker, T., Favreau, P. F., Rich, T. C., ... & Boudreaux, C. W. (2016). Hyperspectral imaging fluorescence excitation scanning for colon cancer detection. *Journal of biomedical optics*, 21(10), 104003-104003. <https://doi.org/10.1117/1.JBO.21.10.104003>
- Lu, G., & Fei, B. (2014). Medical hyperspectral imaging: a review. *Journal of biomedical optics*, 19(1), 010901-010901. <https://doi.org/10.1117/1.JBO.19.1.010901>
- Lu, G., Halig, L., Wang, D., Qin, X., Chen, Z. G., & Fei, B. (2014). Spectral-spatial classification for noninvasive cancer detection using hyperspectral imaging. *Journal of biomedical optics*, 19(10), 106004-106004. <https://doi.org/10.1117/1.JBO.19.10.106004>
- Luo, C., Cen, S., Ding, G., & Wu, W. (2019). Mucinous colorectal adenocarcinoma: clinical pathology and treatment options. *Cancer communications*, 39(1), 1-13. <https://doi.org/10.1186/s40880-019-0361-0>
- Ma, L., Lu, G., Wang, D., Wang, X., Chen, Z. G., Muller, S., ... & Fei, B. (2017, March). Deep learning based classification for head and neck cancer detection with hyperspectral imaging in an animal model. In *Medical imaging 2017: Biomedical applications in molecular, structural, and functional imaging* (Vol. 10137, pp. 632-639). SPIE. <https://doi.org/10.1117/12.2255562>
- Mangal, S., Chaurasia, A., & Khajanchi, A. (2020). Convolution neural networks for diagnosing colon and lung cancer histopathological images. *arXiv preprint arXiv:2009.03878*. <https://doi.org/10.48550/arXiv.2009.03878>
- Masud, M., Sikder, N., Nahid, A. A., Bairagi, A. K., & AlZain, M. A. (2021). A machine learning approach to diagnosing lung and colon cancer using a deep learning-based classification framework. *Sensors*, 21(3), 748.

<https://doi.org/10.3390/s21030748>

- Mehmood, S., Ghazal, T. M., Khan, M. A., Zubair, M., Naseem, M. T., Faiz, T., & Ahmad, M. (2022). Malignancy detection in lung and colon histopathology images using transfer learning with class selective image processing. *IEEE Access*, 10, 25657-25668. [10.1109/ACCESS.2022.3150924](https://doi.org/10.1109/ACCESS.2022.3150924)
- Miikkulainen, R. (2019). Evolving deep neural networks. *Artificial intelligence in the age of neural networks and brain computing* (pp. 293-312). Elsevier.
- Mukku, M. (2019). Evolving Deep Neural Networks. <http://hdl.handle.net/10263/7262>
- Naga Raju, M. S., & Srinivasa Rao, B. (2023). Lung and colon cancer classification using hybrid principle component analysis network-extreme learning machine. *Concurrency and Computation: Practice and Experience*, 35(1), e7361. <https://doi.org/10.1002/cpe.7361>
- Nathan, M., Kabatznik, A. S., & Mahmood, A. (2018, April). Hyperspectral imaging for cancer detection and classification. In *2018 3rd Biennial South African Biomedical Engineering Conference (SAIBMEC)* (pp. 1-4). IEEE. [10.1109/SAIBMEC.2018.8363180](https://doi.org/10.1109/SAIBMEC.2018.8363180)
- Nguyen, B. H., Xue, B., & Zhang, M. (2020). A survey on swarm intelligence approaches to feature selection in data mining. *Swarm and Evolutionary Computation*, 54, 100663. <https://doi.org/10.1016/j.swevo.2020.100663>
- Pacal, I., Karaboga, D., Basturk, A., Akay, B., & Nalbantoglu, U. (2020). A comprehensive review of deep learning in colon cancer. *Computers in Biology and Medicine*, 126, 104003. <https://doi.org/10.1016/j.compbiomed.2020.104003>
- Pagès, F., Mlecnik, B., Marliot, F., Bindea, G., Ou, F. S., Bifulco, C., ... & Galon, J. (2018). International validation of the consensus Immunoscore for the classification of colon cancer: a prognostic and accuracy study. *The Lancet*, 391(10135), 2128-2139. [https://doi.org/10.1016/S0140-6736\(18\)30789-X](https://doi.org/10.1016/S0140-6736(18)30789-X)
- Patibandla, R. L., & Narayana, V. L. (2021). Computational intelligence approach for prediction of COVID-19 using particle swarm optimization. *Computational Intelligence Methods in COVID-19: Surveillance, Prevention, Prediction and Diagnosis*, 175-189.
- Poudel, S., Kim, Y. J., Vo, D. M., & Lee, S. W. (2020). Colorectal disease classification using efficiently scaled dilation in convolutional neural network. *IEEE Access*, 8, 99227-99238. [10.1109/ACCESS.2020.2996770](https://doi.org/10.1109/ACCESS.2020.2996770)
- Provath, M.A.M., Deb, K., & Hyun, K. (2023) *Classification of Lung and Colon Cancer Using Deep Learning Method*. Springer

