



T.C.  
NECMETTİN ERBAKAN  
ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



**BİYOMEDİKAL GÖRÜNTÜLERDE CNN  
HİPERPARAMETRE OPTİMİZASYONU**

**Abdurrahman AVCI**

**YÜKSEK LİSANS TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Şubat-2025  
KONYA  
Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Abdurrahman Avcı tarafından hazırlanan “Biyomedikal Görüntülerde CNN Hiperparametre Optimizasyonu” adlı tez çalışması 06/02/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Prof. Dr. Sabri KOÇER

#### Danışman

Dr. Öğr. Üyesi Murat KARAKOYUN

#### Üye

Dr. Öğr. Üyesi Vahit TONGUR

### İmza

.....

.....

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun ....../.../20.. gün ve ..... sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY  
FBE Müdürü

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Abdurrahman AVCI

Tarih: 06/02/2025

## ÖZET

### YÜKSEK LİSANS TEZİ

## BİYOMEDİKAL GÖRÜNTÜLERDE CNN HİPERPARAMETRE OPTİMİZASYONU

Abdurrahman AVCI

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Murat KARAKOYUN

2025, 63 Sayfa

Jüri

Dr. Öğr. Üyesi Murat KARAKOYUN  
Prof. Dr. Sabri KOÇER  
Dr. Öğr. Üyesi Vahit TONGUR

Günümüzde derin öğrenme, biyomedikal alanda tıbbi görüntü analizi, hastalık teşhisi, genetik analiz, ilaç keşfi, klinik karar destek sistemleri, hasta monitörizasyonu, hastalık sınıflandırması ve halk sağlığı gibi birçok alanda yaygın olarak kullanılmaktadır. Bu tezde, derin öğrenme modellerinin performansını artırmak amacıyla hiperparametre optimizasyonu üzerinde çalışılmıştır. Hiperparametre optimizasyonu, modelin en iyi performansı elde etmesi için gerekli olan parametrelerin en iyi değerlerini belirlemeyi amaçlayan kritik bir süreçtir. Bu sürecin doğru bir şekilde yönetilmesi, modelin doğruluğunu ve genel etkinliğini önemli ölçüde artırabilir. Çalışmada, biyomedikal görüntülerde Evrişimli Sinir Ağı (CNN) derin öğrenme modellerinin hiperparametre optimizasyonu için Deniz Yırtıcıları Algoritması (MPA) kullanılmıştır. Tez çalışmasında, göğüs röntgeni (normal/zatüre) ve beyin MR görüntüleri (normal/tümörlü) üzerinde altı farklı derin öğrenme modelinin (VGG16, ResNet50V2, InceptionV3, VGG19, MobileNetV2 ve DenseNet121) hiperparametrelerinin optimizasyonu gerçekleştirilmiştir. Her model için beş kritik hiperparametre (öğrenme oranı, optimizasyon fonksiyonu, parti boyutu, nöron düşürme oranı ve epoch sayısı) MPA algoritması kullanılarak optimize edilmiş, optimizasyon süreci 20 ve 30 popülasyon büyüklüğü ile yürütülmüş ve transfer öğrenme yaklaşımı uygulanmıştır. Özellikle, göğüs röntgeni veri setinde ResNet50V2 modeli %92.47'lik en yüksek doğruluk değerine ulaşırken, beyin MR veri setinde yine ResNet50V2 modeli %99.24'lük bir doğruluk değeri elde etmiştir. Göğüs röntgeni veri setinde en yüksek iyileşmeyi VGG16 modeli göstermiştir. Başlangıç doğruluk değeri %86.21 olan model, optimizasyon sonrası %90.22'e ulaşarak yaklaşık %4.01'lik bir iyileşme sağlamıştır. En düşük iyileşmeyi ise DenseNet121 modeli göstermiş olup, %88.78'den %90.54'e yükselerek %1.76'luk bir iyileşme kaydetmiştir. Beyin MR veri setinde en yüksek iyileşmeyi yine VGG16 modeli göstermiştir. Başlangıç doğruluk değeri %94.99 olan model, optimizasyon sonrası %97.30'a ulaşarak yaklaşık %2.31'lik bir iyileşme sağlamıştır. En düşük iyileşmeyi ise MobileNetV2 modeli göstermiş olup, %98.52'den %99.21'e yükselerek %0.69'luk bir iyileşme kaydetmiştir.

**Anahtar Kelimeler:** Biyomedikal Görüntü, Deniz Yırtıcıları Algoritması, Derin Öğrenme, Evrişimli Sinir Ağı, Hiperparametre Optimizasyonu, Transfer Öğrenme

## **ABSTRACT**

### **MS THESIS**

## **CNN HYPERPARAMETER OPTIMIZATION IN BIOMEDICAL IMAGES**

**Abdurrahman AVCI**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
NECMETTİN ERBAKAN UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE  
IN COMPUTER ENGINEERING**

**Advisor: Asst. Prof. Dr. Murat KARAKOYUN**

**2025, 63 Pages**

### **Jury**

**Asst. Prof. Dr. Murat KARAKOYUN**

**Prof. Dr. Sabri KOÇER**

**Asst. Prof. Dr. Vahit TONGUR**

Today, deep learning is widely used in many areas within the biomedical field, such as medical image analysis, disease diagnosis, genetic analysis, drug discovery, clinical decision support systems, patient monitoring, disease classification, and public health. In this thesis, hyperparameter optimization was conducted to improve the performance of deep learning models. Hyperparameter optimization is a critical process that aims to determine the optimal values of parameters necessary for the model to achieve the best performance. Proper management of this process can significantly increase the model's accuracy and overall effectiveness. In the study, the Marine Predators Algorithm (MPA) was used for hyperparameter optimization of Convolutional Neural Network (CNN) deep learning models on biomedical images. In the thesis work, hyperparameter optimization of six different deep learning models (VGG16, ResNet50V2, InceptionV3, VGG19, MobileNetV2, and DenseNet121) was performed on chest X-rays (normal/inflamed) and brain MRI images (normal/tumorous). For each model, five critical hyperparameters (learning rate, optimizer selection, batch size, dropout rate, and number of epochs) were optimized using the MPA algorithm; the optimization process was conducted with population sizes of 20 and 30, and the transfer learning approach was applied. Notably, the ResNet50V2 model achieved the highest accuracy of 92.47% on the chest X-ray dataset, while on the brain MRI dataset, the same model achieved an accuracy of 99.24%. On the chest X-ray dataset, the VGG16 model showed the greatest improvement, increasing from an initial accuracy of 86.21% to 90.22% after optimization, achieving an improvement of approximately 4.01%. The model showing the least improvement was DenseNet121, which increased from 88.78% to 90.54%, recording an improvement of 1.76%. On the brain MRI dataset, the VGG16 model again showed the greatest improvement, increasing from an initial accuracy of 94.99% to 97.30% after optimization, achieving an improvement of approximately 2.31%. The model showing the least improvement was MobileNetV2, which increased from 98.52% to 99.21%, recording an improvement of 0.69%.

**Keywords:** Biomedical Image, Convolutional Neural Networks, Deep Learning, Hyperparameter Optimization, Marine Predators Algorithm, Transfer Learning

## ÖNSÖZ

Yüksek lisans eğitimim boyunca ve tez çalışmamın her aşamasında bilgi ve tecrübesiyle bana yol gösteren, akademik gelişimime katkıda bulunan, her türlü konuda desteğini ve yardımını esirgemeyen değerli danışman hocam Sayın Dr. Öğr. Üyesi Murat KARAKOYUN'a en içten teşekkürlerimi sunarım.

Bu zorlu süreçte her zaman yanımda olan, bana olan inancını hiç kaybetmeyen, sonsuz sevgisi ve desteğiyle bana güç veren, hayatımın her anında olduğu gibi tez çalışmam süresince de sabır ve anlayışla yanımda olan sevgili eşim Tuba AVCI'ya sonsuz teşekkür ederim.

Hayatım boyunca maddi ve manevi desteklerini hiçbir zaman esirgemeyen, her zaman yanımda olan, beni bugünlere getiren ve başarılarımın temel taşı olan sevgili annem Ayşegül ÖZKAĞNICI ve babam Hayrullah AVCI'ya en derin şükranlarımı sunarım.

Hayatımın her döneminde yanımda olan, desteklerini her zaman hissettiğim sevgili kardeşlerim Hüseyin AVCI ve Talha AVCI'ya teşekkürlerimi sunarım.

Abdurrahman AVCI  
KONYA-2025

# İÇİNDEKİLER

<b>ÖZET .....</b>	<b>iv</b>
<b>ABSTRACT.....</b>	<b>v</b>
<b>ÖNSÖZ .....</b>	<b>vi</b>
<b>İÇİNDEKİLER .....</b>	<b>vii</b>
<b>SİMGELER VE KISALTMALAR.....</b>	<b>ix</b>
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1. Tezin Amacı.....	3
2.2. Tezin Önemi .....	3
2.3. Tezin Kapsamı .....	3
2.4. Tez Organizasyonu .....	4
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>5</b>
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>10</b>
3.1. Veri Setleri .....	10
3.1.1. Göğüs Röntgeni Veri Seti .....	10
3.1.2. Beyin MR Veri Seti .....	11
3.2. CNN Modelleri .....	13
3.2.1. InceptionV3 Modeli .....	14
3.2.2. ResNet50V2 Modeli .....	15
3.2.3. VGG-16 Modeli .....	16
3.2.4. VGG-19 Modeli .....	17
3.2.5. MobileNetV2 Modeli.....	18
3.2.6. DenseNet121 Modeli .....	18
3.3. Hiperparametre Optimizasyonu .....	20
3.3.1. Optimize Edilen Hiperparametreler.....	22
3.3.2. Deniz Yırtıcıları Algoritması .....	26
3.4. Performans Metrikleri.....	31
3.4.1. Doğruluk Değeri .....	31
3.4.2. Kayıp Değeri .....	31
3.4.3. Hassasiyet Değeri .....	31
3.4.4. Duyarlılık Değeri .....	32
3.4.5. F1 Skor.....	32
3.4.6. AUC Değeri .....	32
3.5. Deneysel Tasarım .....	33
3.5.1. Donanım ve Yazılım .....	33
3.5.2. Optimizasyon Süreci .....	34
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>36</b>

4.1. Sonular .....	36
4.1.1. Gğs Rntgeni Veri Seti İin Sonular.....	36
4.1.2. Beyin MR Veri Seti İin Sonular.....	46
<b>5. SONULAR VE NERİLER .....</b>	<b>56</b>
5.1 Sonular .....	56
5.2 neriler .....	57
<b>6. KAYNAKLAR .....</b>	<b>59</b>



## SİMGELER VE KISALTMALAR

### Kısaltmalar

CNN	Convolution Neural Network
MPA	Marine Predators Algorithm
PSO	Particle Swarm Optimization
GWO	Grey Wolf Optimizer
GA	Genetic Algorithm
LGBM	Light Gradient Boost Machine
DNN	Deep Neural Network
IWOA	Improved Whale Optimization Algorithm
RBNN	Radial Basis Artificial Neural Network
MR	Magnetic Resonance
OBL	Opposition-Based Learning
GSA	Gravitational Search Algorithm
HHO	Harris Hawks Optimization
WOA	Whale Optimization Algorithm
DWLSSA	Discrete Salp Swarm Optimization
BCS	Binary Cuckoo Search
BGWO	Binary grey wolf optimization
FFA	Fast Folding Algorithm
BMVO	Binary Multi-Verse Optimization
RBMFO	Rank Based Moth Flame optimisation
MAKHA	Hybrid Monkey Algorithm with Krill Herd Algorithm Optimization
GOA	Gannet Optimization Algorithm
POA	Pelican Optimization Algorithm
GPOA	Gannet Pelican Optimization Algorithm
FA	Firefly Algorithm
DQN	The deep Q-network
EWMA	Exponentially Weighted Moving Average
ACO	Ant colony optimization algorithms
HFB	Hybrid-Flash Butterfly Optimization Algorithm
ILSVRC	ImageNet Large Scale Visual Recognition Challenge
SGD	Stochastic Gradient Descent
ResNet	Residual Networks
ReLU	Rectified Linear Unit
DenseNet	Densely Connected Convolutional Networks
VGG	Visual Geometry Group
AUC	Area Under Curve

## 1. GİRİŞ

Günümüzde derin öğrenme, biyomedikal alanda tıbbi görüntü analizi, hastalık teşhisi, genetik analiz, ilaç keşfi, klinik karar destek sistemleri, hasta monitörizasyonu, hastalık sınıflandırması ve halk sağlığı gibi birçok alanda kullanılmaktadır. Tüm bu uygulamalar, derin öğrenmenin biyomedikal alanda sağlık hizmetlerinin daha hızlı, doğru ve kişiselleştirilmiş bir şekilde sunulmasına olanak tanıyarak hastaların yaşam kalitesini artırmada, sağlık sistemlerinin etkinliğini geliştirmede, hastalıkların erken teşhisinde, tedavi yöntemlerinin geliştirilmesinde ve hasta bakımının iyileştirilmesinde büyük bir potansiyele sahip olduğunu göstermektedir (Haque ve Neubert 2020).

Evrışimli Sinir Ağları (CNN) başta görüntü işleme alanında olmak üzere bilgisayar görmesi, video tanıma, doğal dil işleme ve tıbbi görüntü analizi gibi birçok alanda tercih edilen ve popüler bir derin öğrenme yöntemidir. Yapay sinir ağı insan beyninin bir tür modellenmesi gibi çalışır. CNN yöntemi hayvanların görme merkezinden esinlenmiştir. CNN genellikle girdi, evrişim, ortaklama ve çıktı katmanlarından oluşur. Evrişimsel işlemler, bir nöronun kendi uyarı alanından uyaranlara verdiği cevap olarak düşünülebilir (Fukushima 1980). Sağlık alanında yardımcı ve önerici olması açısından derin öğrenme sıkça kullanılmaya başlanmıştır. CNN de görüntü işlemede ki performansı sayesinde bu alanda kullanılmış ve kullanılmaya devam edilmektedir (Liu vd. 2017).

Biyomedikal alanda CNN, tıbbi görüntü analizi ve teşhis süreçlerinde devrim niteliğinde yenilikler sunmaktadır. CNN, özellikle karmaşık ve yüksek boyutlu tıbbi görüntülerdeki örüntüleri otomatik olarak öğrenme ve sınıflandırma yetenekleri sayesinde, radyoloji ve patoloji gibi alanlarda önemli başarılar elde etmiştir. Litjens vd. (2017), çalışmaları CNN'in tıbbi görüntü analizinde yaygın olarak kullanıldığını ve bu modellerin akciğer nodülleri, beyin tümörleri ve retina hastalıkları gibi çeşitli klinik durumların tespitinde yüksek doğruluk oranlarına ulaştığını göstermektedir. Özellikle U-Net gibi CNN tabanlı mimariler, tıbbi görüntü segmentasyonunda standart hale gelmiş ve birçok klinik uygulamada kullanılmaktadır (Ronneberger vd. 2015). Shen vd. (2017), derin öğrenme tekniklerinin biyomedikal görüntüleme sağladığı avantajları vurgulayarak, bu teknolojilerin teşhis süreçlerini hızlandığını ve doğruluğunu artırdığını belirtmiştir. Bu gelişmeler, CNN'lerin biyomedikal alanda daha çeşitli

uygulamalarda kullanılmasına ve yapay zeka destekli tanı sistemlerinin gelecekte daha yaygın bir şekilde benimsenmesine zemin hazırlamaktadır.

CNN görüntü sınıflandırma ve analizi görevlerinde yaygın olarak kullanılan güçlü derin öğrenme modelleridir. Ancak, bu modellerin performansı büyük ölçüde parametrelerin doğru seçimine bağlıdır. Öğrenme oranı, parti boyutu, optimizasyon fonksiyonu, nöron düşürme oranı ve epoch sayısı gibi kritik parametreler, modelin öğrenme sürecini ve nihai başarısını doğrudan etkilemektedir. Örneğin, çok yüksek bir öğrenme oranı modelin optimal noktayı atlmasına ve yakınsamanın başarısız olmasına neden olabilirken, çok düşük bir öğrenme oranı eğitimin aşırı yavaş ilerlemesine ve lokal minimumlara takılma riskine yol açabilir. CNN'lerin parametrelerinin optimize edilmesi, manuel deneme-yanılma yaklaşımıyla çok zordur. Çünkü parametreler arasındaki karmaşık etkileşimler ve geniş arama uzayı, optimal değerlerin bulunmasını zorlaştırır. Hiperparametre optimizasyonunun önemi, özellikle tıbbi görüntü analizi gibi yüksek doğruluk gerektiren uygulamalarda daha da ortaya çıkmaktadır. Yanlış seçilmiş hiperparametreler, modelin öğrenme sürecini olumsuz etkileyebilir, yanlış sınıflandırmalara yol açabilir ve klinik karar verme süreçlerinde hatalı sonuçlar doğurabilir. Meta-sezgisel optimizasyon algoritmaları gibi yaklaşımlar, optimal hiperparametre değerlerinin belirlenmesinde öne çıkar (Feurer ve Hutter 2019).

Hiperparametre optimizasyonu, makine öğrenmesi ve derin öğrenme modellerinin performansını iyileştirmek için önemli bir süreçtir. CNN için hiperparametre optimizasyonu, modelin performansını artırmak ve daha iyi genelleme yeteneği sağlamak amacıyla kritik bir rol oynamaktadır. Hiperparametre optimizasyon süreci, Grid Search, Random Search, Bayesian Optimizasyon ve meta-sezgisel algoritmalar gibi farklı tekniklerle gerçekleştirilebilir. Meta-sezgisel algoritmalar, karmaşık optimizasyon problemlerinde en iyi sonuca ulaşma yetenekleri, esneklikleri ve geniş bir uygulama alanına sahip olmalarıyla öne çıkar. Bu algoritmalar, doğrusal olmayan ve çok boyutlu problemlerde etkili çözümler sunarak en iyi sonuçları bulma eğilimindedirler (Yang ve Deb 2010). Mohakud ve Dash (2021)'in çalışmasında belirtildiği gibi, öğrenme oranı, parti boyutu, epoch sayısı, katman sayısı ve nöron düşürme oranı gibi hiperparametrelerin manuel olarak ayarlanması oldukça zaman alıcı ve karmaşık bir süreçtir. Wang vd. (2019), Parçacık Sürü Optimizasyonu (PSO) tabanlı bir yaklaşım olan cPSO-CNN'i önererek, CNN hiperparametrelerinin otomatik optimizasyonu için etkili bir çözüm

sunmuşlardır. Litjens vd. (2017), tarafından yapılan kapsamlı bir incelemede, özellikle tıbbi görüntü analizinde, doğru hiperparametre seçiminin modelin başarısında belirleyici rol oynadığı vurgulanmıştır. Bu optimizasyon teknikleri arasında, özellikle doğadan esinlenen algoritmalar (Genetik Algoritma ve PSO gibi), geniş hiperparametre uzayını etkili bir şekilde araştırma ve optimal değerleri bulma konusunda üstün başarı göstermektedir.

### **1.1. Tezin Amacı**

Bu tez çalışmasının temel amacı, biyomedikal görüntülerin sınıflandırılmasında kullanılan derin öğrenme modellerinin performansını hiperparametre optimizasyonu yoluyla iyileştirmektir. Özellikle VGG-16, ResNet50V2, InceptionV3, VGG-19, MobileNetV2 ve DenseNet121 gibi CNN modellerinin hiperparametrelerini optimize ederek, bu modellerin doğruluk ve genelleme yeteneklerini geliştirmek hedeflenmiştir. Bu amaç doğrultusunda, Deniz Yırtıcıları Algoritması kullanılarak hiperparametre optimizasyonunun etkinliği değerlendirilmiş ve farklı CNN mimarilerinin performansları karşılaştırmalı olarak analiz edilmiştir. Optimize edilmiş modellerin klinik uygulamalardaki potansiyel kullanımının değerlendirilmesi de çalışmanın önemli amaçlarından biridir.

### **2.2. Tezin Önemi**

Biyomedikal görüntü analizi, doğru teşhis ve tedavi planlaması için kritik öneme sahiptir. Derin öğrenme modellerinin bu alandaki kullanımı, teşhis süreçlerini hızlandırmakta ve doğruluğunu artırmaktadır. Ancak, bu modellerin performansı büyük ölçüde doğru hiperparametre ayarlarına bağlıdır. Bu araştırma, hiperparametre optimizasyonunun model performansını nasıl etkilediğini göstererek, tıbbi görüntü analizinde daha etkili ve güvenilir yapay zeka sistemlerinin geliştirilmesine katkıda bulunmaktadır. Farklı CNN mimarilerinin biyomedikal görüntü analizindeki etkinliğini karşılaştırmalı olarak ortaya koymaktadır. Ayrıca, Deniz Yırtıcıları Algoritması gibi yeni optimizasyon tekniklerinin uygulanabilirliğini değerlendirerek, literatüre yenilikçi bir bakış açısı kazandırmaktadır.

### **2.3. Tezin Kapsamı**

Çalışma kapsamında, iki farklı tıbbi görüntüleme veri seti (göğüs röntgeni ve beyin MR) üzerinde altı farklı CNN mimarisi incelenmiştir. Deniz Yırtıcıları Algoritması ile gerçekleştirilen hiperparametre optimizasyonu sonucunda, modellerin performansları doğruluk, kayıp, hassasiyet, özgüllük ve F1-skoru metrikleri ile değerlendirilmiş, optimizasyon öncesi ve sonrası performans karşılaştırmaları yapılmıştır. Ancak araştırmanın bazı sınırlılıkları bulunmaktadır. Çalışma yalnızca iki tür tıbbi görüntüleme veri seti ile sınırlı olup, kullanılan veri setlerinin boyutu ve çeşitliliği de kısıtlıdır. Modellerin farklı veri setleri üzerindeki performansı tam olarak değerlendirilememiştir. Hesaplama kaynakları ve zaman kısıtlamaları nedeniyle test edilebilen hiperparametre kombinasyonları sınırlı tutulmuş, sadece belirli CNN mimarileri değerlendirilmiştir. Ayrıca, klinik uygulamada doğrulanması için daha fazla test ve çeşitlilik gereklidir.

