



**T.C.**

**TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ**

**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI**

**CİLT HASTALIKLARININ TEŞHİSİ İÇİN EVRİŞİMSEL SİNİR  
AĞLARININ OPTİMİZASYON YÖNTEMLERİ  
İLE GELİŞTİRİLMESİ**

**YÜKSEK LİSANS TEZİ**

**Emirhan AYDIN**

**Danışman: Doç. Dr. Mahir KAYA**

**TOKAT- 2025**

## ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Mahir KAYA danışmanlığında hazırlamış olduğum “Cilt Hastalıklarının Teşhisi İçin Evrişimsel Sinir Ağlarının Optimizasyon Yöntemleri İle Geliştirilmesi” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

28/11/2025

Emirhan AYDIN

## JÜRİ KABUL VE ONAY

**Emirhan AYDIN** tarafından hazırlanan “**Cilt Hastalıklarının Teşhisi İçin Evrimsel Sinir Ağlarının Optimizasyon Yöntemleri İle Geliştirilmesi**” adlı tez çalışmasının savunma sınavı 12.12.2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

### Jüri Üyeleri

### İmzası

Üye (Danışman): Doç. Dr. Mahir KAYA

.....

Üye (Başkan): Prof. Dr. Turgut ÖZSEVEN

.....

Üye: Doç. Dr. Bülent TURAN

.....

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

## ÖNSÖZ

Tez çalışmam da dahil olmak üzere lisans eğitimimden bu yana üzerimde emeği olan danışmanım Doç. Dr. Mahir KAYA ve diğer tüm hocalarıma teşekkürlerimi sunarım. Hayatımın her anında olduğu gibi bu süreçte de yanımda olan aileme sonsuz teşekkürlerimi sunarım.

Emirhan AYDIN  
TOKAT-2025



## ÖZET

### CİLT HASTALIKLARININ TEŞHİSİ İÇİN EVRİŞİMSEL SİNİR AĞLARININ OPTİMİZASYON YÖNTEMLERİ İLE GELİŞTİRİLMESİ

Aydın, Emirhan  
Yüksek Lisans, Bilgisayar Mühendisliği Anabilim Dalı  
Tez Danışmanı: Doç. Dr. Mahir KAYA  
Kasım 2025, x + 57 sayfa

Günümüzde cilt kanserleri, dünya genelinde en yaygın ve ölümcül hastalık türlerinden biri haline gelmiştir. Erken teşhis, hastalığın ilerlemesini önlemede ve tedavi başarısını artırmada kritik bir rol oynamaktadır. Ancak, farklı cilt lezyonlarının görsel olarak benzer özellikler göstermesi, dermatologlar için teşhis sürecini zorlaştırmaktadır. Bu nedenle, bilgisayarlı görüntü analizi ve derin öğrenme tabanlı yaklaşımlar, cilt hastalıklarının otomatik teşhisinde önemli bir araştırma alanı haline gelmiştir.

Bu çalışmada, ISIC 2019 veri seti kullanılarak cilt hastalıklarının sınıflandırılmasına yönelik bir derin öğrenme modeli geliştirilmiştir. İlk aşamada, transfer öğrenme yaklaşımıyla beş farklı önceden eğitilmiş mimari incelenmiş ve bu modeller arasından **EfficientNetV2S** en yüksek F1 skorunu elde ederek temel model olarak seçilmiştir.

İkinci aşamada, EfficientNetV2S modeli kanal, uzamsal, sıkma ve özellik çıkarma (SE) gibi dikkat mekanizmalarıyla zenginleştirilmiş, böylece modelin öznitelik seçme ve anlamlı bölgeleri vurgulama yeteneği artırılmıştır.

Üçüncü aşamada, geliştirilen bu modelin hiperparametreleri **Equilibrium Optimizer (EO)** algoritması kullanılarak optimize edilmiştir. EO algoritması, modelin performansını daha üst seviyelere taşıyarak hiperparametre optimizasyonunda etkin bir yöntem olduğunu ortaya koymuştur.