- Qi, L., Ke, J., Yu, Z., Cao, Y., Lai, Y., Chen, Y., ... & Wang, X. (2021). Identification of prognostic spatial organization features in colorectal cancer microenvironment using deep learning on histopathology images. *Medicine in Omics*, 2, 100008. <https://doi.org/10.1016/j.meomic.2021.100008>
- Rahebi, J. (2023). Fishier mantis optimiser: a swarm intelligence algorithm for clustering images of COVID-19 pandemic. *International Journal of Nanotechnology*, 20(1-4), 25-49. <https://doi.org/10.1504/IJNT.2023.131111>
- Rathore, S., Hussain, M., Ali, A., & Khan, A. (2013). A recent survey on colon cancer detection techniques. *IEEE/ACM Transactions on computational biology and bioinformatics*, 10(3), 545-563. [10.1109/TCBB.2013.84](https://doi.org/10.1109/TCBB.2013.84)
- Ravishankar, H., Sudhakar, P., Venkataramani, R., Thiruvankadam, S., Annangi, P., Babu, N., & Vaidya, V. (2016). Understanding the mechanisms of deep transfer learning for medical images. In *Deep Learning and Data Labeling for Medical Applications: First International Workshop, LABELS 2016, and Second International Workshop, DLMIA 2016, Held in Conjunction with MICCAI 2016, Athens, Greece, October 21, 2016, Proceedings 1* (pp. 188-196). Springer International Publishing.
- Richards, S., Walker, J., Nakanishi, M., Belghasem, M., Lyle, C., Arinze, N., ... & Chitalia, V. C. (2020). Haploinsufficiency of Casitas B-Lineage Lymphoma Augments the Progression of Colon Cancer in the Background of Adenomatous Polyposis Coli Inactivation. *The American Journal of Pathology*, 190(3), 602-613. <https://doi.org/10.1016/j.ajpath.2019.10.024>
- Saremi, S., Mirjalili, S., & Lewis, A. (2017). Grasshopper optimisation algorithm: theory and application. *Advances in engineering software*, 105, 30-47. <https://doi.org/10.1016/j.advengsoft.2017.01.004>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Sethi, I. K., & Jain, A. K. (Eds.). (2014). *Artificial neural networks and statistical pattern recognition: old and new connections*. Elsevier.
- Shang, Y., Zhang, X., Lu, L., Jiang, K., Krohn, M., Matschos, S., ... & Linnebacher, M. (2021). Pharmaceutical immunoglobulin G impairs anti-carcinoma activity of oxaliplatin in colon cancer cells. *British Journal of Cancer*, 124(8), 1411-1420. [10.1038/s41416-021-01272-6](https://doi.org/10.1038/s41416-021-01272-6)
- Shin, H. C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., ... & Summers, R. M. (2016). Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE transactions on medical imaging*, 35(5), 1285-1298. [10.1109/TMI.2016.2528162](https://doi.org/10.1109/TMI.2016.2528162)
- Shin, Y., & Balasingham, I. (2017, July). Comparison of hand-craft feature based