#### **2.4. Tez Organizasyonu**

Tez beş ana bölümden oluşmaktadır. Giriş bölümünde araştırmanın amacı, önemi, kapsamı ve sınırlılıkları açıklanmıştır. Kaynak araştırması bölümünde derin öğrenme, CNN mimarileri, hiperparametre optimizasyonu ve biyomedikal görüntü analizi konularında kapsamlı bir literatür taraması sunulmuştur. Materyal ve yöntem bölümünde kullanılan veri setleri, CNN modelleri, Deniz Yırtıcıları Algoritması ve değerlendirme metrikleri detaylı olarak açıklanmıştır. Araştırma sonuçları bölümünde optimizasyon sonuçları, performans karşılaştırmaları ve istatistiksel analizler sunulmuştur. Son olarak, sonuç ve öneriler bölümünde elde edilen bulgular değerlendirilmiştir. Her bölüm, konunun sistematik ve kapsamlı bir şekilde anlaşılmasını sağlayacak şekilde organize edilmiştir.

## 2. KAYNAK ARAŞTIRMASI

Biyomedikal görüntü analizi alanında derin öğrenme ve optimizasyon tekniklerinin kullanımı önemli bir araştırma konusu haline gelmiştir. Bu bölümde, tez çalışmasının temelini oluşturan derin öğrenme, CNN, hiperparametre optimizasyonu, meta-sezgisel algoritmalar ve biyomedikal görüntü analizi konularında kapsamlı bir literatür taraması sunulmuştur.

Makine öğrenmesi algoritmalarının hiperparametrelerini meta-sezgisel optimizasyon yöntemleri kullanarak ayarlamayı amaçlamaktadır. Araştırmacılar, Gri Kurt Optimizasyonu (GWO) ve Genetik Algoritma (GA) meta-sezgisel yöntemlerini kullanarak 11 farklı makine öğrenmesi algoritmasının hiperparametrelerini optimize etmişlerdir. Çalışmada moleküler etkileşimler, kanser, klinik tanı, davranış tahminleri, insan derisi RGB görüntüleri ve Covid-19/kardiyomegali hastalarının X-ray görüntüleri gibi farklı biyolojik ve biyomedikal kategorilerde 11 veri seti kullanılmıştır. Önerilen yöntem, veri setini girdi olarak alıp en iyi keşfedilen algoritmayı ve ilgili argümanları önermektedir. Çalışmada Light Gradient Boost Machine (LGBM), Limited memory BFGS algoritması (Lbfgs), FastTree, FastForest, Averaged Perceptron ve Linear SVM gibi sınıflandırıcılar ile bu algoritmaların regresyon versiyonları kullanılmıştır. Ayrıca dört farklı mimari kullanan bir Derin Sinir Ağı (DNN) algoritması da görüntü sınıflandırma için test edilmiştir. Sonuçlar, tüm denemelerde eğitim aşamasının performansının iyileştirildiğini göstermiştir. GWO,  $2.6E-5$  p-değeri ile daha iyi bir performans sergilemiştir. Ayrıca çalışmanın deney vakalarının çoğunda, meta-sezgisel yöntemler Izgara Aramasına göre daha iyi performans ve daha hızlı yakınsama göstermiştir. Önerilen yöntem, bilinmeyen dağılıma sahip veri setleri, karmaşık davranışlı makine öğrenmesi algoritmaları veya analitik istatistik ve veri bilimi algoritmalarında uzman olmayan kullanıcılar için uygundur (Nematzadeh vd. 2022).

Beyin tümörü sınıflandırması için İyileştirilmiş Balina Optimizasyon Algoritması (IWOA) tabanlı Radyal Sinir Ağı (RBNN) yaklaşımı önerilen çalışmada, üç farklı veri seti üzerinde kapsamlı deneyler gerçekleştirilmiştir. Önerilen sistem, ön işleme, segmentasyon, özellik çıkarımı ve sınıflandırma aşamalarından oluşmaktadır. MR görüntüleri önce gri seviyeye dönüştürülmüş, ardından Bulanık C-Means (FCM) kümeleme kullanılarak tümör bölgesi belirlenmiştir. Özellik çıkarımı aşamasında PCA,

ortalama, entropi ve dalgacık dönüşümü kullanılarak özellikler elde edilmiş, son olarak IWOA ile optimize edilmiş RBNN kullanılarak sınıflandırma yapılmıştır. Sistem, beyin anormalliklerini dört kategoride (tümör, enflamatuar hastalık, inme ve dejeneratif) sınıflandırabilmektedir. Deneysel sonuçlarda önerilen yöntem, maksimum %95.1 doğruluk, %96 hassasiyet, %94.5 özgüllük, %96.1 F1-skor ve %96 kesinlik değerlerine ulaşmıştır. IWOA'nın geleneksel optimizasyon algoritmalarına göre daha hızlı yakınsama ve yüksek doğruluk sağlaması, FCM segmentasyonunun yüksek doğrulukta tümör bölgesi tespiti ve çoklu özellik çıkarım tekniklerinin kombinasyonu, çalışmanın öne çıkan yenilikçi yönleridir. Sonuçlar, önerilen sistemin beyin tümörü sınıflandırmasında mevcut yöntemlere göre daha iyi performans gösterdiğini ortaya koymuştur (Dixit ve Nanda 2022).

Akciğer nodüllerinin tespiti için Gri Kurt Optimizasyonu (GWO) ve Evrişimli Sinir Ağı tabanlı yeni bir yaklaşım önermişlerdir. LIDC-IDRI veri setinden alınan toplam 910 görüntü (250 normal, 320 benign ve 320 malign) üzerinde gerçekleştirilen çalışmada, öncelikle görüntüler GWO algoritması ile optimize edilmiş ağırlıklı filtreler kullanılarak gürültüden arındırılmıştır. Ardından, watershed dönüşümü ve dilatasyon işlemleri kullanılarak segmentasyon gerçekleştirilmiştir. Son aşamada, 13 katmanlı özel bir CNN mimarisi kullanılarak görüntüler normal, benign ve malign olmak üzere üç sınıfta sınıflandırılmıştır. Model, %70 eğitim ve %30 test verisi kullanılarak değerlendirilmiş ve %98.33 doğruluk, %100 hassasiyet ve %93.33 özgüllük değerlerine ulaşmıştır. Önerilen yaklaşım, GWO tabanlı gürültü giderme ile görüntü kalitesinin artırılması, üç sınıflı sınıflandırma ile klinik uygulanabilirlik, yüksek sınıflandırma performansı ve düşük yanlış pozitif oranı gibi önemli katkılar sunmaktadır. Çalışma, akciğer nodüllerinin otomatik tespitinde yüksek doğruluklu ve klinik uygulamalarda kullanılabilir bir yaklaşım ortaya koymaktadır. Geleneksel yöntemlerle karşılaştırıldığında, önerilen model hem doğruluk hem de hesaplama verimliliği açısından üstün performans sergilemiştir. Bu sonuçlar, GWO-CNN tabanlı yaklaşımın akciğer nodüllerinin erken teşhisinde etkili bir araç olarak kullanılabileceğini göstermektedir (Bilal vd. 2022).

Houssein ve arkadaşları, meme kanseri teşhisi için derin öğrenme tabanlı yeni bir sınıflandırma modeli önermektedir. Önerilen model, önceden eğitilmiş bir CNN mimarisi olan ResNet50 ile iyileştirilmiş bir meta-sezgisel optimizasyon algoritmasının (IMPA) hibrit kullanımına dayanmaktadır. Deniz Yırtıcıları Algoritması (MPA), yerel

optimumlara takılmayı önlemek ve sömürüyü iyileştirmek için OBL (Opposition-Based Learning) stratejisi kullanılarak geliştirilmiştir. İyileştirilmiş algoritma (IMPA), ResNet50 mimarisinin hiperparametrelerini optimize etmek için kullanılmış ve IMPA-ResNet50 adı verilen bir model oluşturulmuştur. Model dört ana aşamadan oluşmaktadır: (1) veri ön işleme ve veri artırma, (2) hiperparametre optimizasyonu, (3) öğrenme aşaması ve (4) performans değerlendirmesi. Model, CBIS-DDSM ve MIAS olmak üzere iki mamografi veri seti üzerinde test edilmiştir. CBIS-DDSM veri setinde %98.32 doğruluk, %96.61 hassasiyet ve %98.56 özgüllük elde edilirken, MIAS veri setinde %98.88 doğruluk, %97.61 hassasiyet ve %98.40 özgüllük değerlerine ulaşılmıştır. Önerilen model, orijinal MPA algoritması ve manuel olarak ayarlanmış ResNet50 mimarisi ile karşılaştırıldığında önemli performans artışı göstermiştir. Ayrıca GSA, HHO, WOA gibi diğer meta-sezgisel algoritmalarla yapılan karşılaştırmalarda da üstün sonuçlar elde edilmiştir. Bu sonuçlar, IMPA'nın ResNet50 mimarisinin hiperparametrelerini optimize etmede etkili olduğunu ve meme kanseri teşhisinde yüksek doğrulukta sonuçlar üretebildiğini göstermektedir (Houssein vd. 2022).

Uyku apnesi tespiti için tek kanallı EKG sinyallerini kullanarak Evrişimli Sinir Ağı hiperparametrelerini optimize etmek amacıyla İyileştirilmiş Bal Porsuğu Algoritması (MHBA) geliştirdikleri çalışmalarında, uyku apnesi teşhisinde yeni bir yaklaşım sunmuşlardır. Çalışma, geleneksel polisomnografi yöntemlerinin karmaşıklığını ve maliyetini azaltmak amacıyla, tek kanallı EKG sinyalleri üzerinden uyku apnesi tespiti yapmayı hedeflemektedir. MHBA, üç iyileştirme stratejisi (quasi-opposition öğrenme, elit-rehberli evrim ve adaptif mutasyon) ile zenginleştirilmiş olup, Physionet Apnea ECG veritabanındaki 70 tek kanallı EKG kaydı üzerinde test edilmiştir. Deneysel sonuçlar, önerilen yöntemin %91.3 doğruluk, %97.5 AUC, %93.6 özgüllük ve %90.1 hassasiyet değerleri ile geleneksel CNN ve diğer makine öğrenimi yöntemlerinden daha üstün performans gösterdiğini ortaya koymuştur. Bu çalışma, uyku apnesi tespitinde daha düşük maliyetli ve uygulanabilir bir alternatif sunarken, CNN performansını artırmak için meta-sezgisel algoritmaların etkinliğini de vurgulamaktadır (Abasi vd. 2023).

Parkinson hastalığının tespiti için ayırık salp sürü algoritması (DWLSSA) tabanlı yeni bir sınıflandırma yaklaşımı önerilmiştir. Önerilen model, ağırlıklar ve Lévy uçuşları ile geliştirilmiş bir meta-sezgisel optimizasyon algoritmasının hibrit kullanımına dayanmaktadır. UCI veri tabanından alınan ve 31 bireyin (23'ü Parkinson hastası) ses

verilerinden oluşan toplam 195 ses örneği (48 sağlıklı, 147 hasta) içeren konuşma PD veri seti üzerinde test edilmiştir. Model, DWLSSA algoritması ile özellik seçimi ve Destek Vektör Makinesi (SVM) ile sınıflandırma olmak üzere iki aşamadan oluşmaktadır. Temel SSA algoritmasına, ağırlıklar ile arama uzayının keşif ve sömürü dengesinin iyileştirilmesi ve Lévy uçuşları ile yerel optimumlara takılmanın önlenmesi şeklinde iki önemli geliştirme getirilmiştir. Model performansı çeşitli metriklerle değerlendirilmiş ve %98.75 doğruluk, %98.15 hassasiyet, %97.37 özgüllük, %99.39 kesinlik, %98.77 F-ölçütü ve %97.76 G-ortalama sonuçları elde edilmiştir. DWLSSA algoritması BCS, BGWO, GA, WOA, PSO, FFA, BMVO, RBMFO ve MAKHA gibi diğer meta-sezgisel algoritmalarla karşılaştırıldığında üstün performans göstermiş ve sonuçlar, önerilen yaklaşımın Parkinson hastalığının erken teşhisinde etkili bir araç olarak kullanılabileceğini ortaya koymuştur (Sureja vd. 2023).

Göz dibi görüntülerini kullanarak diyabetik retinopati tespiti için optimizasyon tabanlı bir derin öğrenme yaklaşımı önermişlerdir. Çalışmada, göz dibi görüntüleri önce medyan filtre ve ROI çıkarımı ile ön işleme tabi tutulmuş, ardından U-Net mimarisi kullanılarak lezyon segmentasyonu gerçekleştirilmiştir. U-Net'in eğitimi için Gannet Pelikan Optimizasyon Algoritması (GPOA) geliştirilmiş ve bu algoritma Gannet Optimizasyon Algoritması (GOA) ile Pelikan Optimizasyon Algoritmasının (POA) entegrasyonundan oluşturulmuştur. Segmentasyon sonrası görüntüler çevirme, döndürme, kesme, kırpma ve öteleme gibi veri artırma işlemlerine tabi tutulmuştur. Özellik çıkarımı aşamasında LTP, LGXP, SLBT, texton ve renk histogramı gibi görüntü tabanlı özellikler ile alan, eksantriklik, entropi, basıklık ve çevre gibi vektör tabanlı özellikler çıkarılmıştır. Son olarak, diyabetik retinopati tespiti için Derin Q Ağı (DQN) kullanılmış ve bu ağın eğitimi için Üstel Gannet Ateşböceği Optimizasyon Algoritması (EGFOA) geliştirilmiştir. EGFOA, Üstel Ağırlıklı Hareketli Ortalama (EWMA), GOA ve Ateşböceği Optimizasyon Algoritmasının (FA) birleşiminden oluşmaktadır. Deneysel sonuçlar, önerilen yöntemin %91.6 doğruluk, %92.2 hassasiyet ve %91.9 özgüllük değerlerine ulaştığını göstermiştir (Prabhakar vd. 2024).

Kardiyovasküler hastalıkların (KVH) teşhisi için Karınca Kolonisi Optimizasyonu ve geliştirilmiş derin öğrenme yaklaşımını birleştiren yeni bir model (ICVD-ACOEDL) önermişlerdir. Çalışmada, büyük tıbbi veri setlerinden anlamlı

örüntüler çıkarmak ve KVH'yi güvenilir bir şekilde teşhis etmek amaçlanmıştır. Model, özellik seçimi için Karınca Kolonisi Optimizasyonu (ACO), veri ön işleme için min-max ölçeklendirme ve sınıflandırıcı hiperparametrelerinin optimizasyonu için Bayesian optimizasyonu kullanmaktadır. Kaggle veri deposundan alınan 629 hastalıklı ve 561 normal örnek içeren veri seti üzerinde gerçekleştirilen deneysel çalışmalarda, model %99.71 doğruluk oranına ulaşmıştır. Önerilen yaklaşım, 14 mevcut özellik arasından kalp atış hızı, kolesterol, EKG, ağrı tipi ve dinlenme kan basıncı gibi optimal özellikleri seçerek sınıflandırma performansını artırmıştır. Model, SVM (%85.19), REPTree (%93.41), ANN (%95.95) ve bagging (%95.19) gibi geleneksel yöntemlerle karşılaştırıldığında üstün performans sergilemiştir. Çalışma, KVH teşhisinde yapay zeka destekli sistemlerin klinik karar destek mekanizmalarına entegrasyonu için umut verici bir temel oluşturmaktadır (Xia vd. 2024).

Dermoskopik görüntülerden cilt hastalıklarının sınıflandırılması için yeni bir Hibrit Flash Kelebek Optimizasyonu tabanlı Evrişimli Sinir Ağı ve Çift Yönlü Uzun Kısa Süreli Bellek (HFB-CNN-BiLSTM) yaklaşımı önermişlerdir. Ham 10000 veri setinden alınan toplam 10,015 dermoskopik görüntü üzerinde gerçekleştirilen çalışmada, öncelikle veri artırma teknikleri kullanılarak görüntü sayısı 42,000'e çıkarılmış ve sınıflandırma performansı iyileştirilmiştir. Önerilen model, görüntüleri normal ve anormal (melanom, benign keratoz ve melanositik nevüs) olmak üzere sınıflandırmaktadır. CNN-BiLSTM mimarisi, görüntülerden renk, doku, yapı ve lezyon boyutu gibi özellikleri çıkarmakta ve HFB algoritması ile optimize edilmektedir. MATLAB2018b ortamında test edilen sistem, %96.3 doğruluk, %96.8 hassasiyet, %97.4 F-ölçütü, %96.8 kesinlik ve %97.6 özgüllük değerlerine ulaşmıştır. Model, DL (%95), ARL-CNN (%92.3), IM-CNN (%85.25) ve SPBL (%88.75) gibi mevcut yöntemlerle karşılaştırıldığında üstün performans sergilemiştir. Çalışma, cilt hastalıklarının erken teşhisinde yüksek doğruluk veren bir yaklaşım sunmaktadır (Vidhyalakshmi ve Kanchana 2024).

### 3. MATERYAL VE YÖNTEM

Bu çalışmada, biyomedikal görüntüler üzerinde farklı CNN modellerine Deniz Yırtıcıları Algoritması uygulanarak hiperparametre optimizasyonu yapılmıştır. Çalışma göğüs röntgeni ve beyin MR görüntüleri içeren veri setleri ile yapılmıştır. Bu bölümde çalışmada kullanılan veri setleri, CNN modelleri, optimizasyon algoritması, hiperparametre optimizasyonu, model eğitimi ve değerlendirme metrikleri detaylı bir şekilde ele alınmıştır.

#### 3.1. Veri Setleri

Bu tez çalışmasında, modern tıbbi tanı süreçlerinde kullanılan iki temel görüntüleme yöntemini temsil eden, uluslararası standartlarda iki değerli veri seti kullanılmıştır. Çalışmanın birinci veri kaynağını, Çin'in önde gelen sağlık kurumlarından Guangzhou Women and Children's Medical Center'in klinik arşivlerinden elde edilen, toplam 5,856 adet yüksek çözünürlüklü göğüs röntgeni görüntüsünü içeren "Chest X-Ray Images (Pneumonia)" veri seti oluşturmaktadır. Bu veri seti, normal akciğer dokusuna sahip hastalar ile zatüre vakalarının karşılaştırmalı analizine olanak sağlayan zengin bir görüntü arşivi sunmaktadır (Kermany vd. 2018).

Çalışmanın ikinci veri kaynağı, nörolojik görüntüleme alanında çığır açıcı potansiyele sahip 21,672 adet beyin MR görüntüsünden oluşan "Brain Tumor MRI Dataset"tir. Bu kapsamlı veri seti, farklı tümör tiplerini ve evrelerini içeren, çeşitli kesitsel görüntülerden oluşmaktadır. Her iki veri setinin en önemli özelliklerinden biri, görüntülerin deneyimli radyolog ekipleri tarafından titizlikle incelenmiş, kategorize edilmiş ve çift kontrollü doğrulama süreçlerinden geçirilmiş olmasıdır (Kadam vd. 2021).

##### 3.1.1. Göğüs Röntgeni Veri Seti


Bu veri seti, Guangzhou Women and Children's Medical Center'dan elde edilen ve uzman radyologlar tarafından değerlendirilmiş toplam 5,856 adet yüksek çözünürlüklü pediatrik göğüs röntgeni görüntüsünden oluşmaktadır. Görüntüler, normal akciğer dokusuna sahip hastalar ile bakteriyel ve zatüre vakalarını içermektedir. Veri seti, yapay zeka modellerinin eğitimi için optimize edilmiş bir yapıda düzenlenmiş olup, eğitim

(training), doğrulama (validation) ve test setleri olmak üzere üç ana kategoriye ayrılmıştır. Eğitim seti 5,216 görüntü içermekte olup, bunların 1,341'i normal, 3,875'i zatüre vakalarına aittir. Test seti ise 624 görüntüden oluşmakta, bunların 234'ü normal, 390'ı zatüre vakalarını temsil etmektedir. Doğrulama seti, modellerin performansını değerlendirmek için kullanılan 16 görüntüden oluşmaktadır. Veri setine ait görüntü sayıları Çizelge 3.1' de verilmiştir (Keremany vd. 2018).

**Çizelge 3.1.** Chest X-Ray Pneumonia veri seti dağılımı

Veri Seti	Normal	İltihaplı	Toplam
Eğitim	1341	3875	5216
Test	234	390	624
Doğrulama	8	8	16
<b>Toplam</b>	<b>1583</b>	<b>4273</b>	<b>5856</b>

Tüm görüntüler JPEG formatında olup, anterior-posterior (AP) pozisyonunda çekilmiştir. Veri setine ait bazı görüntüler Şekil 3.1'de verilmiştir. Her bir görüntü, uzman tarafından dikkatle incelenmiş ve etiketlenmiştir. Veri setinin en önemli özelliklerinden biri, gerçek klinik ortamdan elde edilmiş olması ve uzman radyologlar tarafından detaylı şekilde etiketlenmiş olmasıdır.