Son aşamada, model daha geniş kapsamlı bir veri seti üzerinde yeniden eğitilmiş ve F1 skorunda belirgin bir artış sağlanmıştır. Elde edilen sonuçlar, dikkat mekanizmalarının entegrasyonunun, EO tabanlı hiperparametre optimizasyonunun ve daha büyük veri setleriyle eğitimin model başarısını anlamlı biçimde iyileştirdiğini göstermektedir.

**Anahtar Kelimeler:** Cilt Hastalıkları, Derin Öğrenme, CNN, Hiperparametre Optimizasyonu, ISIC 2019, Equilibrium Optimizasyon Algoritması

**ABSTRACT**  
**DEVELOPMENT OF CONVOLUTIONAL NEURAL NETWORKS FOR SKIN  
DISEASE DIAGNOSIS WITH OPTIMIZATION METHODS**

Aydın, Emirhan  
Master, Department of Computer Engineering  
Advisor: Assoc. Prof. Dr. Mahir KAYA  
November 2025, x + 57 pages

In recent years, skin cancers have become one of the most common and deadly diseases worldwide. Early diagnosis plays a critical role in preventing disease progression and improving treatment success. However, the visual similarity of different skin lesions makes the diagnostic process challenging for dermatologists. Therefore, computer-based image analysis and deep learning-based approaches have become an important research area for the automatic diagnosis of skin diseases.

In this study, a deep learning model was developed for the classification of skin diseases using the ISIC 2019 dataset. In the first stage, five different pre-trained architectures were evaluated through transfer learning, and **EfficientNetV2S** was selected as the base model for achieving the highest F1 score.

In the second stage, the EfficientNetV2S model was enhanced with **channel and spatial attention mechanisms**, improving its ability to select meaningful features and emphasize important regions within the images.

In the third stage, the hyperparameters of the enhanced model were optimized using the **Equilibrium Optimizer (EO)** algorithm. The EO algorithm effectively improved the model's performance, demonstrating its capability as a powerful approach for hyperparameter optimization.

Finally, the model was retrained on a larger dataset, which led to a further increase in the F1 score. The results indicate that the integration of attention mechanisms, EO-based hyperparameter optimization, and training with a larger dataset significantly improve the performance of deep learning models for skin disease classification.

**Keywords:** Skin Diseases, Deep Learning, CNN, Hyperparameter Optimization, ISIC 2019, Equilibrium Optimizer

## İÇİNDEKİLER

|                                                                    |      |
|--------------------------------------------------------------------|------|
| ETİK SÖZLEŞME.....                                                 | i    |
| JÜRİ KABUL VE ONAY .....                                           | ii   |
| ÖNSÖZ .....                                                        | iii  |
| ÖZET .....                                                         | iv   |
| ABSTRACT.....                                                      | v    |
| İÇİNDEKİLER .....                                                  | vi   |
| TABLolar LİSTESİ.....                                              | viii |
| ŞEKİLLER LİSTESİ .....                                             | ix   |
| KISALTMALAR .....                                                  | x    |
| 1. GİRİŞ .....                                                     | 1    |
| 2. İLGİLİ ÇALIŞMALAR.....                                          | 4    |
| 3. MATERYAL VE YÖNTEM .....                                        | 12   |
| 3.1. Yapay Zeka ve Derin Öğrenme.....                              | 12   |
| 3.1.1. Yapay zeka .....                                            | 12   |
| 3.1.2. Derin öğrenme .....                                         | 12   |
| 3.2. Evrişimsel Sinir Ağları (CNN).....                            | 13   |
| 3.2.1. CNN mimarisi ve temel bileşenleri .....                     | 13   |
| 3.2.2. Dikkat mekanizmaları .....                                  | 15   |
| 3.3. Veri Seti ve İşlemleri .....                                  | 16   |
| 3.3.1. Veri seti .....                                             | 16   |
| 3.3.2. Alt veri setlerinin oluşturulması ve dengeleme çözümü ..... | 18   |
| 3.3.3. Veri ön işleme.....                                         | 22   |
| 3.4. Transfer öğrenme .....                                        | 23   |
| 3.4.1. Önceden eğitilmiş modeller.....                             | 23   |
| 3.4.2. Transfer öğrenme stratejileri .....                         | 24   |
| 3.4.3. Transfer öğrenme çalışması.....                             | 24   |
| 3.5. Hiperparametre Optimizasyonu .....                            | 25   |
| 3.5.1. Optimizasyon algoritması: Equilibrium Optimizer .....       | 25   |
| 3.5.2. Optimize edilecek hiperparametreler .....                   | 26   |
| 3.6. Performans Metrikleri .....                                   | 31   |
| 3.6.1. Karışıklık matrisi .....                                    | 31   |