- SVM and CNN based deep learning framework for automatic polyp classification. In *2017 39th annual international conference of the IEEE engineering in medicine and biology society (EMBC)* (pp. 3277-3280). IEEE. [10.1109/EMBC.2017.8037556](https://doi.org/10.1109/EMBC.2017.8037556)
- Stephen, O., & Sain, M. (2023). Using Deep Learning with Bayesian–Gaussian Inspired Convolutional Neural Architectural Search for Cancer Recognition and Classification from Histopathological Image Frames. *Journal of Healthcare Engineering*, 2023. <https://doi.org/10.1155/2023/4597445>
- Stidham, R. W., Liu, W., Bishu, S., Rice, M. D., Higgins, P. D., Zhu, J., ... & Waljee, A. K. (2019). Performance of a deep learning model vs human reviewers in grading endoscopic disease severity of patients with ulcerative colitis. *JAMA network open*, 2(5), e193963-e193963. [10.1001/jamanetworkopen.2019.3963](https://doi.org/10.1001/jamanetworkopen.2019.3963)
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826). [10.1109/CVPR.2016.308](https://doi.org/10.1109/CVPR.2016.308)
- Tabakhi, S., Moradi, P., & Akhlaghian, F. (2014). An unsupervised feature selection algorithm based on ant colony optimization. *Engineering Applications of Artificial Intelligence*, 32, 112-123. <https://doi.org/10.1016/j.engappai.2014.03.007>
- Tam Cho, W. K. (2018). An evolutionary algorithm for subset selection in causal inference models. *Journal of the Operational Research Society*, 69(4), 630-644. <https://doi.org/10.1057/s41274-017-0258-8>
- Tan, Y. J., Sim, K. S., & Ting, F. F. (2017, November). Breast cancer detection using convolutional neural networks for mammogram imaging system. In *2017 International Conference on Robotics, Automation and Sciences (ICORAS)* (pp. 1-5). IEEE. [10.1109/ICORAS.2017.8308076](https://doi.org/10.1109/ICORAS.2017.8308076)
- Too, J., Abdullah, A. R., & Mohd Saad, N. (2019, May). A new co-evolution binary particle swarm optimization with multiple inertia weight strategy for feature selection. In *Informatics* (Vol. 6, No. 2, p. 21). MDPI. <https://doi.org/10.3390/informatics6020021>
- Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264). IGI global. <https://doi.org/10.4018/978-1-60566-766-9.ch011>
- Tulum, G., Osman, O., Bolat, B., Dandin, Ö., Ergin, T., & Cüce, F. (2019, April). Colonic polyp classification using projection image and convolutional neural network. In *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)* (pp. 1-4). IEEE.

- Turčaník, M. (2017, October). Hash function generation based on neural networks and chaotic maps. In *2017 Communication and Information Technologies (KIT)* (pp. 1-5). IEEE. [10.23919/KIT.2017.8109467](https://doi.org/10.23919/KIT.2017.8109467)
- Turčaník, M., & Javurek, M. (2016, October). Hash function generation by neural network. In *2016 New Trends in Signal Processing (NTSP)* (pp. 1-5). IEEE. [10.1109/NTSP.2016.7747793](https://doi.org/10.1109/NTSP.2016.7747793)
- Viji, C., Rajkumar, N., Suganthi, S. T., Venkatachalam, K., & Pandiyan, S. (2021). RETRACTED ARTICLE: An improved approach for automatic spine canal segmentation using probabilistic boosting tree (PBT) with fuzzy support vector machine. *Journal of Ambient Intelligence and Humanized Computing*, 12(6), 6527-6536. [10.1007/s12652-020-02267-6](https://doi.org/10.1007/s12652-020-02267-6)
- Xu, B., Wang, N., Chen, T., & Li, M. (2015). Empirical evaluation of rectified activations in convolutional network. *arXiv preprint arXiv:1505.00853*. <https://doi.org/10.48550/arXiv.1505.00853>
- Yin, X., Yu, X., Sohn, K., Liu, X., & Chandraker, M. (2019). Feature transfer learning for face recognition with under-represented data. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 5704-5713). [10.1109/CVPR.2019.00585](https://doi.org/10.1109/CVPR.2019.00585)
- Yu, L., & Liu, H. (2004). Efficient feature selection via analysis of relevance and redundancy. *The Journal of Machine Learning Research*, 5, 1205-1224.
- Yu, Y., Lin, H., Meng, J., Wei, X., Guo, H., & Zhao, Z. (2017). Deep transfer learning for modality classification of medical images. *Information*, 8(3), 91. <https://doi.org/10.3390/info8030091>
- Zhang, D., Huang, G., Zhang, Q., Han, J., Han, J., & Yu, Y. (2021). Cross-modality deep feature learning for brain tumor segmentation. *Pattern Recognition*, 110, 107562. <https://doi.org/10.1016/j.patcog.2020.107562>
- Zhang, R., Zheng, Y., Mak, T. W. C., Yu, R., Wong, S. H., Lau, J. Y., & Poon, C. C. (2016). Automatic detection and classification of colorectal polyps by transferring low-level CNN features from nonmedical domain. *IEEE journal of biomedical and health informatics*, 21(1), 41-47. [10.1109/JBHI.2016.2635662](https://doi.org/10.1109/JBHI.2016.2635662)
- Zhang, Y., & Jin, Z. (2020). Group teaching optimization algorithm: A novel metaheuristic method for solving global optimization problems. *Expert Systems with Applications*, 148, 113246. <https://doi.org/10.1016/j.eswa.2020.113246>
- Zhao, B., Gabriel, R. A., Vaida, F., Eisenstein, S., Schnickel, G. T., Sicklick, J. K., & Clary, B. M. (2020). Using machine learning to construct nomograms for patients with metastatic colon cancer. *Colorectal Disease*, 22(8), 914-922. <https://doi.org/10.1111/codi.14991>