**Şekil 3.1.** Chest X-Ray Pneumonia veri seti normal ve zatüre görüntü örnekleri

### 3.1.2. Beyin MR Veri Seti

Beyin tümörü veri seti, modern tıbbi görüntüleme ve yapay zeka araştırmaları için özel olarak hazırlanmış, temizlenmiş ve standardize edilmiş bir seti temsil etmektedir. Veri seti, üç farklı tümör kategorisi (Hipofiz, Glioma ve Meningioma) ile birlikte normal beyin MRI görüntülerini içeren dört temel sınıftan oluşmaktadır. Veri setinin en önemli özelliği, diğer Kaggle platformundaki benzer setlerden farklı olarak, kapsamlı bir veri temizleme sürecinden geçirilmiş olmasıdır. Veri setinin oluşturulma sürecinde, görüntü kalitesi ve doğruluğunu en üst düzeye çıkarmak için çeşitli teknikler uygulanmıştır. İlk

olarak, görüntü vektör karşılaştırma yöntemi kullanılarak tekrarlanan örnekler tespit edilmiş ve veri setinden çıkarılmıştır. Tüm görüntüler, akademik standartlara uygun ve bellek açısından verimli olan 224x224 piksel boyutuna yeniden boyutlandırılmıştır. Veri setinin zenginleştirilmesi amacıyla çeşitli görüntü artırma teknikleri uygulanmıştır. Bu teknikler arasında histogram eşitleme, görüntü döndürme, parlaklık ayarlaması ile yatay ve dikey çevirme işlemleri yer almaktadır (Kadam vd. 2021).


Veri seti kullanılırken tümör kategorisindeki görüntüler tek yerde toplanmıştır. Normal ve tümörlü şekilde kategorize edilmiştir. Her bir sınıf için, görüntüler önce %60 eğitim ve %40 geçici set olarak ikiye ayrılmıştır. Daha sonra geçici set, eşit olarak (%20-%20) doğrulama ve test setlerine bölünmüştür. Bu bölümlenme, sklearn kütüphanesinin train\_test\_split fonksiyonu kullanılarak rastgele ancak tekrarlanabilir bir şekilde gerçekleştirilmiştir. Eğitim seti 1,839 normal 11,163 tümörlü, test seti 614 normal 3,722 tümörlü ve doğrulama seti 613 normal 3.721 tümörlü olmak üzere toplam 21,672 görüntüden oluşmaktadır. Çizelge 3.2 'de veri setine ait veri seti dağılımı verilmiştir.

**Çizelge 3.2.** Brain Tumors MRI veri seti dağılımı

Veri Seti	Normal	Tümörlü	Toplam
Eğitim	1839	11163	13002
Test	614	3722	4336
Doğrulama	613	3721	4334
<b>Toplam</b>	<b>3066</b>	<b>18606</b>	<b>21672</b>

Bu görüntüler, tümörlerin çeşitli açılardan ve kesitlerden görünümünü içermektedir. Veri setine ait bazı görüntüler Şekil 3.2'de verilmiştir.

### Brain Tumor Classification (MRI) Dataset

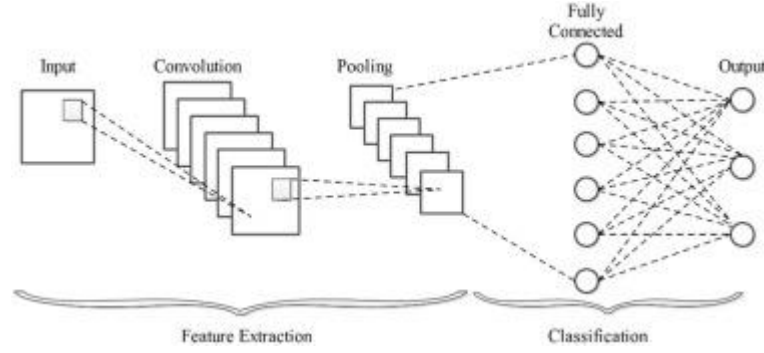


**Şekil 3.2.** Brain Tumors MRI veri seti normal ve tümörlü görüntü örnekleri

### 3.2. CNN Modelleri

Evrişimli Sinir Ağı, görsel verilerin analizi ve işlenmesinde devrim yaratan, katmanlı yapısıyla karmaşık görüntü özelliklerini otomatik olarak öğrenebilen güçlü bir derin öğrenme mimarisidir. İlk olarak 1989 yılında el yazısı rakamların tanınması için geliştirilen çalışma ile temelleri atılmıştır (LeCun vd. 1989). Her ne kadar CNN'in matematiksel temelleri 1980'li yıllarda atılmış olsa da, bu teknolojinin potansiyeli ImageNet Görsel Tanıma Yarışması'nda (ILSVRC) elde edilen çığır açıcı başarıyla gün yüzüne çıkmıştır. Toronto Üniversitesi'nden araştırmacıların geliştirdiği Evrişimli Sinir Ağı tabanlı AlexNet mimarisi, görüntü sınıflandırma görevinde o güne kadar görülmemiş bir başarı elde ederek, yapay zeka araştırmalarının odağını derin öğrenme yaklaşımlarına yöneltmiştir (Krizhevsky vd. 2012).

Evrişimli Sinir Ağları, görüntü sınıflandırma, nesne tespiti ve doğal dil işleme gibi karmaşık görevlerde üstün başarı gösteren ileri düzey bir derin öğrenme mimarisidir. Bu güçlü mimari, üç temel katman tipinden oluşur: evrişim katmanları, havuzlama katmanları ve tam bağlantılı katmanlar. Bu katmanların hiyerarşisi Şekil 3.3'de verilmiştir. Evrişim katmanları, görüntüdeki özellikleri tespit etmek için özel filtreler kullanır. Bu filtreler, görüntü üzerinde sistematik olarak kaydırılarak özellik haritaları oluşturur. İlk katmanlarda kenarlar ve renk geçişleri gibi basit özellikler tespit edilirken, derin katmanlarda daha karmaşık ve soyut özellikler öğrenilir. Bu hiyerarşik öğrenme yapısı, CNN'lerin görsel verileri insan görme sistemine benzer şekilde analiz etmesini sağlar. Havuzlama katmanları, özellik haritalarının boyutsal küçültülmesinden sorumludur. Genellikle maksimum havuzlama (max pooling) yöntemi kullanılarak, belirli bir bölgedeki en yüksek değer seçilir. Bu işlem, modelin küçük pozisyon değişikliklerine karşı dayanıklı olmasını sağlarken, hesaplama yükünü azaltır ve aşırı öğrenmeyi önler. Ayrıca, modelin ölçek ve dönüşüm değişikliklerine karşı daha sağlam olmasına katkıda bulunur. Mimarinin son bileşeni olan tam bağlantılı katmanlar, önceki katmanlarda öğrenilen tüm özellikleri birleştirerek nihai sınıflandırma kararını verir. Her nöronun önceki katmandaki tüm nöronlarla bağlantılı olduğu bu katmanlarda, genellikle softmax aktivasyon fonksiyonu kullanılarak her bir sınıf için olasılık değerleri hesaplanır. Bu yapı, CNN'lerin karmaşık görsel örüntüleri yüksek doğrulukla sınıflandırmasını mümkün kılar (Li vd. 2021).

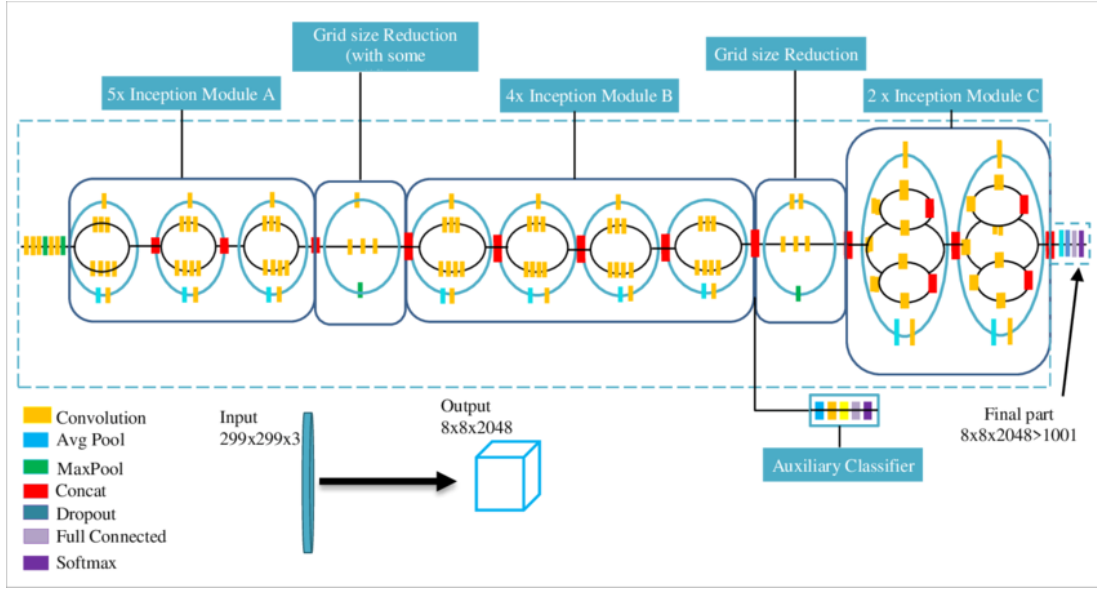


Şekil 3.3. CNN katmanlarının hiyerarşisi (Girdhar vd. 2022)

Bu çalışmada, biyomedikal görüntülerin sınıflandırılması için modern CNN mimarilerinden InceptionV3, ResNet50V2, VGG-16, VGG-19, MobileNetV2 ve DenseNet121 kullanılarak kapsamlı bir karşılaştırmalı analiz gerçekleştirilmiştir. Bu mimariler hakkında bilgiler aşağıda verilmiştir.

### 3.2.1. InceptionV3 Modeli

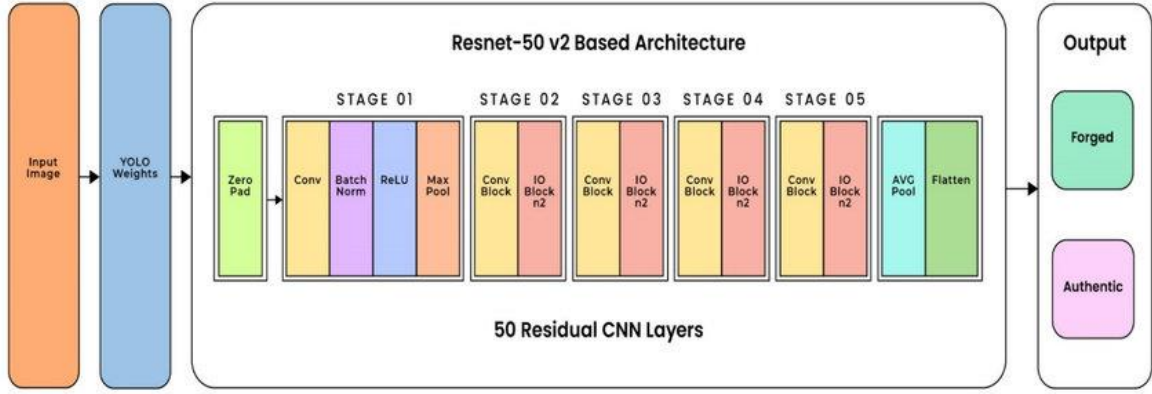
InceptionV3, 2015 yılında Google araştırmacıları tarafından geliştirilen GoogLeNet modelinin geliştirilmiş bir versiyonudur. Bu model, CNN mimarilerinden biridir. GoogLeNet/Inception ailesinin üçüncü versiyonu olan bu mimari, önceki versiyonlara göre önemli iyileştirmeler ve yenilikler içermektedir. Görsel sınıflandırmada daha başarılı sonuçlar almak için geliştirilmiştir. Bu model farklı boyutlarda evrişim filtrelerini paralel olarak uygulayarak ağır farklı ölçeklerdeki özellikleri öğrenmesini sağlar. Ayrıca, hesaplama verimliliğini artırmak için faktörize edilmiş konvolüsyonlar kullanılmıştır. Model katman yapısı Şekil 3.4' de gösterilmiştir. Model, transfer öğrenme için önceden eğitilmiş ağırlıklarla birlikte gelir ve genellikle görüntü sınıflandırma, nesne tanıma ve tıbbi görüntüleme gibi alanlarda yaygın olarak kullanılır (Szegedy vd. 2016).



Şekil 3.4. InceptionV3 katman yapısı (Iparraguirre-Villanueva vd. 2022)

### 3.2.2. ResNet50V2 Modeli

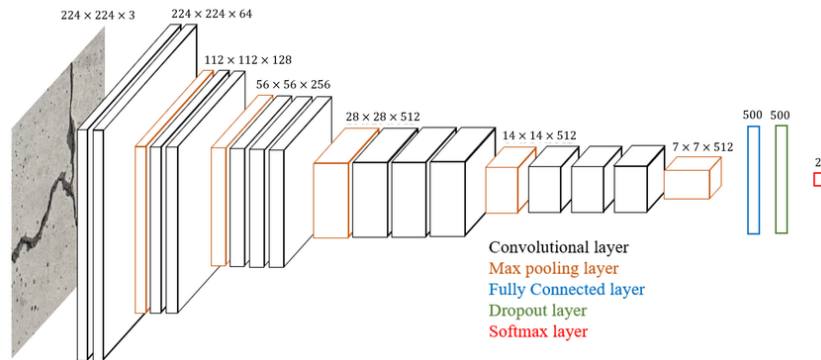
ResNet50V2 modeli, Residual Network (ResNet) ailesine ait ve Microsoft Research tarafından geliştirilen ResNet50 modelinin geliştirilmiş bir versiyonudur. Bu model, derin evrişimli sinir ağı mimarisiyle tanınır ve daha iyi performans ile daha iyi eğitim stabilitesi sunmak için çeşitli iyileştirmeler içerir. ResNet mimarisinin temel yapı taşı olan artık bağlantıları (residual connections) korurken, aktivasyon fonksiyonlarının yerleşimini ve batch normalization katmanlarının düzenini değiştirerek daha iyi performans elde etmeyi başarmıştır. ResNet50V2, orijinal ResNet50 modelinin daha derin ve karmaşık bir versiyonudur ve daha fazla sayıda katman içerir. Model, özellikle büyük veri kümelerinde eğitilerek yüksek doğruluk oranları elde etmeyi hedefler. Derin öğrenme modellerinde yaygın olarak karşılaşılan gradyan kaybolması problemini çözmek için residual (artık) bağlantılar kullanır. ResNet50V2'nin temel farkı, batch normalization ve ReLU aktivasyon fonksiyonlarının residual bloklardaki yerleşimidir. Modelin mimarisi şekil 3.5'de verilmiştir. Bu değişiklikler, modelin daha hızlı ve daha stabil bir şekilde eğitilmesini sağlar. Transfer öğrenme için uygun bir mimari olan ResNet50V2, ImageNet üzerinde önceden eğitilmiş ağırlıkları kullanarak farklı işlemlere kolayca uyum sağlar. Özellikle medikal görüntüleme alanında, hastalık tespiti, tümör sınıflandırması ve organ segmentasyonu gibi kritik görevlerde yaygın olarak kullanılmaktadır (He vd. 2016).



Şekil 3.5. ResNet50V2 model mimarisi (Qazi vd. 2022)

### 3.2.3. VGG-16 Modeli

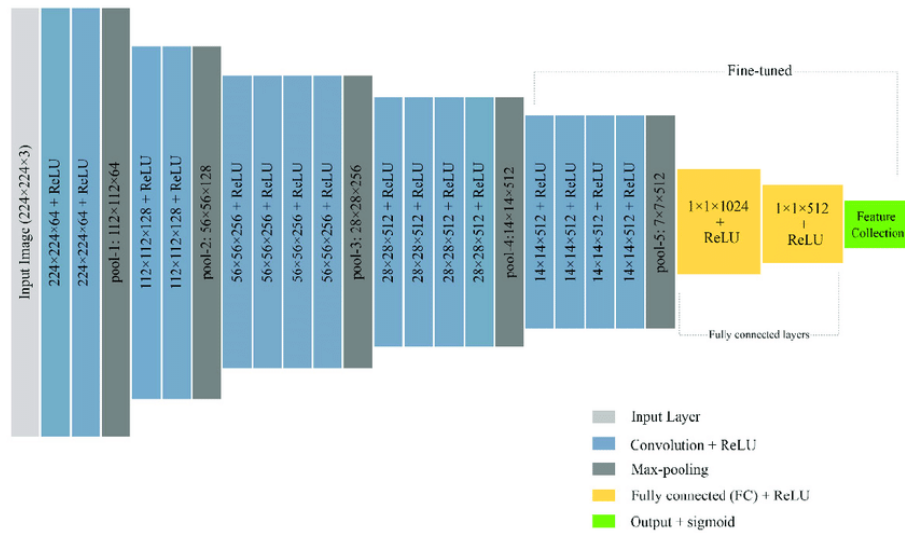
VGG-16, 2014 yılında Oxford Üniversitesi'nin Visual Geometry Group (VGG) tarafından geliştirilen ve ImageNet veri kümesinde görüntü sınıflandırma görevinde yüksek başarı elde eden bir evrişimli sinir ağı mimarisidir. VGG-16, adını toplamda 16 katmandan oluşmasından alır; bu katmanlar arasında 13 konvolüsyonel katman ve 3 tam bağlantılı (fully connected) katman bulunur. Mimarinin en dikkat çekici özelliği, geleneksel yaklaşımların aksine, küçük boyutlu (3x3) konvolüsyon filtrelerini ardışık olarak kullanmasıdır. Her konvolüsyonel katmanın ardından bir ReLU aktivasyon fonksiyonu ve genellikle bir max-pooling katmanı gelir. VGG-16 mimarisi şekil 3.6'da gösterilmiştir. Bu yapı, modelin hem derin hem de geniş olmasını sağlar, bu da daha iyi genelleme yeteneği sunar. VGG-16, özellikle transfer öğrenme için popülerdir; önceden eğitilmiş ağırlıkları kullanarak farklı veri kümelerinde hızlı ve etkili bir şekilde yeni modeller oluşturulabilir (Simonyan ve Zisserman 2014).



Şekil 3.6. VGG-16 model mimarisi (Choi vd. 2021)

### 3.2.4. VGG-19 Modeli

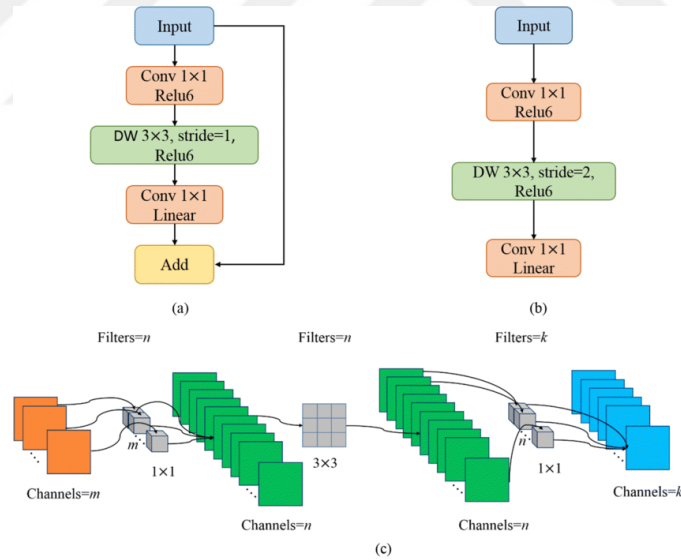
VGG-19, derin öğrenme alanında önemli bir yere sahip olan bir CNN mimarisidir. VGG-16'nın başarılı mimarisini temel alarak, VGG-16'nın daha derin bir versiyonudur ve toplamda 19 katmandan oluşur. 16 konvolüsyonel ve 3 tam bağlantılı katmandan meydana gelir. Mimarinin temel felsefesi, VGG16'da olduğu gibi, küçük boyutlu konvolüsyon filtrelerinin (3x3) ardışık kullanımına dayanır, ancak daha fazla katman ekleyerek modelin öğrenme kapasitesini artırır. ReLU aktivasyon fonksiyonları ile karakterize edilir. Beş temel alandan oluşur ve her alan içerisinde ardışık konvolüsyon katmanları bulunur. İlk iki blok ikişer konvolüsyon katmanı içerirken, sonraki üç blok sırasıyla dört konvolüsyon katmanı içerir. Her konvolüsyon katmanından sonra ReLU aktivasyon fonksiyonu uygulanır ve her bloğun sonunda 2x2 maksimum havuzlama katmanı yer alır. VGG-19 modeline ait mimari Şekil 3.7'de gösterilmiştir. Modern bilgisayarlı görü uygulamalarının güçlü araçlarından biri olan VGG-19, özellikle tıbbi görüntü analizi, nesne tespiti ve yüz tanıma sistemlerinde yaygın olarak kullanılmaktadır. Ancak, derinliği ve parametre sayısı nedeniyle yüksek hesaplama gücü ve bellek gereksinimi vardır. Bu model, özellikle transfer öğrenme için popülerdir, çünkü önceden eğitilmiş ağırlıkları kullanarak farklı veri kümelerinde hızlı ve etkili bir şekilde yeni modeller oluşturulabilir. Ayrıca, önceden eğitilmiş ağırlıkların kullanılabilirliği, farklı görevlere hızlı adaptasyonu mümkün kılar (Simonyan ve Zisserman 2014).



Şekil 3.7. VGG-19 model mimarisi (Mostafiz vd. 2020)

### 3.2.5. MobileNetV2 Modeli

MobileNetV2, Google arařtırmacıları tarafından 2018 yılında tanıtılan ve özellikle mobil ve gömülü sistemler gibi sınırlı kaynaklara sahip ortamlar için tasarlanmış hafif bir evriřimsel sinir ađı mimarisidir. MobileNetV1'in bařarılı mimarisini temel alarak, ters artık (inverted residual) yapısı ve dođrusal darbođazlar (linear bottlenecks) gibi yenilikçi kavramları kullanır. MobileNetV2'nin en temel özelliđi, derinliđine ayrılabilir konvolüsyonları (depthwise separable convolutions) ve ters artık bloklarını birleřtiren özgün yapısıdır. Her blok, önce dar bir katmandan geniř bir katmana geçiř yapan geniřleme katmanı, ardından derinliđine ayrılabilir konvolüsyon ve son olarak dođrusal projeksiyon katmanı içerir. Model mimarisi Őekil 3.8'de verilmiřtir. Bu yapı, hesaplama maliyetini ve parametre sayısını önemli ölçüde azaltırken, modelin dođruluđunu korur. Bu yapı, geleneksel konvolüsyonlara göre çok daha az parametre ve iřlem gerektirirken, model performansını korur. Bu yaklařım, modelin daha az parametreyle daha iyi performans göstermesini sađlar (Sandler vd. 2018).