|                                                                         |    |
|-------------------------------------------------------------------------|----|
| 3.6.2. Accuracy & balanced accuracy (BA) .....                          | 32 |
| 3.6.3. Precision .....                                                  | 32 |
| 3.6.4. Recall .....                                                     | 33 |
| 3.6.5. F1-Skoru .....                                                   | 33 |
| 3.6.6. ROC-AUC skoru .....                                              | 33 |
| 3.7. Materyal .....                                                     | 34 |
| 3.8. Deneysel Araçlar .....                                             | 34 |
| 4. BULGULAR VE TARTIŞMA .....                                           | 35 |
| 4.1. Transfer Öğrenme ile Eğitim Sonuçları .....                        | 35 |
| 4.2. Seçilen Temel Mimari ve Değerlendirme Sonuçları .....              | 36 |
| 4.2.1. Mimari/model bilgileri .....                                     | 36 |
| 4.2.2. Değerlendirme sonuçları .....                                    | 37 |
| 4.3. Seçilen Mimarinin Dikkat Mekanizmaları İle Güçlendirilmesi .....   | 39 |
| 4.4. EO Algoritması ile Hiperparametre Optimizasyonu Sonuçları .....    | 40 |
| 4.4.1. Elde edilen en iyi modelin değerlendirme sonuçları .....         | 42 |
| 4.5. Elde Edilen En İyi Modelin Büyük Veri Setleri ile Eğitilmesi ..... | 43 |
| 4.5.1. DAVS-D eğitim ve değerlendirme sonuçları .....                   | 43 |
| 4.5.2. DAVS-E eğitim ve değerlendirme sonuçları .....                   | 46 |
| 5. SONUÇ .....                                                          | 49 |
| 6. KAYNAKÇA .....                                                       | 51 |
| ÖZGEÇMİŞ .....                                                          | 57 |

## TABLolar LİSTESİ

|                                                                                      |    |
|--------------------------------------------------------------------------------------|----|
| Tablo 3.1 ISIC 2019 sınıf bilgileri .....                                            | 16 |
| Tablo 3.2 (Devam) ISIC 2019 sınıf bilgileri.....                                     | 17 |
| Tablo 3.3 Alt veri seti – A (AVS-A) .....                                            | 18 |
| Tablo 3.4 Veri artırmada kullanılan parametreler .....                               | 19 |
| Tablo 3.5 Çalışmada kullanılan alt veri setleri.....                                 | 20 |
| Tablo 3.6 AVS-B .....                                                                | 21 |
| Tablo 3.7 Çalışmanın son aşamasında kullanılan DAVS'leri.....                        | 21 |
| Tablo 3.8 (Devam) Çalışmanın son aşamasında kullanılan DAVS'leri.....                | 22 |
| Tablo 3.9 Veri ön işlemede kullanılan parametreler .....                             | 23 |
| Tablo 3.10 Optimize edilen hiperparametreler ve değerleri .....                      | 26 |
| Tablo 3.11 Bu çalışmada sabit tutulan hiperparametreler .....                        | 30 |
| Tablo 4.1 Transfer öğrenmede kullanılan mimarilerin değerlendirme sonuçları.....     | 36 |
| Tablo 4.2 Seçilen temel modelin bilgileri .....                                      | 36 |
| Tablo 4.3 (Devam) Seçilen temel modelin bilgileri.....                               | 37 |
| Tablo 4.4 Seçilen temel modelin değerlendirme sonuçları.....                         | 37 |
| Tablo 4.5 Çeşitli dikkat mekanizmaları ile güçlendirilmiş modellerin sonuçları ..... | 39 |
| Tablo 4.6 EO ile bulunan en iyi ilk 5 modelin özellikleri.....                       | 40 |
| Tablo 4.7 EO ile bulunan en iyi ilk 5 modelin performans metrikleri.....             | 40 |
| Tablo 4.8 En iyi modelin DAVS-D ile değerlendirme sonuçları .....                    | 44 |
| Tablo 4.9 En iyi modelin DAVS-E ile değerlendirme sonuçları.....                     | 46 |