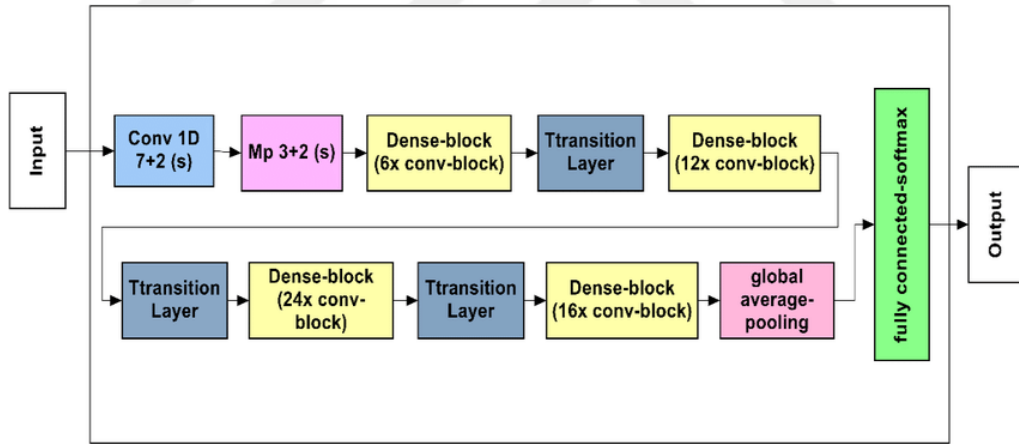


Őekil 3.8. MobileNetV2 model mimarisi (He vd. 2022)

### 3.2.6. DenseNet121 Modeli

DenseNet121, 2017 yılında Gao Huang ve meslektařları tarafından geliřtirilen ve tanıtılan bir CNN mimarisidir. DenseNet, "Densely Connected Convolutional Networks" ifadesinin kısaltmasıdır ve bu model, derin öđrenme alanında önemli bir yenilik olarak kabul edilir. DenseNet121, adını toplamda 121 katmandan oluřmasından alır ve bu

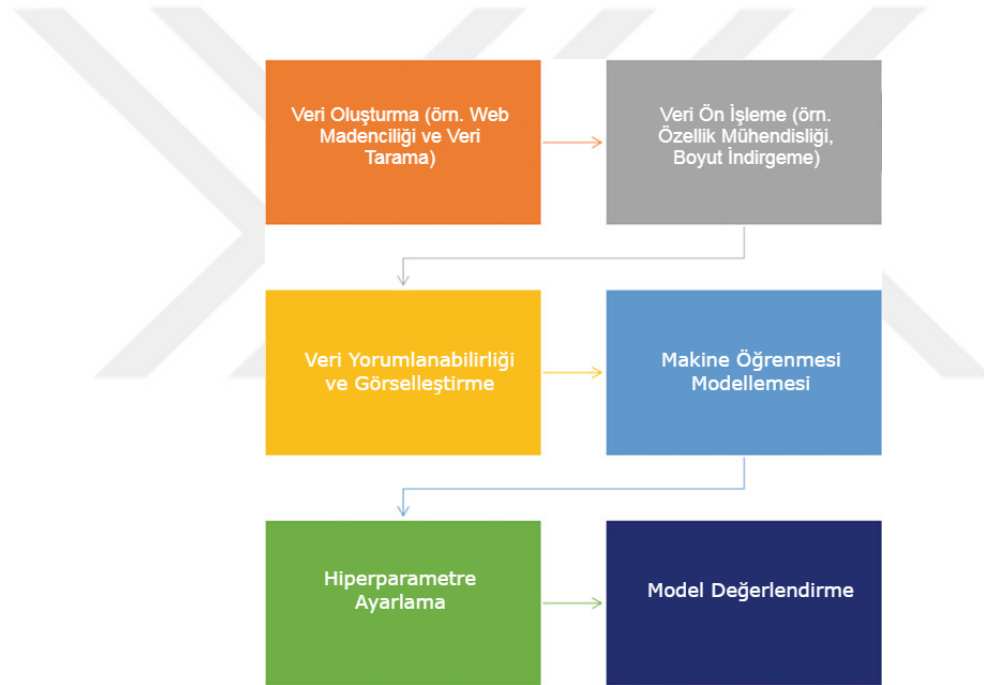
katmanlar arasında yoğun bağlantılar (dense connections) kullanır. Mimarinin temel yeniliği, her katmanın kendinden önceki tüm katmanlarla doğrudan bağlantılara sahip olmasıdır. Her katman, kendinden önceki tüm katmanların çıktılarını girdi olarak alır ve kendi özellik haritalarını sonraki tüm katmanlara iletir. Bu yoğun bağlantı yapısı, bilgi ve gradyan akışını iyileştirir, böylece derin ağların eğitilmesini kolaylaştırır. Ayrıca, parametre verimliliğini artırarak daha az sayıda parametreyle daha iyi performans elde edilmesini sağlar. Bu yapı, özelliklerin yeniden kullanılmasını teşvik eder ve modelin daha az aşırı uyum (overfitting) yapmasına yardımcı olur. DenseNet121, dört ana bloktan oluşur ve her blok, bir dizi yoğun bağlantılı katmadan oluşur. Her katman, bir batch normalization, ReLU aktivasyon fonksiyonu ve 3x3 konvolüsyon işlemi içerir. Bloklar arasında, özellik haritalarının boyutunu azaltmak için geçiş katmanları (transition layers) kullanılır. Bu geçiş katmanları, 1x1 konvolüsyon ve 2x2 ortalama havuzlama (average pooling) işlemlerini içerir. Model mimarisi Şekil 3.9’da gösterilmiştir. DenseNet121, görüntü sınıflandırma, nesne algılama ve segmentasyon gibi çeşitli bilgisayarla görme görevlerinde yaygın olarak kullanılır (Huang vd. 2017).



Şekil 3.9. DenseNet121 model mimarisi (Tareq vd. 2022)

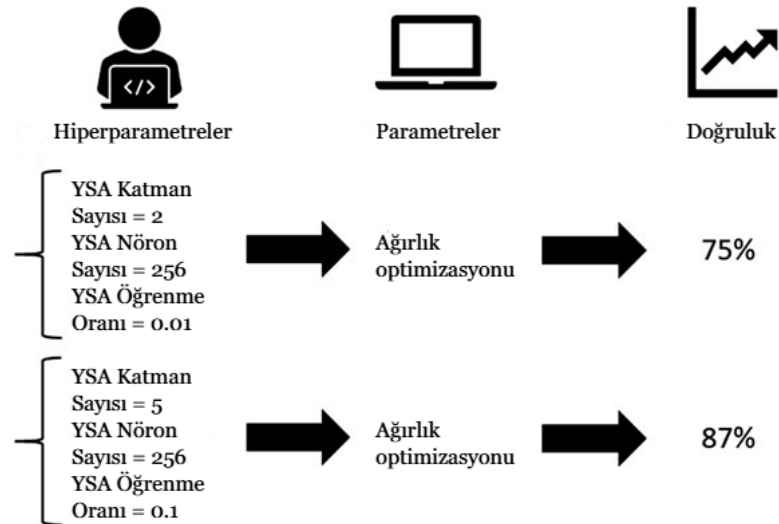
### 3.3. Hiperparametre Optimizasyonu

Hiperparametre optimizasyonu, makine öğrenmesi modellerinin performansını artırmak için modelin hiperparametrelerinin en iyi değerlerini bulma sürecidir. Bu süreç, modelin öğrenme aşamalarını kontrol eden ve model mimarisini şekillendiren parametrelerin en uygun değerlerinin belirlenmesini içerir. Hiperparametreler, modelin eğitim sürecinde otomatik olarak öğrenilemeyen, bunun yerine model eğitiminden önce manuel olarak veya optimizasyon yöntemleriyle bulunması gereken değişkenlerdir. Derin öğrenme iş akışında hiperparametre optimizasyonu Şekil 3.10'da gösterilmiştir. Makine öğrenmesi modellerinin performansını arttıran hiperparametrelerin belirlenmesi, model eğitiminden daha uzun süren bir optimizasyon sürecidir (Jin 2022).



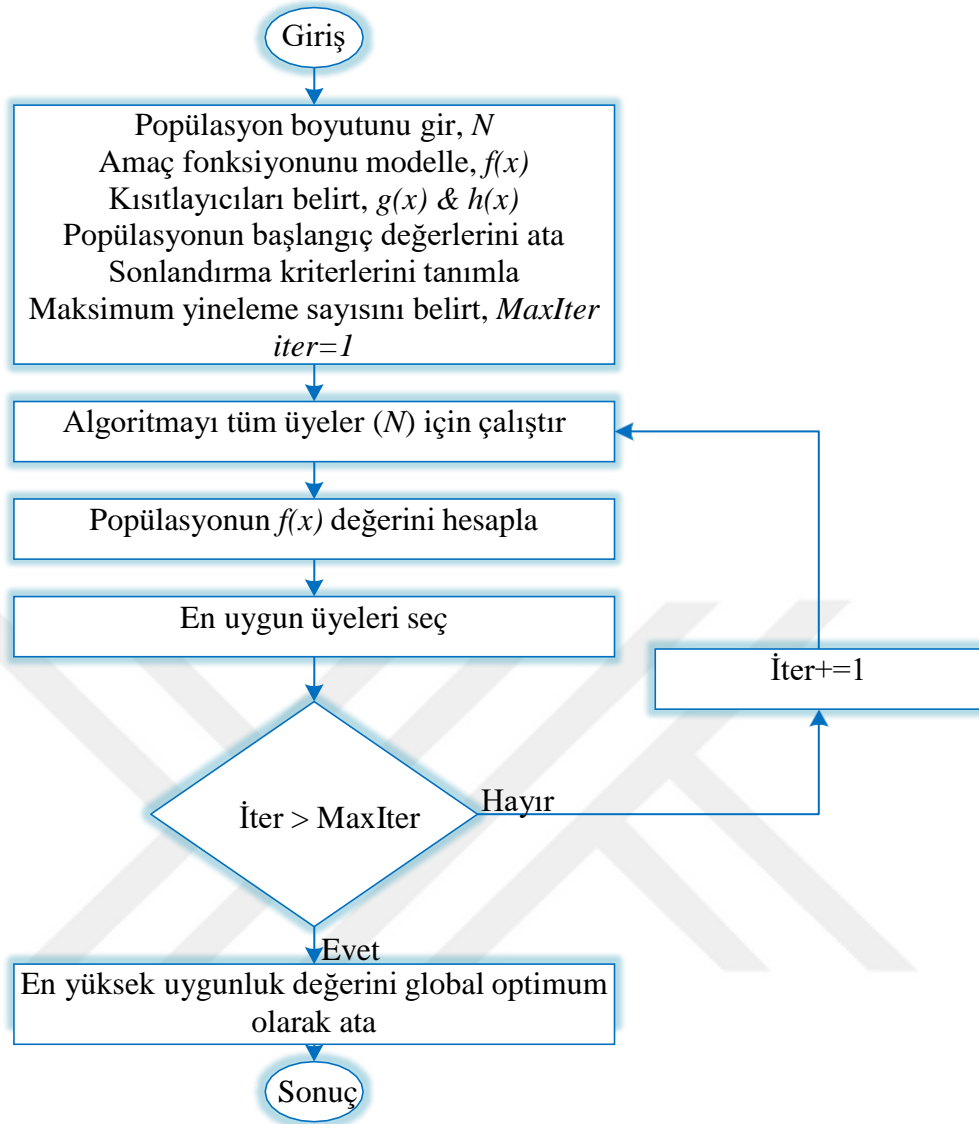
Şekil 3.10. Derin öğrenme iş akışında hiperparametre optimizasyonu (Ippolito 2022)

Optimizasyon süreci genellikle, bir arama uzayında çeşitli hiperparametre kombinasyonlarının denenmesi ve her kombinasyon performansının bir metrik (doğruluk, F1 skoru, AUC) ile değerlendirilmesiyle gerçekleştirilir. Hiperparametre optimizasyonu iş akışı Şekil 3.11'de gösterilmiştir. Derin öğrenme modellerinde yaygın olarak ve bu çalışmada da optimize edilen hiperparametreler arasında öğrenme oranı (learning rate), parti boyutu, epoch sayısı, optimizasyon fonksiyonu seçimi, nöron düşürme oranı gibi parametreler yer almaktadır (Snoek vd. 2012).



Şekil 3.11. Hiperparametre optimizasyonu iş akışı (Ippolito 2022)

Hiperparametre optimizasyonu için çeşitli yöntemler kullanılmaktadır. Geleneksel yöntemler arasında ızgara araması (grid search) ve rastgele arama (random search) yer almaktadır (Jamieson ve Talwalkar 2016). Izgara araması, önceden belirlenen değer aralıklarında tüm olası kombinasyonları sistematik olarak denerken, rastgele arama belirli bir aralıktan rastgele seçilen değerleri kullanır. Bayesian optimizasyon ise, önceki denemelerin sonuçlarını kullanarak daha verimli bir arama stratejisi sunar. Son yıllarda, meta-sezgisel algoritmalar hiperparametre optimizasyonunda giderek daha fazla kullanılmaya başlanmıştır. Genetik algoritma, parçacık sürü optimizasyonu, karınca kolonisi optimizasyonu, diferansiyel evrim, yapay arı kolonisi optimizasyonu, gri kurt algoritması ve bu çalışmada kullanılan deniz yırtıcıları algoritması gibi doğadan esinlenen bu yöntemler, geniş arama uzaylarında etkili çözümler sunabilmektedir. Tüm bu metasezgisel algoritmalara ait genel akış diyagramı Şekil 3.12’de gösterilmiştir. Bu algoritmalar, biyolojik sistemlerdeki evrim, sürü davranışı veya av-avcı ilişkileri gibi doğal süreçleri taklit ederek optimal hiperparametre kombinasyonlarını bulmaya çalışır. Bu yöntemlerin optimizasyon alanındaki zorlu problemleri verimli bir şekilde çözebildiği gözlemlenmiştir. Metasezgisel algoritmalar, karmaşık optimizasyon probleminin arama uzayında çeşitli yaklaşımlarla arama yaparak daha iyiye yakın çözümlere ulaşmayı amaçlamaktadırlar (Peres ve Castelli 2021, Abasi vd. 2023).



Şekil 3.12. Meta-sezgisel algoritmaların akış diyagramı

Hiperparametre uzayının kapsamlı bir şekilde araştırılması, her bir hiperparametre kombinasyonu için model eğitiminin tekrarlanması gerektirdiğinden, hesaplama açısından yoğun bir işlemdir. Optimizasyon süreci önemli miktarda zaman ve hesaplama kaynağı gerektirir. Bu nedenle, kaynakların verimli kullanımı için erken durdurma, aşamalı eleme ve paralel hesaplama gibi stratejiler yaygın olarak kullanılır (Li vd. 2020).

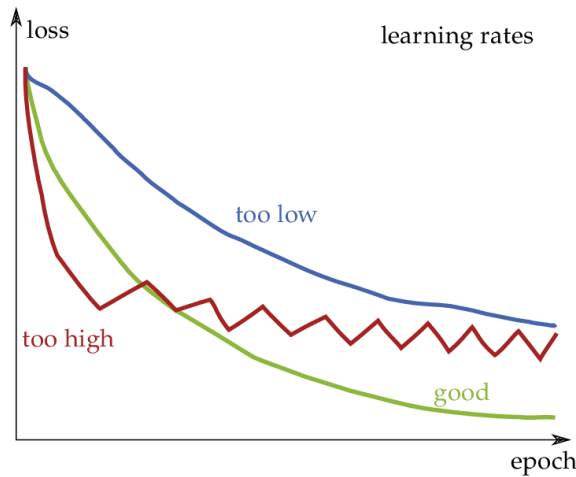
### 3.3.1. Optimize Edilen Hiperparametreler

Bu çalışmada optimizasyonu yapılan öğrenme oranı, parti boyutu, epoch sayısı, optimizasyon fonksiyonu seçimi ve nöron düşürme değeri parametreleri, modelin öğrenme sürecini ve performansını doğrudan etkilemektedir. Hiperparametre

optimizasyonunun modelin performansına olan etkisi, tıbbi görüntü analizi gibi yüksek hassasiyet gerektiren uygulamalarda özellikle dikkat çekmektedir. Bu bölümde optimize edilen parametreler hakkında bilgi ve tanım aralıkları aşağıda verilmiştir.

### 3.3.1.1. Öğrenme Oranı

Öğrenme oranı (Learning rate), modelin ağırlıklarının her adımda ne kadar hızlı güncelleneceğini belirler. Yüksek öğrenme oranı, modelin eğitim verilerine aşırı uyum sağlamasına (overfitting) yol açarak, yeni verilerde başarısız olmasına neden olurken, düşük öğrenme oranı ise modelin veri setindeki örüntüleri yeterince öğrenememesine (underfitting) ve dolayısıyla yetersiz performans göstermesine yol açar. Çok düşük bir öğrenme oranı modelin yerel bir minimumda takılıp kalmasına, çok yüksek bir öğrenme oranı küresel minimumu bulamamasına sebep olacaktır. En uygun öğrenme oranı başlangıçta yüksek bir öğrenme oranıyla küresel minimuma hızlı bir şekilde yaklaşacak ve daha sonraki eğitim sürecinde azalan bir öğrenme oranıyla küresel minimuma yaklaşacaktır. Öğrenme oranı optimizasyonu önemine dair şekil 3.13'de verilmiştir. (Müller 2020).

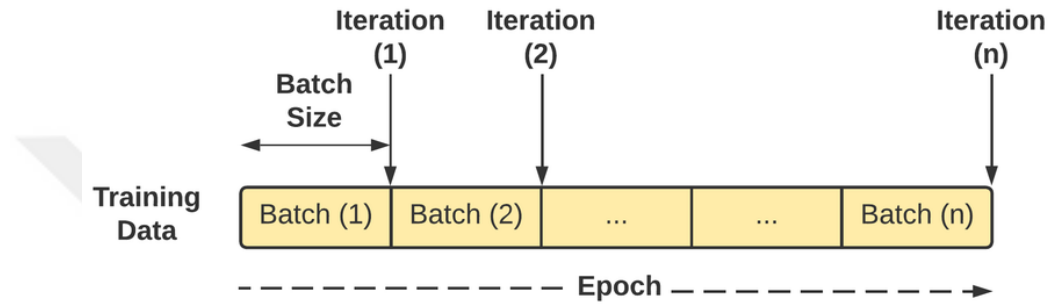


Şekil 3.13. Farklı öğrenme oranları seçiminin epoch boyunca kayıplara etkisi (Müller 2020)

Öğrenme oranı varsayılan tüm CNN modellerinde 0.001 alınmıştır. Hiperparametre optimizasyonu için 0.00001 ile 0.1 tanım aralığı belirlenmiştir.

### 3.3.1.2. Parti Boyutu

Parti boyutu, her adımda modele beslenen veri örneği sayısını belirler. Model öğrenme sırasında parti boyutunun her adımda nasıl işlendiği şekil 3.14’de gösterilmiştir. Parti boyutu modelin performansında önemli bir etkidir. Büyük parti boyutları, daha hızlı öğrenme sağlar, ancak daha fazla bellek gerektirir ve genelleme yeteneğini olumsuz etkileyebilir. Küçük parti boyutları, daha az bellek gerektirir ve daha iyi genelleme sağlayabilir. Ancak yavaş öğrenme sağlar ve hesaplama maliyetini artırabilir (Masters ve Luschi 2018).



Şekil 3.14. Model eğitimi sırasında epoch ve batch gösterimi (Thanapol vd. 2024)

Parti boyutunun belirlenmesinde, GPU belleğine sığması için genelde 2'nin katları şeklinde değerler seçilir. Parti boyutu varsayılan tüm CNN modellerinde 32 alınmıştır. Hiperparametre optimizasyonu için 8 ile 256 tanım aralığı belirlenmiştir.

### 3.3.1.3. Epoch Sayısı

Epoch sayısı, modelin tüm veri setini kaç kez işleyeceğini belirler. Model öğrenme sırasında epoch kavramı şekil 3.14’de gösterilmiştir Model eğitimi sırasında, veriler küçük parçalar halinde işlenir ve her bir parça eğitilir. Modelin başarımı test edilir ve geriye yayılım (“backpropagation”) ile ağırlıklar güncellenir. Bu işlem, her bir eğitim adımında tekrarlanır ve modelin en uygun ağırlık değerleri hesaplanır. Bu tekrarlanan adımlar, modelin eğitim sürecini oluşturur ve epoch olarak adlandırılır. Derin öğrenmede, en uygun ağırlık değerleri adım adım hesaplandığı için, ilk epoch'larda başarımlar düşük olacaktır. Ancak, epoch sayısı arttıkça, başarımlar da artacaktır. Bununla birlikte, belli bir noktadan sonra, modelin öğrenme hızı yavaşlayacaktır. Epoch sayısı ne kadar büyük seçilirse modelin eğitim süreci de uzayacaktır (Shafi ve Assad 2023).

Epoch sayısı varsayılan tüm CNN modellerinde 10 alınmıştır. Hiperparametre optimizasyonu için 5,10 ve 20 değer aralığı belirlenmiştir.


#### 3.3.1.4. Optimizasyon Fonksiyonu

Optimizasyon fonksiyonu, modelin öğrenme sürecini optimize etmek için kullanılan algoritmadır. Doğrusal olmayan problemlerin çözümünde, global minimumu bulmayı hedefleyen optimizasyon algoritmaları kullanılır. Derin öğrenme, yüksek boyutlu ve karmaşık fonksiyonların optimizasyonunu gerektirdiğinden, stochastic gradient descent (SGD) ailesinden algoritmalar yaygın olarak tercih edilir. SGD'nin varyantları olan Adagrad, Adadelata, Adam, ve Adamax, öğrenme oranını adaptif olarak ayarlayarak farklı parametreler için farklı öğrenme oranları kullanır. Adagrad, her parametre için geçmiş gradyanların karelerinin toplamını dikkate alarak öğrenme oranını azaltır, Adadelata ise geçmiş gradyanların bir ortalamasını kullanır. Adam ve Adamax ise momentumu kullanarak daha hızlı yakınsama sağlar; Adam ikinci moment bilgisi de kullanırken, Adamax sonsuz normu kullanır. Bu algoritmaların performans ve hızları, problem yapısına, veri setine ve hiperparametre ayarlarına bağlı olarak değişir (Ruder 2016).

Optimizasyon fonksiyonu varsayılan tüm CNN modellerinde Adam seçilmiştir. Hiperparametre optimizasyonu için Adam, SGD, RMSprop, Adamax ve Nadam olmak üzere 5 farklı değer belirlenmiştir.

#### 3.3.1.5. Nöron Düşürme Oranı

Nöron düşürme oranı, modelin aşırı öğrenmesini önlemek için kullanılan bir tekniktir. Modelin bazı nöronlarını rastgele devre dışı bırakarak, modelin farklı yollarla öğrenmesini sağlar. Nöron düşürme oranı, her eğitim adımıda devre dışı bırakılacak nöronların oranını belirler. Nöron düşürme uygulanmış bir sinir ağı şekil 3.15'de gösterilmiştir. Bu, modelin tek bir nörona aşırı bağımlı olmasını engeller. Nöron düşürme oranı, 0 ile 1 arasında değerler alır. Çok yüksek nöron düşürme oranları modelin yetersiz öğrenmesine neden olabilirken, çok düşük oranlar regularizasyon etkisini azaltır (Srivastava vd. 2014).



Şekil 3.15. Nöron düşürme uygulanmış sinir ağı (Wang vd. 2020)

Nöron düşürme değeri varsayılan tüm CNN modellerinde 0.5 seçilmiştir. Hiperparametre optimizasyonu için 0.2 ile 0.9 tanım aralığı belirlenmiştir.

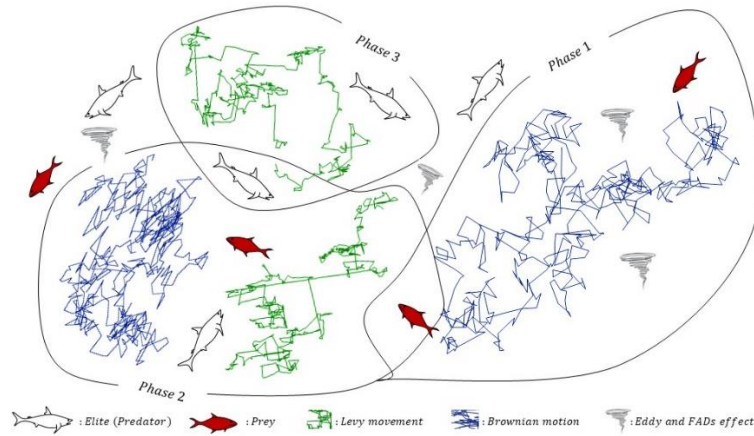
MPA'nın temel parametreleri arasında popülasyon boyutu (N), maksimum iterasyon sayısı (Max\_iter), hız oranı (Velocity Ratio), balık toplama cihazları etkisini simüle eden sabit (FADs) ve Levy uçuşu ile Brown hareketi arasındaki geçiş olasılığını kontrol eden sabit (P) yer alır. Popülasyon boyutu, arama uzayında dolaşan "yırtıcı" sayısını ifade eder ve daha büyük popülasyonlar, arama uzayının daha geniş bir şekilde keşfedilmesini sağlarken hesaplama maliyetini artırır. Maksimum iterasyon sayısı, algoritmanın durmadan önce gerçekleştireceği toplam iterasyon miktarını belirler. Hız oranı, yırtıcıların hareket hızını etkiler ve genellikle 0.1 gibi küçük bir değer kullanılır. Balık toplama cihazlarının etkisini simüle eden sabit (FADs), yırtıcıların avlanma stratejilerini etkileyen bir faktör olup genellikle 0.2 olarak alınır. P sabiti ise, algoritmanın Levy uçuşu ile Brown hareketi arasında geçiş yapma olasılığını kontrol eder ve 0.5 gibi bir değerle keşif ve sömürü arasındaki dengeyi ayarlamaya yardımcı olur. Popülasyon boyutu haricindeki diğer parametreler varsayılan değerlerinde kullanılmıştır.

### 3.3.2. Deniz Yırtıcıları Algoritması

Faramarzi vd. (2020), çalışmalarında deniz ekosistemindeki yırtıcıların avlarını yakalama stratejilerinden esinlenerek geliştirilmiş meta-sezgisel optimizasyon algoritması olan Deniz Yırtıcıları Algoritmasını (Marine Predators Algorithm, MPA) tanıtmaktadırlar. Algoritma, avcı ve av arasındaki etkileşimi, avcılarının avlarını bulma ve

yakalama stratejilerini ve avların kaçınma mekanizmalarını taklit ederek çözüm uzayında etkili bir arama gerçekleştirir. Algoritmanın işleyişi, popülasyon tabanlı bir yaklaşıma dayanır. Deniz yırtıcıları algoritmasının başlangıç popülasyonu, arama uzayında rastgele bir dağılımla oluşturulur. Her iterasyonda, popülasyon üyeleri, avın konumuna göre güncellenir ve en iyi çözümler seçilerek bir sonraki nesle aktarılır. Bu süreç, belirli bir durma kriteri devreye girene kadar devam eder. Algoritmanın dinamik yapısı, av ve avcı hızlarının göreceli oranına göre fazlar arasında geçiş yaparak belirlenir (Yousri vd. 2021).

MPA, deniz ekosistemindeki avcı-av ilişkisini modelleyerek çalışır. Üç aşamadan oluşur: İlk aşamada, hem avcı hem de av Lévy dağılımına göre hareket ederek geniş bir arama yapar. İkinci aşamada, av tespit edildiğinde avcı Brownian hareketiyle avı takip ederken, av Lévy hareketini sürdürür. Son aşamada, av yakalandığında hem avcı hem de av Brownian hareketiyle lokal arama yapar. Deniz yırtıcıları algoritması fazları ve stratejileri Şekil 3.16'da gösterilmiştir. Algoritma, iterasyon sayısına bağlı olarak hız oranını dinamik olarak ayarlar ve  $P=0.5$  olasılığıyla elit veya rastgele çözümler seçerek arama-sömürme dengesini korur (Abdel-Basset vd. 2021).



Şekil 3.16. Deniz yırtıcıları algoritması fazları (Faramarzi vd. 2020)

MPA, başlangıç çözümlerini oluşturmak için önce arama uzayında rastgele ve üniform bir dağılım kullanır. Ardından, avcı sayısı ( $n$ ), iterasyon sayısı ( $m$ ), boyut ( $d$ ) ve  $Av$  avın ilk konumunu göstermektedir Denklem 1'deki  $X_{max}$  ve  $X_{min}$  maksimum ve

minimum değerler ve bir  $[0,1]$  aralığında rastgele üretilen vektör ( $rand$ ) kullanılarak avın başlangıç konumu belirlenir.

$$X_0 = X_{min} + rand(X_{max} - X_{min}) \quad (1)$$

$Av$  matrisi, başlangıç popülasyonunun konumlarını temsil eder. Algoritma,  $Av$  matrisindeki çözümleri değerlendirerek, en iyi çözümleri  $Elit$  matrisine aktarır. Her aşama aşağıda özetlenmiştir.

Faz 1, toplam iterasyon sayısının üçte birini kapsayan bir aşamadır. Bu aşamada,  $av$ 'ın yüksek hızı nedeniyle  $avcının$  Lévy hareketi durdurulur ve  $avcı$  Brownian hareketiyle hareket etmeye başlar.  $Av$ 'ın yeni konumu Denklem 3 kullanılarak hesaplanır. Hesaplamalarda,  $P=0.5$  olasılığı,  $R$   $[0,1]$  aralığında bir üniform rastgele sayı ve  $R_B$  ise Brownian hareketine dayalı bir rastgele vektör olarak kullanılır (Denklem 2 ve 3).

$$adım_l = R_B \otimes (Elit_l - (R_B \otimes Av_l)) \quad (2)$$

$$Av_l = Av_l + (P \cdot R \otimes adım_l) \quad (3)$$

Faz 2, algoritmanın iterasyonlarının üçte ikisini oluşturur.  $avcı$  ve  $av$  aynı hızda hareket eder, ancak farklı hareket modelleri kullanırlar:  $avcı$  Brownian hareketi,  $av$  ise Lévy hareketi kullanır.  $Av$ 'ın hareketi,  $R_L$  vektörü (Lévy dağılımından türetilen rastgele bir vektör) ile ölçeklenir. Popülasyonun ilk yarısının konumları Denklem 4 ve 5 ile güncellenir.

$$adım_l = R_L \otimes (Elit_l - (R_L \otimes Av_l)) \quad (4)$$

$$Av_l = Av_l + (P \cdot R \otimes adım_l) \quad (5)$$

Popülasyonun geri kalanı için, Denklem 6 ve 7 kullanılarak bir güncelleme yapılır. Bu güncellemede,  $Elit$  matris,  $RB$  vektörü ile çarpılır.  $CF$  parametresi,  $avcının$  hareketinin adım boyutunu kontrol eden uyarlanabilir bir faktördür.

$$adım_l = R_B \otimes ((R_B \otimes Elit_l) - Av_l) \quad (6)$$

$$Av_l = Elit_l + (P \cdot CF \otimes adım_l) \quad (7)$$

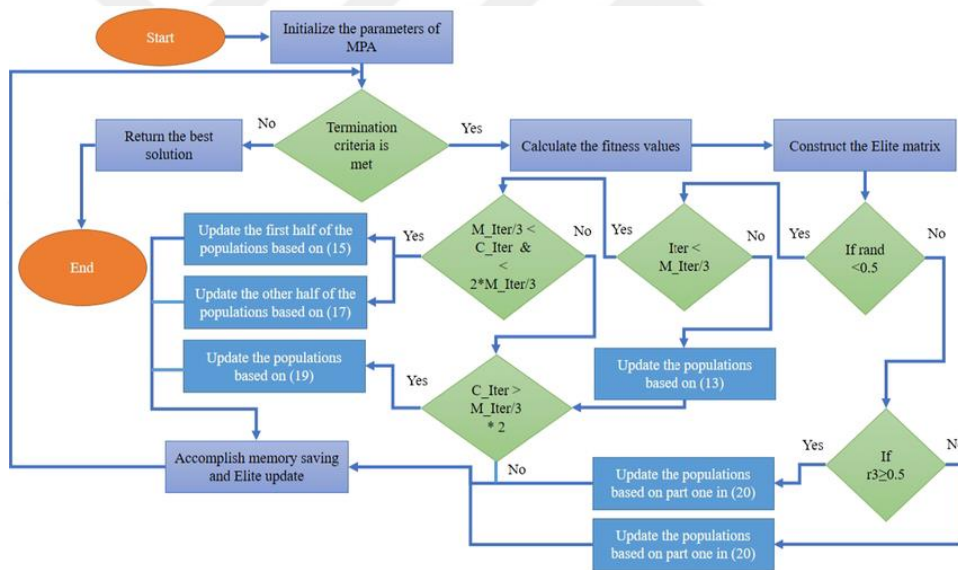
$$CF = [1 - (Iter./Max.Iter)]^{(2.Iter./Max.Iter)} \quad (8)$$

Algoritmanın son aşamasında (Faz 3), *avcı* daha hızlı hareket eder ve Lévy hareketi kullanır. En iyi çözümleri tutan *Elit* matrisi,  $R_L$  ile çarpılır ve *avin* konumu Denklem 10 ile güncellenir.

$$avim_l = R_L \otimes ((R_L \otimes Elit_l) - Av_l) \quad (9)$$

$$Av_l = Av_l + (P.CF \otimes Av_l) \quad (10)$$

MPA algoritmasının her yinelemesinde, Elit matrisi, bulunan en iyi çözümlerle güncellenir. Algoritma, maksimum iterasyon sayısına ulaştığında veya durdurma kriteri sağlandığında durur ve Elit matrisindeki son çözüm, en iyi çözüm olarak kullanılır. Deniz yırtıcıları algoritmasının akış şeması Şekil 3.17 ve sözde kodu Şekil 3.18'de verilmiştir.



Şekil 3.17. Deniz yırtıcıları algoritmasının akış şeması (Abualigah ve Diabat 2023)

Algoritma, avcılarının konumlarını güncellemek için bir olasılık mekanizması olan FAD'i kullanır. FAD, 0 ile 1 arasında rastgele üretilen bir sayı (r) ile kontrol edilir. Eğer r, 0.2'den küçük veya ona eşitse, avcı rastgele bir yönde hareket eder. Bu hareket, bir uyarlanabilir faktör (CF), arama uzayının sınırları (Xmin, Xmax) ve bir ikili rastgele vektör (U) kullanılarak belirlenir. U vektörünün her elemanı, 0 ile 1 arasında üretilen bir rastgele sayının 0.2'den küçük olup olmamasına göre 0 veya 1 olarak atanır. Eğer r,

0.2'den büyükse, avcı, av matrisinden rastgele seçilen iki çözüm arasındaki yöne doğru hareket eder. Bu hareketin büyüklüğü,  $r$  ve FAD değerine bağlıdır (Arslan 2023).

$$Av_l = Av_l + CF[X_{min} + R \otimes (X_{max} - X_{min})] \otimes U \quad r \leq FADs$$

$$Av_l = Av_l + [FADs(1 - r) + r](Av_{r1} - XAv_{r2}) \quad r > FADs$$

*Başlangıç:*

Rastgele ve uniform dağılımla başlangıç popülasyonunu oluştur

Avcı sayısı ( $n$ ), iterasyon sayısı ( $m$ ), boyut ( $d$ ) belirle

Av matrisini oluştur:  $X_0 = X_{min} + rand * (X_{max} - X_{min})$

*Faz 1:*

**For**  $t < (1/3) * m$ :

**for** her av:

$$adım_1 = R_B \otimes (Elit_1 - (R_B \otimes Av_1))$$

$$Av_1 = Av_1 + (P * R \otimes adım_1)$$

*Faz 2:*

**For**  $(1/3) * m \leq t < (2/3) * m$ :

**For** popülasyonun ilk yarısı:

$$adım_1 = R_L \otimes (Elit_1 - (R_L \otimes Av_1))$$

$$Av_1 = Av_1 + (P * R \otimes adım_1)$$

**For** popülasyonun geri kalanı:

$$adım_1 = R_B \otimes ((R_B \otimes Elit_1) - Av_1)$$

$$Av_1 = Elit_1 + (P * CF \otimes adım_1)$$

$$CF = [1 - (Iter / Max.Iter)]^{((2 * Iter) / Max.Iter)}$$

*Faz 3:*

**For**  $t \geq (2/3) * m$ :

**For** her av:

$$adım_1 = R_L \otimes ((R_L \otimes Elit_1) - Av_1)$$

$$Av_1 = Av_1 + (P * CF \otimes Av_1)$$

*FAD Etkisi:*

**For** her av:

$r =$  rastgele sayı  $[0, 1]$

**if**  $r \leq FADs$ :

$U =$  ikili rastgele vektör

$$Av_1 = Av_1 + CF * [X_{min} + R \otimes (X_{max} - X_{min})] \otimes U$$

**else:**

$r1, r2 =$  rastgele seçilen iki çözüm

$$Av_1 = Av_1 + [FADs * (1 - r) + r] * (Av_{r1} - Av_{r2})$$

*Her iterasyonda:*

Elit matrisini en iyi çözümlerle güncelle

Şekil 3.18. Deniz yırtıcıları algoritması sözde kodu

### 3.4. Performans Metrikleri

Makine öğrenmesinde modellerimizin veri setleri üzerindeki başarısını ölçmek ve performansını değerlendirmek için çeşitli metrikler kullanılır. Bu metodoloji, model eğitimi esnasındaki sorunların tespit edilmesini ve en uygun modelin seçilmesini sağlar. Her birinin farklı yönleri vurguladığını ve tek başına kullanılmaması gerektiğini belirtmek önemlidir. En uygun metrik, çözülmeye çalışılan özel probleme ve veri kümesinin özelliklerine bağlıdır. Sonuçlar, istatistiksel olarak anlamlı bir şekilde raporlanır ve model seçimi kararını destekler (Kilic ve Karakoyun 2023).

#### 3.4.1. Doğruluk Değeri

Doğruluk değeri, bir modelin doğru tahminlerinin toplam sayısının, tüm tahminlerin sayısına oranıdır. Performans değerlendirmesi için sıkça kullanılan bir metriktir. Basit ve anlaşılır olmasına rağmen, dengesiz veri kümeleri için yanıltıcı olabilir (Hossin ve Sulaiman 2015).

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN}$$

#### 3.4.2. Kayıp Değeri

Kayıp değeri, bir modelin tahminlerinin gerçeğe ne kadar uzak olduğunu ölçer. Modelin tahminlerinin ne kadar hatalı olduğunu gösterir. Kayıp fonksiyonu, modelin eğitimi sırasında minimize edilmeye çalışılan bir fonksiyondur. Matematiksel formülü modele göre değişir. En yaygın kullanılan kayıp fonksiyonları binary cross-entropy (BCE) ve categorical cross-entropy (CCE)'dir. Kayıp değeri ne kadar düşükse, model o kadar iyi performans gösteriyor demektir (Terven vd. 2023).

$$\text{BCE} = -[y * \log(p) + (1 - y) * \log(1 - p)]$$

$$\text{CCE} = -\sum(y_i * \log(p_i))$$

#### 3.4.3. Hassasiyet Değeri

Hassasiyet değeri, pozitif olarak tahmin edilen örnekler içinde gerçekten pozitif olanların oranıdır. Bir modelin pozitif tahminlerinin ne kadarının doğru olduğunu ölçer. Yanlış pozitiflerin maliyetli olduğu zamanlarda önemi ortaya çıkmaktadır (Rainio vd. 2024).

$$\text{Hassasiyet} = \frac{TP}{TP + FP}$$

#### 3.4.4. Duyarlılık Değeri

Duyarlılık değeri, gerçekte pozitif olan örnekler içinde doğru tahmin edilenlerin oranıdır. Bir modelin pozitif örneklerin ne kadarını doğru olarak tahmin ettiğini ölçer. Yanlış negatiflerin maliyetli olduğu durumlarda değerlidir (Erickson ve Kitamura 2021).

$$\text{Duyarlılık} = \frac{TP}{TP + FN}$$

#### 3.4.5. F1 Skor

F1 skoru, hassasiyet ve duyarlılık değerlerinin harmonik ortalamasıdır. Dengesiz veri setlerinde daha anlamlı bir metrik sunar. 0 ile 1 arasında değer alır ve 1'e yakın değerler daha iyi performansı gösterir (Liu vd. 2023).

$$F1 \text{ skor} = 2 * \frac{\text{Hassasiyet} * \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}}$$

#### 3.4.6. AUC Değeri

AUC değeri, bir modelin pozitif ve negatif örnekleri ayırt etme yeteneğini ölçer. ROC eğrisi, farklı eşik değerleri için doğru pozitif oranına karşı yanlış pozitif oranını gösteren bir grafikdir. AUC, bu eğrinin altında kalan alanı temsil eder ve modelin sınıfları ayırt etme yeteneğini gösterir. AUC değeri 0.5 ile 1 arasında değişir; 1 mükemmel sınıflandırmayı, 0.5 ise rastgele tahmini ifade eder (Chicco ve Jurman 2023).

$$AUC = \int \left( \frac{TP}{TP + FN} * d\left(\frac{FP}{FP + TN}\right) \right)$$

### 3.5. Deneysel Tasarım

Bu bölümde, model eğitimlerin hangi donanım ve yazılım kullanılarak nasıl yapıldığına dair süreç anlatılacaktır.

#### 3.5.1. Donanım ve Yazılım

Derin öğrenme modellerinin eğitimi, büyük veri kümeleri ve karmaşık hesaplamalar gerektiren yoğun bir işlemdir. Bu nedenle, kullanılan donanımın performansı, eğitim süresi, modelin ölçeği ve nihai doğruluğu üzerinde belirleyici bir etkiye sahiptir. GPU (Grafik İşlem Birimi), paralel işlem yapabilme yeteneği ile derin öğrenme modellerinin eğitiminde en önemli donanım bileşeni olarak öne çıkmaktadır. İşlemleri CPU'lara göre daha hızlı gerçekleştirebilir. RAM, büyük veri kümelerinin bellekte tutulabilmesi için gereklidir. Depolama birimleri de veri setlerinin hızlı bir şekilde yüklenip işlenebilmesi için önem taşır.

Bu çalışmada, Intel(R) Core(TM) i7-9750H CPU @ 2.60GHz işlemci, 16.0 GB RAM ve NVIDIA GTX 1660Ti grafik kartı içeren bir bilgisayar sistemi kullanılmıştır. Bu donanım konfigürasyonu, derin öğrenme modellerinin eğitimi ve değerlendirilmesi için gerekli hesaplama gücünü ve bellek kapasitesini sağlamıştır. Eğitim süreçleri zaman almıştır.

Çalışmada, derin öğrenme modellerinin eğitimi ve hiperparametre optimizasyonu için çeşitli modern yazılım araçları ve kütüphaneler kullanılmıştır. Temel olarak, Python programlama dili üzerine inşa edilmiş TensorFlow 2.x derin öğrenme framework'ü kullanılmıştır. TensorFlow'un yüksek seviyeli API'si olan Keras, model oluşturma ve eğitim süreçlerini kolaylaştırmak için tercih edilmiştir. Veri ön işleme ve artırma işlemleri için Keras'ın ImageDataGenerator sınıfı kullanılmıştır. Hiperparametre optimizasyonu için MEALPY (Meta-heuristic ALgorithms in Python) kütüphanesi kullanılmıştır. Metrikler için TensorFlow'un metrics modülü kullanılmıştır. Ayrıca, numpy kütüphanesi numerik işlemler için kullanılmıştır.

### 3.5.2. Optimizasyon Süreci

Bu çalışmada, VGG16, ResNet50V2, InceptionV3, VGG19, MobileNetV2 ve DenseNet121 modelleri kullanılarak biyomedikal görüntülerin sınıflandırma performansını optimize etmek için bir araştırma gerçekleştirilmiştir. Çalışma, Göğüs Röntgeni ve Beyin MR'ı olmak üzere iki farklı veri seti üzerinde yürütülmüş ve Deniz Yırtıcıları Algoritması kullanılarak hiperparametre optimizasyonu gerçekleştirilmiştir. Veri setleri, normal ve zatüre vakalarını içeren Göğüs Röntgeni ile tümörlü ve normal vakaları içeren Beyin MR görüntülerinden oluşmaktadır. Her iki veri seti için de görüntülerin 224x224 piksel boyutuna yeniden boyutlandırılması, piksel değerlerinin 0-1 aralığına normalizasyonu, kayma, yakınlaştırma ve döndürme gibi rastgele dönüşümler uygulanmıştır. Bu artırımlar, eğitim koşullarının daha çeşitli bir setini simüle ederek modellerin genelleme yeteneğini artırmayı hedeflemiştir.

Her model, ImageNet veri seti üzerinde önceden eğitilmiş ağırlıklarla başlatılmıştır. Bu da transfer öğrenme avantajından yararlanarak eğitim sürecini hızlandırmış ve daha iyi genelleme sağlamıştır. Modellerin üst katmanları, belirli görevler için özelleştirilerek yeniden yapılandırılmıştır. Özellikle, son katmanlar çıkarılarak yerine yeni katmanlar eklenmiştir. İlk olarak, modelin çıkışından sonra bir Global Average Pooling katmanı eklenmiştir. Bu katman, her özellik haritasının ortalamasını alarak, modelin parametre sayısını azaltırken aynı zamanda aşırı uyumu önlemeye yardımcı olmuştur. Ardından, 256 nöronlu bir Dense (yoğun) katman eklenmiştir. Bu katman, ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılarak, modelin doğrusal olmayan ilişkileri öğrenme kapasitesini artırmıştır. ReLU, hesaplama açısından verimli olup, negatif değerleri sıfıra eşitleyerek modelin daha hızlı ve etkili öğrenmesini sağlamıştır. Bu katmanın ardından, Dropout katmanı eklenmiştir. Dropout, eğitim sırasında rastgele nöronları devre dışı bırakarak modelin aşırı uyum yapmasını engellemiş ve genelleme yeteneğini artırmıştır. Son olarak, ikili sınıflandırma görevleri için, sigmoid aktivasyon fonksiyonuna sahip bir Dense katman eklenmiştir. Bu katman, modelin iki sınıf arasında olasılık tahminleri yapmasını sağlamış ve çıktı olarak 0 ile 1 arasında bir değer üretmiştir.

Optimizasyon süreci, Deniz Yırtıcıları Algoritması kullanılarak gerçekleştirilmiş ve bu süreçte 20 ve 30 olmak üzere iki farklı popülasyon boyutu kullanılmıştır. Her iki

popülasyon boyutu için de başlangıç stratejisi hem varsayılan parametrelerle hem de rastgele parametrelerle gerçekleştirilmiştir. Başlangıç aşamasında, popülasyonlar farklı hiperparametre kombinasyonlarını temsil eden çözümlerden oluşmuştur. Varsayılan parametrelerle başlatılan stratejide, yaygın olarak kullanılan ve literatürde önerilen varsayılan hiperparametre değerleri ile algoritma başlatılırken, rastgele parametrelerle başlatılan stratejide algoritma rastgele değerler ile başlatılmıştır. Her çözüm, doğruluk metriği kullanılarak değerlendirilmiştir. Bu metrik, modelin belirtilen hiperparametrelerle eğitilmesini ve bir doğrulama seti üzerindeki performansının ölçülmesini içermektedir. MPA algoritması, her iterasyonda çözümleri güncelleyerek daha iyi çözümler aramaktadır. Bu süreç, yırtıcıların avlarını yakalama stratejilerini simüle eden bir dizi matematiksel model kullanılarak gerçekleştirilmiştir. Optimizasyon süreci, maksimum iterasyon sayısına ulaşılan kadar devam etmiştir. Çözümlerin performans metrikleri doğruluk, kayıp, hassasiyet, duyarlılık, F1 skoru, AUC hesaplanmış ve sonuçlar incelenmiştir.

## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışmada, biyomedikal görüntülerin sınıflandırılmasında kullanılan altı farklı derin öğrenme modelinin (VGG16, ResNet50V2, InceptionV3, VGG19, MobileNetV2 ve DenseNet121) performans analizi ve Deniz Yırtıcıları Algoritması ile gerçekleştirilen hiperparametre optimizasyonunun sonuçları detaylı olarak incelenmiştir. Çalışmada, göğüs röntgeni ve beyin MR görüntülerinden oluşan iki farklı veri seti üzerinde gerçekleştirilen deneysel çalışmaların sonuçları, hem varsayılan parametreler hem de optimize edilmiş parametreler için karşılaştırmalı olarak sunulmuştur. Optimizasyon süreci, iki farklı popülasyon boyutu (20 ve 30) ve iki farklı başlangıç stratejisi (varsayılan ve rastgele parametreler) kullanılarak gerçekleştirilmiştir. Farklı popülasyon boyutları ve parametre başlatma stratejileri kullanılarak yapılan deneyler, modelin sınıflandırma yeteneğini etkileyebilecek çeşitli faktörleri ortaya koyabilir. Her bir modelin performansı doğruluk, hassasiyet, duyarlılık, F1 skoru ve AUC metrikleri açısından değerlendirilmiştir. Bu bölümde sunulan sonuçlar, derin öğrenme modellerinin hiperparametre optimizasyonunun sınıflandırma performansı üzerindeki etkisini, farklı model mimarilerinin göreceli performanslarını ve optimizasyon stratejilerinin etkinliğini ortaya koymaktadır. Sonuçlar, önerilen optimizasyon yaklaşımının biyomedikal görüntü sınıflandırma problemlerindeki etkinliğini ve potansiyel klinik uygulamalardaki değerini göstermektedir.

### 4.1. Sonuçlar

Bu bölümde, göğüs röntgeni ve beyin MR görüntüleme veri setleri için elde edilen deneysel sonuçlar, performans metriklerini karşılaştıran detaylı tablolar halinde sunulacaktır. Tablolar, her bir veri seti için farklı derin öğrenme modellerinin (InceptionV3, VGG16, InceptionResNetV2, ResNet50V2, VGG19 ve MobileNetV2) doğruluk, hassasiyet, duyarlılık ve AUC gibi performans metriklerini içerecek ve hiperparametre optimizasyonunun bu metrikler üzerindeki etkisini gösterecektir.

#### 4.1.1. Göğüs Röntgeni Veri Seti İçin Sonuçlar

Çizelge 4.1, Göğüs Röntgeni veri seti için VGG16 modelinde MPA algoritması sonuçlarını göstermektedir. Bu tablo, VGG16 modelinin Göğüs Röntgeni veri seti üzerinde MPA algoritması ile optimize edildiğinde elde edilen sonuçları sunmaktadır. Varsayılan parametrelerle %86.21 doğruluk değeri elde eden model, optimizasyon sonucunda bir performans artışı göstermiştir. MPA algoritması ile gerçekleştirilen kapsamlı optimizasyon sürecinde, farklı hiperparametre kombinasyonları test edilmiş ve en yüksek performans %90.22 doğruluk değeri ile elde edilmiştir.

Varsayılan parametrelerle başlatılan optimizasyon sürecinde, algoritma bu başlangıç noktasından hareketle arama uzayını keşfetmiş ve kademeli olarak daha iyi sonuçlara ulaşmıştır. Öte yandan, rastgele başlangıç parametreleriyle başlatılan optimizasyon süreçlerinde, farklı başlangıç noktalarından hareketle daha geniş bir arama uzayı taranmış ve çeşitli performans sonuçları elde edilmiştir. Her iki başlangıç stratejisinde de dikkat çekici olan, AUC değerlerinin tutarlı bir şekilde %95'in üzerinde seyretmesidir. Bu durum, başlangıç stratejisinden bağımsız olarak modelin güvenilir sınıflandırma performansı sergilediğini göstermektedir.

Optimizasyon sürecinde test edilen farklı konfigürasyonlar arasında, özellikle öğrenme oranının 0.01, optimizasyon fonksiyonunun Adam, parti boyutunun 128, nöron düşürme oranının 0.5 ve iterasyon sayısının 20 olduğu kombinasyon en başarılı sonuçları vermiştir. Bu konfigürasyon ile elde edilen %92.05 hassasiyet, %92.56 geri çağırma, %92.33 F1 skoru ve etkileyici bir %95.99 AUC değeri, modelin sınıflandırma performansının tutarlılığını ve güvenilirliğini göstermektedir. Kayıp değerinin %24.91'e kadar düşürülmesi, modelin öğrenme sürecinin etkinliğini vurgulamaktadır.

MPA algoritmasının hem varsayılan hem de rastgele başlangıç parametreleriyle etkili sonuçlar üretebildiğini göstermektedir. Varsayılan parametrelere (%86.21) optimize edilmiş parametrelere (%90.22) geçişte yaklaşık %4'lük bir performans artışı sağlanması, optimizasyon sürecinin başarısını göstermektedir.

**Çizelge 4.1.** Göğüs röntgeni veri seti için VGG16 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>	0.001	0.001	0.001	0.01
		<b>Optimizasyon Fonksiyonu</b>	Nadam	Nadam	RMSprop	Adam
		<b>Parti Boyutu</b>	16	16	64	128
		<b>Nöron Düşürme Oranı</b>	0.2	0.2	0.5	0.5
		<b>İterasyon</b>	10	5	10	20
	<b>Optimize Doğruluk Değeri</b>		89.74%	90.06%	90.06%	<b>90.22%</b>
	<b>Kayıp Değeri</b>		25.53%	25.12%	25.12%	24.91%
	<b>Hassasiyet Değeri</b>		90.54%	92.05%	92.05%	92.05%
	<b>Geri Çağırma Değeri</b>		93.33%	92.05%	92.05%	92.56%
	<b>F1 Skoru</b>		91.91%	92.05%	92.05%	92.33%
<b>AUC Değeri</b>		95.38%	95.75%	95.75%	95.99%	
<b>Çalışma Zamanı</b>		30:22:19	29:57:54	44:29:44	44:29:44	
<b>Varsayılan VGG16</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b>	0.001			
		<b>Optimizasyon Fonksiyonu</b>	Adam			
<b>Parti Boyutu</b>		32				
<b>Nöron Düşürme Oranı</b>		0.5				
		<b>İterasyon</b>	10			
<b>Varsayılan Doğruluk Değeri</b>		86.21%				

Çizelge 4.2, göğüs röntgeni veri seti üzerinde InceptionV3 modelinin MPA algoritması ile optimize edilmiş sonuçlarını detaylı bir şekilde sunmaktadır. Varsayılan parametrelerle %83.17 doğruluk değeri elde eden model, optimizasyon sonucunda bir performans artışı göstermiştir. MPA algoritması ile gerçekleştirilen kapsamlı optimizasyon sürecinde, farklı hiperparametre kombinasyonları test edilmiş ve en yüksek performans %87.01 doğruluk değeri ile elde edilmiştir.

30 popülasyon boyutunda, optimizasyon performansında bir artış gözlemlenmiştir. Rastgele başlangıç parametreleri ile başlatılan model, RMSprop optimizasyonu ve 32'lik parti boyutu ile %87.02 gibi bir doğruluk değerine ulaşmıştır. Bu konfigürasyonda öğrenme oranının 0.01'e yükseltilmesi, daha agresif bir öğrenme

stratejisinin başarılı olduğunu göstermektedir. Varsayılan başlangıç parametreleri ile başlatılan model ise yine RMSprop optimizasyonu tercih ederek, ancak daha küçük bir parti boyutu (16) ile %86.22 doğruluk değeri elde etmiştir.

Hesaplama maliyeti açısından, 20 popülasyon boyutundaki optimizasyonlar yaklaşık 23 saat sürerken, 30 popülasyon boyutunda bu süre 39 saate çıkmıştır. Varsayılan parametrelerden (%83.17) en iyi optimize edilmiş parametrelere (%87.02) geçişte sağlanan yaklaşık %4'lük iyileşme optimizasyonun başarıya ulaştığını söylemektedir.

**Çizelge 4.2.** Göğüs röntgeni veri seti için InceptionV3 modelinde MPA algoritması sonuçları

Popülasyon Boyutu		20	20	30	30
Başlangıç Parametre Şekli		Rastgele	Varsayılan	Rastgele	Varsayılan
En İyi Parametreler	Öğrenme Oranı	0.0001	0.0001	0.01	0.0001
	Optimizasyon Fonksiyonu	Adam	Nadam	RMSprop	RMSprop
	Parti Boyutu	128	64	32	16
	Nöron Düşürme Oranı	0.7	0.2	0.2	0.2
	İterasyon	20	10	10	10
Optimize Doğruluk Değeri		84.45%	85.09%	<b>87.01%</b>	86.21%
Kayıp Değeri		36.19%	37.96%	37.40%	34.73%
Hassasiyet Değeri		84.14%	82.59%	87.22%	87.16%
Geri Çağırma Değeri		92.56%	96.15%	92.82%	90.51%
F1 Skoru		88.15%	88.86%	89.93%	88.80%
AUC Değeri		91.57%	93.16%	92.70%	92.25%
Çalışma Zamanı		23:17:51	23:01:43	39:04:25	39:09:55
Varsayılan InceptionV3	Varsayılan Parametreler	Öğrenme Oranı 0.001 Optimizasyon Fonksiyonu Adam Parti Boyutu 32 Nöron Düşürme Oranı 0.5 İterasyon 10			
	Varsayılan Doğruluk Değeri		83.17%		

Çizelge 4.3, göğüs röntgeni veri seti üzerinde ResNet50V2 modelinin MPA algoritması ile optimize edilmiş sonuçlarını göstermektedir. ResNet50V2 modeli, göğüs

röntgeni veri seti üzerinde varsayılan parametrelerle %89.42 doğruluk değeri elde etmiştir. MPA algoritması ile gerçekleştirilen kapsamlı optimizasyon sürecinde, farklı hiperparametre kombinasyonları test edilmiş ve en yüksek performans %92.46 doğruluk değeri ile elde edilmiştir.

30 popülasyon boyutunda ve varsayılan başlangıç parametreleri kullanıldığında optimizasyon performansında belirgin bir artış gözlemlenmiştir. Adam optimizasyonu ve 32'lik parti boyutu ile optimal performans sağlanmıştır. 0.01'lik öğrenme oranı ve 0.2'lik nöron düşürme oranı kombinasyonu, modelin performansını önemli ölçüde artırmıştır. Bu konfigürasyon %92.13 hassasiyet ve %96.67 AUC değerleri ile etkileyici bir performans sergilemiştir.

20 popülasyon boyutunda da başarılı sonuçlar elde edilmiş, Nadam optimizasyonu ve 64'lük parti boyutu ile %92.14 doğruluk değerine ulaşılmıştır. SGD optimizasyonu ile test edilen model, daha düşük performans göstermiştir. Hesaplama maliyeti açısından, 20 popülasyon boyutunda yaklaşık 29.5 saat süren optimizasyon, 30 popülasyon boyutunda 49 saate çıkmıştır. Varsayılan parametrelerden (%89.42) optimize edilmiş parametrelere (%92.46) geçişte sağlanan yaklaşık %3'lük iyileşme, optimizasyonun başarısını göstermektedir.

**Çizelge 4.3.** Göğüs röntgeni veri seti için ResNET50V2 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>	0.01	0.0001	0.01	0.001
		<b>Optimizasyon Fonksiyonu</b>	Nadam	Nadam	SGD	Adam
		<b>Parti Boyutu</b>	32	16	64	32
		<b>Nöron Düşürme Oranı</b>	0.2	0.2	0.7	0.2
		<b>İterasyon</b>	20	10	20	10
	<b>Optimize Doğruluk Değeri</b>		88.62%	92.14%	90.22%	<b>92.46%</b>
	<b>Kayıp Değeri</b>		27.66%	23.11%	25.04%	24.36%
	<b>Hassasiyet Değeri</b>		88.65%	92.09%	90.02%	92.13%
	<b>Geri Çağırma Değeri</b>		96.15%	95.64%	92.05%	96.15%
<b>F1 Skoru</b>		92.25%	93.83%	92.38%	94.10%	
<b>AUC Değeri</b>		96.29%	96.64%	96.11%	96.67%	
<b>Çalışma Zamanı</b>		29:34:11	29:36:47	49:25:57	48:58:39	
<b>Varsayılan ResNet50V2</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b> <b>Optimizasyon Fonksiyonu</b> <b>Parti Boyutu</b> <b>Nöron Düşürme Oranı</b> <b>İterasyon</b>	0.001 Adam 32 0.5 10			
	<b>Varsayılan Doğruluk Değeri</b>		89.42%			

Çizelge 4.4, göğüs röntgeni veri seti üzerinde VGG19 modelinin MPA algoritması ile optimize edilmiş sonuçlarını vermektedir. VGG19 modeli, göğüs röntgeni veri seti üzerinde varsayılan parametrelerle %85.73 doğruluk değeri elde etmiştir. MPA algoritması ile gerçekleştirilen kapsamlı optimizasyon sürecinde, en yüksek performans %89.42 doğruluk değeri ile elde edilmiştir.

30 popülasyon boyutunda ve varsayılan başlangıç parametreleri kullanıldığında en iyi sonuçlar gözlemlenmiştir. Nadam optimizasyonu ve 64'lük parti boyutu optimal performans sağlamıştır. 0.001'lik öğrenme oranı ve 0.2'lik nöron düşürme oranı kombinasyonu tercih edilmiştir. Bu konfigürasyon %89.32 hassasiyet ve %93.79 AUC değerleri ile güvenilir bir performans sergilemiştir.

20 popülasyon boyutunda farklı optimizasyon stratejileri denenmiş, Adam ve Nadam optimizasyonları ile sırasıyla %88.46 ve %87.66 doğruluk değerleri elde edilmiştir. Hesaplama maliyeti açısından, 20 popülasyon boyutunda yaklaşık 38 saat süren optimizasyon, 30 popülasyon boyutunda 59 saate çıkmıştır. Varsayılan parametrelerden (%85.73) optimize edilmiş parametrelere (%89.42) geçişte sağlanan yaklaşık %3.7'lik iyileşme, optimizasyon sürecinin başarısını göstermektedir.

**Çizelge 4.4.** Göğüs röntgeni veri seti için VGG19 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30	
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan	
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>		0.001	0.001	0.001	0.001
		<b>Optimizasyon Fonksiyonu</b>		Adam	Nadam	Nadam	Nadam
		<b>Parti Boyutu</b>		32	16	32	64
		<b>Nöron Düşürme Oranı</b>		0.2	0.7	0.2	0.2
		<b>İterasyon</b>		5	10	10	20
	<b>Optimize Doğruluk Değeri</b>		88.46%	87.66%	86.37%	<b>89.42%</b>	
	<b>Kayıp Değeri</b>		32.03%	31.49%	33.07%	30.25%	
	<b>Hassasiyet Değeri</b>		90.15%	89.82%	86.05%	89.32%	
	<b>Geri Çağırma Değeri</b>		91.53%	90.51%	93.33%	94.35%	
<b>F1 Skoru</b>		90.83%	90.16%	89.54%	91.77%		
<b>AUC Değeri</b>		92.89%	93.22%	92.71%	93.79%		
<b>Çalışma Zamanı</b>		37:46:22	38:09:41	56:18:21	59:49:18		
<b>Varsayılan VGG19</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b>		0.001			
		<b>Optimizasyon Fonksiyonu</b>		Adam			
		<b>Parti Boyutu</b>		32			
		<b>Nöron Düşürme Oranı</b>		0.5			
		<b>İterasyon</b>		10			
<b>Varsayılan Doğruluk Değeri</b>		85.73%					

Çizelge 4.5, göğüs röntgeni veri seti üzerinde MobileNetV2 modelinin MPA algoritması ile optimize edilmiş değerlerini göstermektedir. MobileNetV2 modeli, göğüs röntgeni veri seti üzerinde varsayılan parametrelerle %86.85 doğruluk değeri elde etmiştir. MPA algoritması ile gerçekleştirilen kapsamlı optimizasyon sürecinde, en yüksek performans %90.70 doğruluk değeri ile elde edilmiştir.

20 popülasyon boyutunda, Adam optimizasyonu ve 32'lik parti boyutu ile optimal sonuçlar gözlemlenmiştir. 0.001'lik öğrenme oranı ve 0.2'lik nöron düşürme oranı kombinasyonu, modelin performansını önemli ölçüde artırmıştır. Bu konfigürasyon %94.14 hassasiyet ve %96.74 AUC değerleri ile etkileyici bir performans sergilemiştir.

30 popülasyon boyutunda da benzer sonuçlar elde edilmiş, Nadam optimizasyonu ve 64'lük parti boyutu ile %90.70 doğruluk değerine ulaşılmıştır. Hesaplama maliyeti açısından, 20 popülasyon boyutunda yaklaşık 20.5 saat süren optimizasyon, 30 popülasyon boyutunda 30 saate çıkmıştır. Varsayılan parametrelerden (%86.85) optimize edilmiş parametrelere (%90.70) geçişte sağlanan yaklaşık %3.85'lik iyileşme, optimizasyonun başarısını göstermektedir.

**Çizelge 4.5.** Göğüs röntgeni veri seti için MobileNetV2 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>	0.001	0.0001	0.001	0.01
		<b>Optimizasyon Fonksiyonu</b>	Adam	RMSprop	Adam	Nadam
		<b>Parti Boyutu</b>	64	32	64	64
		<b>Nöron Düşürme Oranı</b>	0.5	0.2	0.5	0.2
		<b>İterasyon</b>	10	5	10	20
	<b>Optimize Doğruluk Değeri</b>		90.70%	90.54%	90.22%	<b>90.70%</b>
	<b>Kayıp Değeri</b>		23.48%	23.22%	29.16%	25.71%
	<b>Hassasiyet Değeri</b>		94.14%	90.07%	89.07%	90.68%
	<b>Geri Çağırma Değeri</b>		90.76%	95.38%	96.15%	94.87%
<b>F1 Skoru</b>		92.42%	92.65%	92.47%	92.73%	
<b>AUC Değeri</b>		96.74%	96.51%	95.66%	96.06%	
<b>Çalışma Zamanı</b>		20:30:50	20:18:47	30:14:17	30:22:55	
<b>Varsayılan MobileNetV2</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b>	0.001			
		<b>Optimizasyon Fonksiyonu</b>	Adam			
<b>Parti Boyutu</b>		32				
<b>Nöron Düşürme Oranı</b>		0.5				
<b>İterasyon</b>		10				
<b>Varsayılan Doğruluk Değeri</b>		86.85%				

Çizelge 4.6, göğüs röntgeni veri seti üzerinde DenseNet121 modelinin MPA algoritması ile optimize edilmiş sonuçlarını göstermektedir. DenseNet121 modeli, başlangıçta %88.78 olan doğruluk değerini optimizasyon sonrasında %90.54'e yükseltmiştir. MPA algoritması ile gerçekleştirilen optimizasyon sürecinde, farklı hiperparametre kombinasyonları test edilmiş ve en iyi sonuçlar 20 popülasyon boyutunda elde edilmiştir.


Varsayılan başlangıç parametreleri ile başlatılan model, Nadam optimizasyonu ve 128'lik parti boyutu ile %90.54 doğruluk değerine ulaşmıştır. 0.01'lik öğrenme oranı ve 0.5'lik nöron düşürme oranı kombinasyonu tercih edilmiştir. Bu konfigürasyon %89.87 hassasiyet ve %96.13 AUC değerleri ile güvenilir bir performans sergilemiştir.

30 popülasyon boyutunda, RMSprop optimizasyonu test edilmiş ancak daha düşük doğruluk değerleri elde edilmiştir. Hesaplama maliyeti açısından, 20 popülasyon boyutunda yaklaşık 24 saat süren optimizasyon, 30 popülasyon boyutunda 34 saate çıkmıştır. Varsayılan parametrelere (%88.78) optimize edilmiş parametrelere (%90.54) geçişte sağlanan yaklaşık %1.76'lık iyileşme, modelin başlangıçta da iyi performans gösterdiğini ancak optimizasyonla daha da iyileştirilebildiğini göstermektedir.

**Çizelge 4.6.** Göğüs röntgeni veri seti için DenseNet121 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>	0.01	0.01	0.001	0.001
		<b>Optimizasyon Fonksiyonu</b>	Nadam	Nadam	Nadam	RMSprop
		<b>Parti Boyutu</b>	16	128	16	16
		<b>Nöron Düşürme Oranı</b>	0.5	0.5	0.7	0.5
		<b>İterasyon</b>	10	10	20	20
	<b>Optimize Doğruluk Değeri</b>		86.21%	<b>90.54%</b>	89.90%	90.38%
	<b>Kayıp Değeri</b>		31.92%	28.02%	25.84%	29.76%
	<b>Hassasiyet Değeri</b>		83.04%	89.87%	90.37%	90.24%
	<b>Geri Çağırma Değeri</b>		97.94%	95.64%	93.84%	94.87%
<b>F1 Skoru</b>		89.88%	92.67%	92.07%	92.50%	
<b>AUC Değeri</b>		96.24%	96.13%	95.70%	95.53%	
<b>Çalışma Zamanı</b>		18:13:11	24:21:48	33:38:51	34:22:15	
<b>Varsayılan DenseNet121</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b>	0.001			
		<b>Optimizasyon Fonksiyonu</b>	Adam			
		<b>Parti Boyutu</b>	32			
		<b>Nöron Düşürme Oranı</b>	0.5			
		<b>İterasyon</b>	10			
<b>Varsayılan Doğruluk Değeri</b>		88.78%				

Şekil 4.1'de, göğüs röntgeni veri seti için derin öğrenme modellerinin popülasyon boyutuna (20 ve 30) ve başlangıç stratejilerine (rastgele veya varsayılan) göre doğruluk değeri artışları gösterilmiştir.



Şekil 4.1. Göğüs röntgeni veri seti için doğruluk değeri artışları

#### 4.1.2. Beyin MR Veri Seti İçin Sonuçlar

Çizelge 4.7, Beyin MR veri seti üzerinde VGG16 modelinin MPA algoritması ile optimize edilmiş performans değerlendirmesini göstermektedir. VGG16 mimarisi, ilk aşamada varsayılan parametrelerle %94.99 başarı oranı yakalamıştır. MPA algoritmasının uygulanmasıyla gerçekleştirilen kapsamlı iyileştirme sürecinde, model %97.30'luk etkileyici bir doğruluk seviyesine ulaşmıştır.

30 popülasyon boyutunda ve varsayılan başlangıç parametreleri kullanıldığında en iyi sonuçlar gözlemlenmiştir. Nadam optimizasyonu ve 64'lük parti boyutu optimal performans sağlamıştır. 0.001'lik öğrenme oranı ve 0.2'lik nöron düşürme oranı kombinasyonu tercih edilmiştir. Bu konfigürasyon %98.13 hassasiyet ve %99.39 AUC değerleri ile etkileyici bir performans sergilemiştir.

20 popülasyon boyutunda da başarılı sonuçlar elde edilmiş, Nadam optimizasyonu ve 32'lik parti boyutu ile %97.00 doğruluk değerine ulaşılmıştır. Varsayılan parametrelerden (%94.99) optimize edilmiş parametrelere (%97.30) geçişte sağlanan yaklaşık %2.31'lik iyileşme, optimizasyon sürecinin başarısını göstermektedir.

Çizelge 4.7. Beyin MR veri seti için VGG16 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>	0.001	0.001	0.001	0.001
		<b>Optimizasyon Fonksiyonu</b>	Nadam	Nadam	Adam	Nadam
		<b>Parti Boyutu</b>	32	32	64	64
		<b>Nöron Düşürme Oranı</b>	0.2	0.2	0.5	0.2
		<b>İterasyon</b>	10	20	20	20
	<b>Optimize Doğruluk Değeri</b>		96.19%	97.00%	96.42%	<b>97.30%</b>
	<b>Kayıp Değeri</b>		09.87%	06.93%	09.22%	07.24%
	<b>Hassasiyet Değeri</b>		96.64%	98.04%	96.84%	98.13%
	<b>Geri Çağırma Değeri</b>		99.00%	98.46%	99.05%	98.73%
	<b>F1 Skoru</b>		97.81%	98.25%	97.94%	98.43%
<b>AUC Değeri</b>		98.99%	99.43%	99.10%	99.39%	
<b>Çalışma Zamanı</b>		53:18:41	52:23:49	69:55:09	71:22:25	
<b>Varsayılan VGG16</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b> <b>Optimizasyon Fonksiyonu</b> <b>Parti Boyutu</b> <b>Nöron Düşürme Oranı</b> <b>İterasyon</b>	0.001 Adam 32 0.5 10			
	<b>Varsayılan Doğruluk Değeri</b>		94.99%			

Çizelge 4.8, Beyin MR veri seti üzerinde InceptionV3 modelinin MPA algoritması ile optimize edilmiş metriklerini göstermektedir. InceptionV3 modeli, başlangıçta %96.49 olan başarı oranını, optimize edilmiş parametrelerle %98.33 seviyesine taşımayı başarmıştır

30 popülasyon boyutunda ve Nadam optimizasyonu ile en iyi sonuçlar gözlemlenmiştir. 16'lık parti boyutu ve 0.0001'lik öğrenme oranı optimal performans sağlamıştır. 0.2'lik nöron düşürme oranı tercih edilmiştir. Bu konfigürasyon %99.29 hassasiyet ve %99.73 AUC değerleri ile üstün bir performans sergilemiştir.

20 popülasyon boyutunda da tatmin edici sonuçlar elde edilmiş, aynı optimizasyon stratejisi ile %97.32 doğruluk değerine ulaşılmıştır. Varsayılan

parametrelerden (%96.49) optimize edilmiş parametrelere (%98.33) geçişte sağlanan yaklaşık %1.84'lük iyileşme, modelin başarılı bir şekilde optimize edildiğini göstermektedir.

**Çizelge 4.8.** Beyin MR veri seti için InceptionV3 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30	
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan	
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>		0.0001	0.0001	0.0001	0.0001
		<b>Optimizasyon Fonksiyonu</b>		Nadam	Nadam	Nadam	Nadam
		<b>Parti Boyutu</b>		32	32	16	16
		<b>Nöron Düşürme Oranı</b>		0.2	0.2	0.2	0.2
	<b>İterasyon</b>		10	10	20	20	
	<b>Optimize Doğruluk Değeri</b>		97.25%	97.32%	98.22%	<b>98.33%</b>	
	<b>Kayıp Değeri</b>		08.23%	07.48%	05.21%	05.48%	
	<b>Hassasiyet Değeri</b>		98.51%	97.90%	98.69%	99.29%	
	<b>Geri Çağırma Değeri</b>		98.28%	99.00%	99.24%	98.76%	
	<b>F1 Skoru</b>		98.39%	98.45%	98.96%	99.03%	
<b>AUC Değeri</b>		99.27%	99.37%	99.48%	99.73%		
<b>Çalışma Zamanı</b>		19:26:35	19:41:38	30:17:23	30:08:22		
<b>Varsayılan InceptionV3</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b>		0.001			
		<b>Optimizasyon Fonksiyonu</b>		Adam			
		<b>Parti Boyutu</b>		32			
		<b>Nöron Düşürme Oranı</b>		0.5			
		<b>İterasyon</b>		10			
<b>Varsayılan Doğruluk Değeri</b>		96.49%					

Çizelge 4.9, Beyin MR veri seti üzerinde ResNet50V2 modelinin MPA algoritması ile optimize edilmiş sonuçlarını göstermektedir. ResNet50V2 mimarisi, ilk etapta etkileyici bir performans sergileyerek %97.80 doğruluk oranı yakalamıştır. MPA algoritmasının uygulanmasıyla gerçekleştirilen optimizasyon süreci sonucunda, model %99.23 gibi dikkat çekici bir başarı seviyesine ulaşmıştır.

30 popülasyon boyutunda ve Nadam optimizasyonu kullanılarak elde edilen en iyi sonuçlarda, 64'lük parti boyutu ve 0.2'lik nöron düşürme oranı tercih edilmiştir. Bu

yapılandırma ile model, %99.62 hassasiyet ve %99.92 AUC değerleri gibi üstün performans metriklerine erişmiştir.

Hesaplama maliyeti perspektifinden bakıldığında, 20 popülasyon boyutunda yaklaşık 32 saat süren optimizasyon süreci, 30 popülasyon boyutunda 55 saate yükselmiştir. Varsayılan parametrelerden (%97.80) optimize edilmiş parametrelere (%99.23) geçişte sağlanan yaklaşık %1.43'lük iyileşme, modelin başarılı bir şekilde rafine edildiğini göstermektedir.

**Çizelge 4.9.** Beyin MR veri seti için ResNet50V2 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30	
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan	
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>		0.01	0.001	0.001	0.001
		<b>Optimizasyon Fonksiyonu</b>		Adamax	Nadam	Nadam	Nadam
		<b>Parti Boyutu</b>		64	16	32	64
		<b>Nöron Düşürme Oranı</b>		0.5	0.2	0.2	0.2
		<b>İterasyon</b>		20	20	20	20
	<b>Optimize Doğruluk Değeri</b>		98.59%	99.12%	99.07%	<b>99.23%</b>	
	<b>Kayıp Değeri</b>		03.95%	02.60%	02.45%	02.17%	
	<b>Hassasiyet Değeri</b>		99.24%	99.67%	99.40%	99.62%	
	<b>Geri Çağırma Değeri</b>		99.11%	99.30%	99.51%	99.48%	
	<b>F1 Skoru</b>		99.18%	99.48%	99.46%	99.55%	
<b>AUC Değeri</b>		99.71%	99.91%	99.91%	99.92%		
<b>Çalışma Zamanı</b>		30:58:44	32:18:05	53:59:12	55:51:22		
<b>Varsayılan ResNet50V2</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b>		0.001			
		<b>Optimizasyon Fonksiyonu</b>		Adam			
		<b>Parti Boyutu</b>		32			
		<b>Nöron Düşürme Oranı</b>		0.5			
		<b>İterasyon</b>		10			
<b>Varsayılan Doğruluk Değeri</b>		97.80%					

Çizelge 4.10, Beyin MR veri seti üzerinde VGG19 modelinin MPA algoritması ile optimize edilmiş sonuçlarını göstermektedir. VGG19 modeli, başlangıçta %94.71 olan doğruluk oranını, titizlikle gerçekleştirilen optimizasyon çalışmaları sonucunda %96.44 seviyesine taşımayı başarmıştır.

30 popülasyon boyutunda ve Nadam optimizasyonu kullanılarak gerçekleştirilen deneylerde, 64'lük parti boyutu ve 0.2'lik nöron düşürme oranı optimal sonuçlar vermiştir. Bu konfigürasyon ile model, %97.42 hassasiyet ve %98.82 AUC değerlerine ulaşmıştır.

Zaman açısından değerlendirildiğinde, 20 popülasyon boyutunda yaklaşık 18-25 saat aralığında tamamlanan optimizasyon süreci, 30 popülasyon boyutunda 38-41 saat seviyelerine çıkmıştır. Başlangıç parametrelerinden (%94.71) optimize edilmiş parametrelere (%96.44) geçişte elde edilen %1.73'lük performans artışı, modelin iyileştirme potansiyelini ortaya koymaktadır.

Çizelge 4.10. Beyin MR veri seti için VGG19 modelinde MPA algoritması sonuçları

Optimizasyon	Popülasyon Boyutu		20	20	30	30
	Başlangıç Parametre Şekli		Rastgele	Varsayılan	Rastgele	Varsayılan
	En İyi Parametreler	Öğrenme Oranı	0.001	0.001	0.001	0.001
		Optimizasyon Fonksiyonu	Adammax	RMSprop	Nadam	Nadam
		Parti Boyutu	32	32	16	64
		Nöron Düşürme Oranı	0.7	0.2	0.2	0.2
		İterasyon	20	20	10	20
	Optimize Doğruluk Değeri		95.15%	95.98%	95.22%	<b>96.44%</b>
	Kayıp Değeri		13.56%	10.57%	12.15%	09.46%
	Hassasiyet Değeri		97.10%	96.75%	97.74%	97.42%
	Geri Çağırma Değeri		97.25%	98.62%	96.66%	98.46%
	F1 Skoru		97.18%	97.68%	97.20%	97.94%
AUC Değeri		97.51%	98.53%	98.18%	98.82%	
Çalışma Zamanı		25:20:44	18:28:02	38:06:21	41:22:39	
Varsayılan VGG19	Varsayılan Parametreler	Öğrenme Oranı	0.001			
		Optimizasyon Fonksiyonu	Adam			
Parti Boyutu		32				
Nöron Düşürme Oranı		0.5				
İterasyon		10				
Varsayılan Doğruluk Değeri		94.71%				

Çizelge 4.11, Beyin MR veri seti üzerinde MobileNetV2 modelinin MPA algoritması ile optimize edilmiş sonuçlarını göstermektedir. Model, %98.52 gibi yüksek bir başlangıç doğruluk oranı ile dikkat çekmiş ve MPA algoritması ile gerçekleştirilen kapsamlı optimizasyon çalışmaları sonucunda bu değeri %99.21'e kadar yükseltmeyi başarmıştır.

Optimizasyon sürecinde, 30 popülasyon boyutunda ve Nadam optimizasyonu kullanılarak yürütülen deneylerde, 16'lık parti boyutu ve 0.2'lik nöron düşürme oranı en verimli sonuçları sağlamıştır. Bu yapılandırma %99.75 geri çağırma ve %99.68 AUC değeri gibi üstün performans metriklerine ulaşmıştır. Bu değerler, modelin sınıflandırma görevinde olağanüstü bir başarı elde ettiğini göstermektedir.

Hesaplama maliyeti açısından değerlendirildiğinde, MobileNetV2'nin oldukça verimli olduğu görülmektedir. 20 popülasyon boyutunda yaklaşık 13-14 saat süren optimizasyon süreci, 30 popülasyon boyutunda 23-24 saate yükselmiştir. %0.69'luk bir iyileşme sağlanmıştır.

**Çizelge 4.11.** Beyin MR veri seti için MobileNetV2 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>		20	20	30	30	
	<b>Başlangıç Parametre Şekli</b>		Rastgele	Varsayılan	Rastgele	Varsayılan	
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>		0.01	0.001	0.001	0.001
		<b>Optimizasyon Fonksiyonu</b>		Adamax	Nadam	Nadam	Nadam
		<b>Parti Boyutu</b>		64	16	16	16
		<b>Nöron Düşürme Oranı</b>		0.2	0.2	0.2	0.2
		<b>İterasyon</b>		20	20	10	20
	<b>Optimize Doğruluk Değeri</b>		98.06%	99.14%	98.75%	<b>99.21%</b>	
	<b>Kayıp Değeri</b>		05.72%	02.68%	03.97%	02.58%	
	<b>Hassasiyet Değeri</b>		98.04%	99.38%	99.40%	99.33%	
	<b>Geri Çağırma Değeri</b>		99.73%	99.62%	99.14%	99.75%	
	<b>F1 Skoru</b>		98.88%	99.50%	99.27%	99.54%	
<b>AUC Değeri</b>		99.42%	99.89%	99.80%	99.68%		
<b>Çalışma Zamanı</b>		13:00:29	13:49:51	23:02:57	23:14:43		
<b>Varsayılan MobileNetV2</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b>		0.001			
		<b>Optimizasyon Fonksiyonu</b>		Adam			
		<b>Parti Boyutu</b>		32			
		<b>Nöron Düşürme Oranı</b>		0.5			
		<b>İterasyon</b>		10			
<b>Varsayılan Doğruluk Değeri</b>		98.52%					

Çizelge 4.12, Beyin MR veri seti üzerinde DenseNet121 modelinin MPA algoritması ile optimize edilmiş sonuçlarını göstermektedir. Model, %97.25 gibi yüksek bir başlangıç doğruluk oranından başlayarak, MPA algoritması ile gerçekleştirilen sistematik optimizasyon çalışmaları sonucunda %98.38 seviyesine ulaşmayı başarmıştır.

30 popülasyon boyutunda ve Nadam optimizasyonu kullanılarak gerçekleştirilen deneylerde, 128'lik parti boyutu ve 0.2'lik nöron düşürme oranı optimal sonuçlar

vermiştir. Bu konfigürasyon ile model, %98.38 hassasiyet, %99.75 geri çağırma, %99.06 F1 skoru ve %99.74 AUC değeri gibi etkileyici performans metriklerine ulaşmıştır.

Hesaplama zamanı 30 popülasyon boyutunda 25-26 saate çıkmıştır. Başlangıç doğruluk değeri olan %97.25'ten optimize edilmiş doğruluk değeri olan %98.38'e ulaşılarak yaklaşık %1.13'lük bir iyileşme sağlanmıştır.

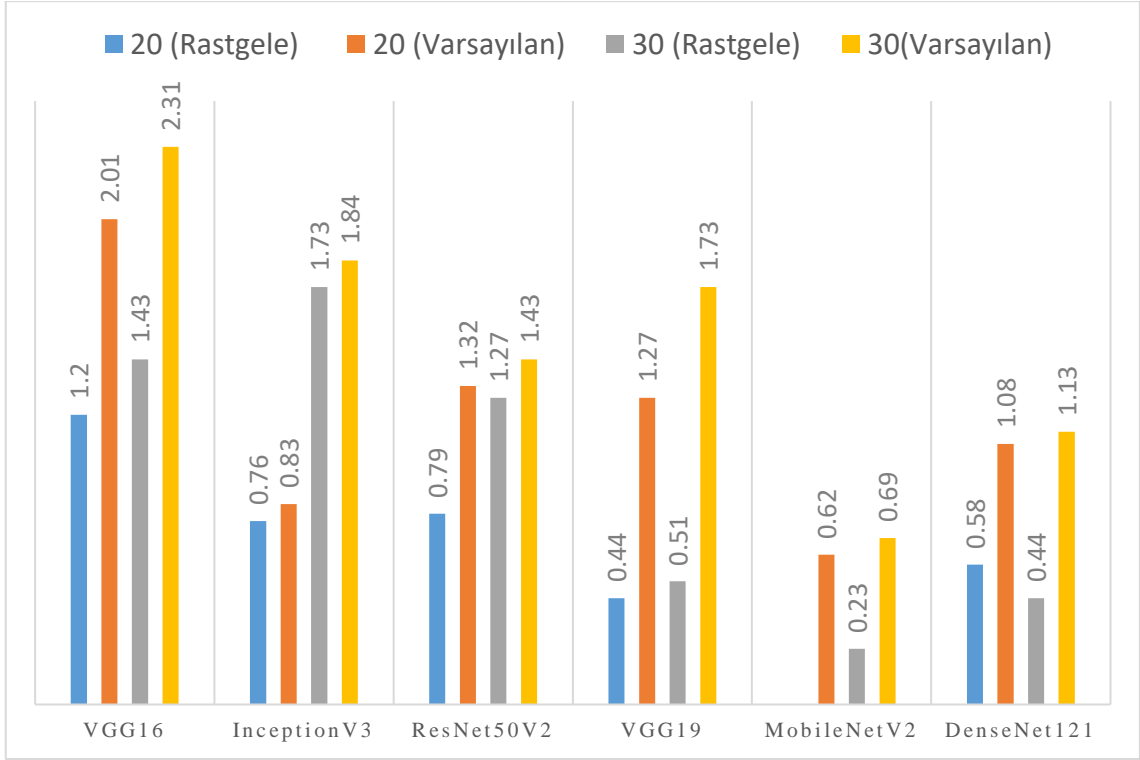
Göğüs röntgeni veri setinde en yüksek iyileşmeyi VGG16 modeli göstermiştir. Başlangıç doğruluk değeri %86.21 olan model, optimizasyon sonrası %90.22'e ulaşarak yaklaşık %4.01'lik bir iyileşme sağlamıştır. En düşük iyileşmeyi ise DenseNet121 modeli göstermiş olup, %88.78'den %90.54'e yükselerek %1.76'lık bir iyileşme kaydetmiştir.

Beyin MR veri setinde en yüksek iyileşmeyi VGG16 modeli göstermiştir. Başlangıç doğruluk değeri %94.99 olan model, optimizasyon sonrası %97.30'a ulaşarak yaklaşık %2.31'lik bir iyileşme sağlamıştır. En düşük iyileşmeyi ise MobileNetV2 modeli göstermiş olup, %98.52'den %99.21'e yükselerek %0.69'luk bir iyileşme kaydetmiştir.

Çizelge 4.12. Beyin MR veri seti için DenseNet121 modelinde MPA algoritması sonuçları

<b>Optimizasyon</b>	<b>Popülasyon Boyutu</b>	20	20	30	30	
	<b>Başlangıç Parametre Şekli</b>	Rastgele	Varsayılan	Rastgele	Varsayılan	
	<b>En İyi Parametreler</b>	<b>Öğrenme Oranı</b>	0.001	0.001	0.001	0.001
		<b>Optimizasyon Fonksiyonu</b>	Adam	Nadam	Nadam	Nadam
		<b>Parti Boyutu</b>	16	32	128	32
		<b>Nöron Düşürme Oranı</b>	0.5	0.2	0.5	0.2
		<b>İterasyon</b>	10	10	10	10
	<b>Optimize Doğruluk Değeri</b>	97.83%	98.33%	97.69%	<b>98.38%</b>	
	<b>Kayıp Değeri</b>	05.21%	04.01%	05.78%	04.24%	
	<b>Hassasiyet Değeri</b>	98.47%	98.58%	97.96%	98.38%	
	<b>Geri Çağırma Değeri</b>	99.00%	99.48%	99.38%	99.75%	
	<b>F1 Skoru</b>	98.74%	99.03%	98.66%	99.06%	
<b>AUC Değeri</b>	99.65%	99.66%	99.63%	99.74%		
<b>Çalışma Zamanı</b>	12:56:15	12:33:55	25:49:55	25:03:22		
<b>Varsayılan DenseNet121</b>	<b>Varsayılan Parametreler</b>	<b>Öğrenme Oranı</b> <b>Optimizasyon Fonksiyonu</b> <b>Parti Boyutu</b> <b>Nöron Düşürme Oranı</b> <b>İterasyon</b>	0.001 Adam 32 0.5 10			
	<b>Varsayılan Doğruluk Değeri</b>	97.25%				

Şekil 4.2'de, beyin MR veri seti için derin öğrenme modellerinin popülasyon boyutuna (20 ve 30) ve başlangıç stratejilerine (rastgele veya varsayılan) göre doğruluk değeri artışları gösterilmiştir.



Şekil 4.2. Beyin MR veri seti için doğruluk değeri artışları

## 5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, göğüs röntgeni ve beyin MR görüntülerinin sınıflandırılması için farklı derin öğrenme mimarilerinin Deniz Yırtıcıları Algoritması ile optimizasyonu gerçekleştirilmiş ve kapsamlı analizler yapılmıştır. Elde edilen sonuçlar ve öneriler bu bölümde sunulmuştur.

### 5.1 Sonuçlar

Bu çalışma, göğüs röntgeni ve beyin MR görüntülerinin sınıflandırılmasında derin öğrenme modellerinin performansını optimize etmek için MPA algoritmasının etkinliğini değerlendirmiştir. VGG16, InceptionV3, ResNet50V2, VGG19, MobileNetV2 ve DenseNet121 gibi farklı mimarilere sahip modeller, her iki veri seti üzerinde test edilmiş ve MPA algoritması ile hiperparametreleri optimize edilmiştir. Sonuçlar, MPA'nın tüm modellerde ve veri setlerinde, varsayılan parametrelere kıyasla önemli performans iyileştirmeleri sağladığını göstermektedir. Özellikle, göğüs röntgeni veri setinde ResNet50V2 modeli %92.47'lik en yüksek doğruluk değerine ulaşırken, beyin MR veri setinde yine ResNet50V2 modeli %99.24'lük bir doğruluk değeri elde etmiştir. Bu iyileşmeler, MPA algoritmasının etkili bir optimizasyon aracı olduğunu ve derin öğrenme modellerinin performansını artırmada önemli bir rol oynadığını göstermektedir.

Çalışma boyunca, farklı popülasyon boyutları (20 ve 30), başlangıç parametre şekilleri (rastgele ve varsayılan), öğrenme oranları, optimizasyon fonksiyonları (Adam, Nadam, RMSprop, SGD, Adamax), parti boyutları, nöron düşürme oranları ve iterasyon sayıları test edilmiştir. Genel olarak, 30 popülasyon boyutunun daha iyi sonuçlar verdiği gözlemlenmiştir, ancak bu durum hesaplama maliyetini de artırmıştır.

Öğrenme oranı, parti boyutu, nöron düşürme oranı ve optimizasyon fonksiyonları gibi hiperparametrelerin optimal değerleri ise modele ve veri setine bağlı olarak değişiklik göstermiştir. Öğrenme oranının 0.001 ve 0.01 arasında ayarlanması, genellikle en iyi sonuçları vermiştir. Adam ve Nadam optimizasyon fonksiyonları, çoğu modelde en iyi performansı sağlamıştır. MPA algoritmasının performansı, 0.2 nöron

düşürme oranı ve 16-64 arasındaki parti boyutlarıyla elde edilmiştir. Bu parametreler, gelecekteki benzer çalışmalar için referans değerler olarak kullanılabilir.

Hesaplama maliyeti açısından, optimizasyon süreleri 12 saat ile 71 saat arasında değişmektedir. Modelin karmaşıklığı ve popülasyon boyutu, çalışma zamanını etkileyen önemli faktörlerdir. Hesaplama süreleri açısından, MobileNetV2 ve DenseNet121 mimarileri her iki veri seti için de en verimli modeller olarak öne çıkmıştır. Bu modeller, 12-25 saatlik optimizasyon süreleriyle, VGG16 ve ResNet50V2 gibi daha karmaşık mimarilere kıyasla önemli bir avantaj sağlamıştır. Özellikle kısıtlı hesaplama kaynaklarına sahip uygulamalar için bu modellerin tercih edilmesi önerilebilir.

20 popülasyon ve 30 popülasyon ile elde edilen iyileşme oranları birbirine oldukça yakın olup, doğruluk veya performans artışında belirgin bir fark gözlemlenmemektedir. Ancak, popülasyon boyutundaki bu artış, algoritmanın çalışma süresini ciddi ölçüde uzatmaktadır. Elde edilen sınırlı iyileşme oranı göz önüne alındığında, artan hesaplama maliyeti göz ardı edilemez. Dolayısıyla, daha büyük popülasyon boyutları yerine optimum bir değer seçimi, hem hesaplama süresini azaltmak hem de yeterli performansı korumak adına daha uygun bir strateji olacaktır.

## 5.2 Öneriler

MPA algoritması, derin öğrenme modellerinin hiperparametre optimizasyonu için etkili bir yöntem olarak kullanılabilir. Çalışmada kullanılan her iki veri seti (göğüs röntgeni ve beyin MR) ve tüm modellerde, MPA varsayılan parametrelere göre performans artışı sağlamıştır. Bu nedenle, benzer tıbbi görüntü sınıflandırma problemlerinde MPA'nın kullanılması önerilir.

Model seçimi veri setinin özelliklerine ve hesaplama kaynaklarına bağlı olarak yapılmalıdır. Örneğin, MobileNetV2, göreceli olarak düşük hesaplama maliyeti ile iyi performans gösterdiğinden, kaynakların kısıtlı olduğu durumlarda tercih edilebilir. Diğer taraftan, daha yüksek hesaplama gücü mevcutsa, ResNet50V2 gibi daha karmaşık modeller daha yüksek doğruluk değerleri elde etmek için kullanılabilir. Beyin MR veri seti gibi daha karmaşık veri setlerinde, ResNet50V2 ve MobileNetV2 gibi modellerin daha iyi performans gösterdiği gözlemlenmiştir.

Optimizasyon süreci, farklı hiperparametre kombinasyonlarını denemeyi içermelidir. Bu çalışmada, popülasyon boyutu, öğrenme oranı, optimizasyon fonksiyonu ve parti boyutu gibi hiperparametreler üzerinde farklı değerler denenmiştir. Benzer şekilde, farklı problemlerde en uygun hiperparametre değerlerini bulmak için kapsamlı bir arama yapılması önerilir. Özellikle Nadam optimizasyon fonksiyonu, genel olarak iyi sonuçlar vermiştir ve denenmesi önerilebilir.

MPA'nın farklı tıbbi görüntü sınıflandırma görevlerindeki performansını değerlendirmeye odaklanabilir. Farklı veri setleri ve modeller kullanılarak MPA'nın genelleştirilebilirliği test edilebilir. Ayrıca, MPA'nın diğer optimizasyon algoritmaları ile karşılaştırılması, performansını daha iyi anlamak için faydalı olacaktır.

Gelecekteki çalışmalar için, hiperparametre optimizasyonunun daha da detaylandırılması önerilmektedir. Özellikle, farklı veri setleri ve model mimarileri için en uygun hiperparametrelerin belirlenmesi, model performansını daha da artırabilir. Ayrıca, farklı derin öğrenme modellerinin ve mimarilerinin denenmesi, belirli veri setleri için en uygun modelin seçilmesine yardımcı olabilir. Optimizasyon sürecinin uzun çalışma süreleri göz önüne alındığında, daha güçlü hesaplama kaynaklarının kullanılması, sürecin hızlandırılmasına ve daha fazla hiperparametre kombinasyonunun test edilmesine olanak tanıyabilir. Sonuç olarak, MPA algoritması, derin öğrenme modelleri üzerindeki etkisini ve potansiyel iyileştirme alanlarını göstermekte olup, bu bulguların daha geniş veri setleri ve farklı uygulama alanları üzerinde test edilmesi ile daha da zenginleştirilebilir.

## 6. KAYNAKLAR

- Abasi, A. K., Aloqaily, M. ve Guizani, M., 2023, Optimization of cnn using modified honey badger algorithm for sleep apnea detection, *Expert Systems with Applications*, 229(120484).
- Abdel-Basset, M., El-Shahat, D., Chakraborty, R. K. ve Ryan, M., 2021, Parameter estimation of photovoltaic models using an improved marine predators algorithm, *Energy Conversion Management*, 227(113491).
- Abualigah, L. ve Diabat, A., 2023, Improved multi-core arithmetic optimization algorithm-based ensemble mutation for multidisciplinary applications, *Journal of Intelligent Manufacturing*, 34(4), 1833-1874.
- Arslan, S., 2023, Güncel Metasezgisel Algoritmalarının Performansları Üzerine Karşılaştırılmalı Bir Çalışma, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(4), 1861-1884.
- Bilal, A., Sun, G., Li, Y., Mazhar, S. ve Latif, J., 2022, Lung nodules detection using grey wolf optimization by weighted filters and classification using CNN, *Journal of the Chinese Institute of Engineers*, 45(2), 175-186.
- Chicco, D. ve Jurman, G., 2023, The Matthews correlation coefficient (MCC) should replace the ROC AUC as the standard metric for assessing binary classification, *BioData Mining*, 16(1), 4.
- Choi, D., Bell, W., Kim, D. ve Kim, J., 2021, UAV-Driven Structural Crack Detection and Location Determination Using Convolutional Neural Networks, *Sensors (Basel)*, 21(8), 2650.
- Dixit, A. ve Nanda, A., 2022, An improved whale optimization algorithm-based radial neural network for multi-grade brain tumor classification, *The Visual Computer*, 38(11), 3525-3540.
- Erickson, B. J. ve Kitamura, F., 2021, Magician's corner: 9. Performance metrics for machine learning models, *Radiological Society of North America*. **3**: e200126.
- Faramarzi, A., Heidarinejad, M., Mirjalili, S. ve Gandomi, A. H., 2020, Marine Predators Algorithm: A nature-inspired metaheuristic, *Expert Systems with Applications*, 152(113377).
- Feurer, M. ve Hutter, F., 2019, Hyperparameter optimization, *Automated machine learning: Methods, systems, challenges*, 3-33.
- Fukushima, K., 1980, Neocognitron: a self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biol Cybern*, 36(4), 193-202.
- Girdhar, A., Kapur, H. ve Kumar, V., 2022, Classification of white blood cell using convolution neural network, *Biomedical Signal Processing Control*, 71(103156).

- Haque, I. R. I. ve Neubert, J., 2020, Deep learning approaches to biomedical image segmentation, *Informatics in Medicine Unlocked*, 18(100297).
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Identity mappings in deep residual networks, *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*, 630-645.
- He, Z., Ma, Y., Wang, Z. ve Li, E., 2022, A novel efficient method for welding spots detection, *Multimedia Tools Applications*, 81(18), 26381-26401.
- Hossin, M. ve Sulaiman, M. N., 2015, A review on evaluation metrics for data classification evaluations, *International journal of data mining knowledge management process*, 5(2), 1.
- Houssein, E. H., Emam, M. M. ve Ali, A. A., 2022, An optimized deep learning architecture for breast cancer diagnosis based on improved marine predators algorithm, *Neural Comput Appl*, 34(20), 18015-18033.
- Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K. Q., 2017, Densely connected convolutional networks, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708.
- Iparraquirre-Villanueva, O., Guevara-Ponce, V., Roque Paredes, O., Sierra-Liñan, F., Zapata-Paulini, J. ve Cabanillas-Carbonell, M., 2022, Convolutional neural networks with transfer learning for pneumonia detection.
- Ippolito, P. P., 2022, Hyperparameter Tuning: The Art of Fine-Tuning Machine and Deep Learning Models to Improve Metric Results, *Applied data science in tourism: Interdisciplinary approaches, methodologies, and applications*, Springer, 231-251.
- Jamieson, K. ve Talwalkar, A., 2016, Non-stochastic best arm identification and hyperparameter optimization, *Artificial intelligence and statistics*, 240-248.
- Jin, H., 2022, Hyperparameter importance for machine learning algorithms, *arXiv preprint arXiv:05132*.
- Kadam, A., Bhuvaji, S. ve Deshpande, S., 2021, Brain Tumor Classification using Deep Learning Algorithms, *Int J Res Appl Sci Eng Technol*, 9(4)17-426.
- Kermany, D., Zhang, K. ve Goldbaum, M., 2018, Large dataset of labeled optical coherence tomography (oct) and chest x-ray images, *Mendeley Data*, 3(10.17632).
- Kilic, A. ve Karakoyun, M., 2023, Plant Diseases Detection Using Explainable Deep Learning Methods and Its Applicability in Real Life.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25(
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. ve Jackel, L. D., 1989, Backpropagation applied to handwritten zip code recognition, *Neural computation*, 1(4), 541-551.

- Li, L., Jamieson, K., Rostamizadeh, A., Gonina, E., Ben-Tzur, J., Hardt, M., Recht, B. ve Talwalkar, A., 2020, A system for massively parallel hyperparameter tuning, *Proceedings of Machine Learning Systems*, 2(230-246).
- Li, Z., Liu, F., Yang, W., Peng, S. ve Zhou, J., 2021, A survey of convolutional neural networks: analysis, applications, and prospects, *IEEE transactions on neural networks learning systems*, 33(12), 6999-7019.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J., van Ginneken, B. ve Sanchez, C. I., 2017, A survey on deep learning in medical image analysis, *Med Image Anal*, 42(60-88).
- Liu, S., Roemer, F., Ge, Y., Bedrick, E. J., Li, Z. M., Guermazi, A., Sharma, L., Eaton, C., Hochberg, M. C., Hunter, D. J., Nevitt, M. C., Wirth, W., Kent Kwok, C. ve Sun, X., 2023, Comparison of evaluation metrics of deep learning for imbalanced imaging data in osteoarthritis studies, *Osteoarthritis Cartilage*, 31(9), 1242-1248.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y. ve Alsaadi, F. E., 2017, A survey of deep neural network architectures and their applications, *Neurocomputing*, 234(11-26).
- Masters, D. ve Luschi, C., 2018, Revisiting small batch training for deep neural networks, *arXiv preprint arXiv:07612*.
- Mohakud, R. ve Dash, R., 2021, Survey on hyperparameter optimization using nature-inspired algorithm of deep convolution neural network, *Intelligent and Cloud Computing: Proceedings of ICICC 2019, Volume 1*, 737-744.
- Mostafiz, R., Rahman, M. M., Islam, A. K. ve Belkasim, S., 2020, Focal liver lesion detection in ultrasound image using deep feature fusions and super resolution, *Machine Learning Knowledge Extraction*, 2(3), 10.
- Müller, M., 2020, Camera re-localization with data augmentation by image rendering and image-to-image translation, *Karlsruher Institut für Technologie (KIT)*.
- Nematzadeh, S., Kiani, F., Torkamanian-Afshar, M. ve Aydin, N., 2022, Tuning hyperparameters of machine learning algorithms and deep neural networks using metaheuristics: A bioinformatics study on biomedical and biological cases, *Comput Biol Chem*, 97(107619).
- Peres, F. ve Castelli, M., 2021, Combinatorial optimization problems and metaheuristics: Review, challenges, design, and development, *Applied Sciences*, 11(14), 6449.
- Prabhakar, T., Rao, T. M., Maram, B. ve Chigurukota, D., 2024, Exponential gannet firefly optimization algorithm enabled deep learning for diabetic retinopathy detection, *Biomedical Signal Processing Control*, 87(105376).
- Qazi, E. U. H., Zia, T. ve Almorjan, A., 2022, Deep learning-based digital image forgery detection system, *Applied Sciences*, 12(6), 2851.
- Rainio, O., Teuvo, J. ve Klén, R., 2024, Evaluation metrics and statistical tests for machine learning, *Scientific Reports*, 14(1), 6086.

- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18*, 234-241.
- Ruder, S., 2016, An overview of gradient descent optimization algorithms, *arXiv preprint arXiv:1609.04747*.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. ve Chen, L.-C., 2018, Mobilenetv2: Inverted residuals and linear bottlenecks, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4510-4520.
- Shafi, S. ve Assad, A., 2023, Exploring the relationship between learning rate, batch size, and epochs in deep learning: an experimental study, *Soft Computing for Problem Solving: Proceedings of the SocProS 2022*, Springer, 201-209.
- Shen, D., Wu, G. ve Suk, H. I., 2017, Deep Learning in Medical Image Analysis, *Annu Rev Biomed Eng*, 19(1), 221-248.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1404.5997*.
- Snoek, J., Larochelle, H. ve Adams, R. P., 2012, Practical bayesian optimization of machine learning algorithms, *Advances in neural information processing systems*, 25(1), 2121-2129.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research*, 15(1), 1929-1958.
- Sureja, N. M., Patel, P. N., Patel, H. ve Shingadiya, C. J., 2023, A discrete salp swarm algorithm with weights and Lévy flights: application for Parkinson's disease detection, *Indonesian Journal of Electrical Engineering*, 29(1), 472-480.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826.
- Tareq, I., Elbagoury, B. M., El-Regaily, S. ve El-Horbaty, E.-S. M., 2022, Analysis of ton-iiot, unw-nb15, and edge-iiot datasets using dl in cybersecurity for iiot, *Applied Sciences*, 12(19), 9572.
- Terven, J., Cordova-Esparza, D. M., Ramirez-Pedraza, A. ve Chavez-Urbiola, E. A., 2023, Loss functions and metrics in deep learning. A review, *arXiv preprint arXiv:2305.02694*.
- Thanapol, P., Lavangnananda, K., Leprévost, F., Glad, A., Schleich, J. ve Bouvry, P., 2024, Round-Based Mechanism and Job Packing with Model-Similarity-Based Policy for Scheduling DL Training in GPU Cluster, *Applied Sciences*, 14(6), 2349.
- Vidhyalakshmi, A. ve Kanchana, M., 2024, Classification of skin disease using a novel hybrid flash butterfly optimization from dermoscopic images, *Neural Computing Applications*, 36(8), 4311-4324.

- Wang, B., Sun, Y., Xue, B. ve Zhang, M., 2019, Evolving deep neural networks by multi-objective particle swarm optimization for image classification, *Proceedings of the genetic and evolutionary computation conference*, 490-498.
- Wang, Z.-S., Lee, J., Song, C. G. ve Kim, S.-J., 2020, Efficient chaotic imperialist competitive algorithm with dropout strategy for global optimization, *Symmetry*, 12(4), 635.
- Xia, B., Innab, N., Kandasamy, V., Ahmadian, A. ve Ferrara, M., 2024, Intelligent cardiovascular disease diagnosis using deep learning enhanced neural network with ant colony optimization, *Sci Rep*, 14(1), 21777.
- Yang, X.-S. ve Deb, S., 2010, Engineering optimisation by cuckoo search, *International Journal of Mathematical Modelling Numerical Optimisation*, 1(4), 330-343.
- Yousri, D., Hasanien, H. M. ve Fathy, A., 2021, Parameters identification of solid oxide fuel cell for static and dynamic simulation using comprehensive learning dynamic multi-swarm marine predators algorithm, *Energy Conversion Management*, 228(113692).