## ŞEKİLLER LİSTESİ

|                                                                                      |    |
|--------------------------------------------------------------------------------------|----|
| Şekil 3.1 ReLU fonksiyon grafiği (Agarap, 2019) .....                                | 14 |
| Şekil 3.2 CBAM yöntemi (Woo ve ark., 2018) .....                                     | 16 |
| Şekil 3.3 ISIC 2019 veri setinden örnek görüntüler (Saeed ve ark., 2023) .....       | 17 |
| Şekil 3.4 ISIC 2019 veri setinde bulunan farklı sınıflardaki benzer görüntüler ..... | 18 |
| Şekil 3.5 EO algoritması(Faramarzi ve ark., 2020) .....                              | 26 |
| Şekil 3.6 Bu çalışmada elde edilen bir karışıklık matrisi .....                      | 32 |
| Şekil 3.7 ROC-AUC eğrisi(Jaskowiak ve ark., 2022) .....                              | 34 |
| Şekil 4.1 Seçilen temel modelin eğitim-doğrulama doğruluk ve kayıp grafikleri.....   | 38 |
| Şekil 4.2 Seçilen temel modelin karışıklık matrisi .....                             | 38 |
| Şekil 4.3 Global en iyi ajan performans grafiği.....                                 | 41 |
| Şekil 4.4 Lokal en iyi ajan performans grafiği .....                                 | 42 |
| Şekil 4.5 En iyi modelin eğitim-doğrulama doğruluk ve kayıp grafikleri.....          | 42 |
| Şekil 4.6 En iyi modelin karışıklık matrisi .....                                    | 43 |
| Şekil 4.7 DAVS-D eğitim ve test setinden örnekler .....                              | 44 |
| Şekil 4.8 En iyi modelin DAVS-D ile eğitim-doğrulama doğruluk ve kayıp grafikleri .  | 45 |
| Şekil 4.9 En iyi modelin DAVS-D test seti ile oluşturulan karışıklık matrisi.....    | 46 |
| Şekil 4.10 En iyi modelin DAVS-E ile eğitim-doğrulama doğruluk ve kayıp grafikleri   | 47 |
| Şekil 4.11 En iyi modelin DAVS-E test seti ile oluşturulan karışıklık matrisi .....  | 48 |

## KISALTMALAR

| Kısaltma | Açıklama                                            |
|----------|-----------------------------------------------------|
| AK       | Actinic Keratosis                                   |
| AVS      | Alt Veri Seti                                       |
| BA       | Balanced Accuracy                                   |
| BAM      | Bottleneck Attention Module                         |
| BCC      | Basal Cell Carcinoma                                |
| BKL      | Bening Keratosis                                    |
| CBAM     | Convolutional Block Attention Module                |
| CNN      | Convolutional Neural Network                        |
| Conv2D   | 2D Convolution Layer                                |
| D        | Dropout                                             |
| DAVS     | Dengelenmiş Alt Veri Seti                           |
| DF       | Dermatofibroma                                      |
| EO       | Equilibrium Optimizer                               |
| FC       | Fully Connected Layer, Tam Bağlı Katman             |
| GAP      | Global Average Pooling (Küresel Ortalama Havuzlama) |
| ISIC     | International Skin Imaging Collaboration            |
| LR       | Learning Rate (Öğrenme Oranı)                       |
| MEL      | Melanoma                                            |
| NV       | Melanocytic Nevi                                    |
| SCC      | Squamous Cell Carcinoma                             |
| SE       | Squeeze-and-Excitation                              |
| VASC     | Vascular Lesions                                    |

## 1. GİRİŞ

Cilt hastalıkları, hem estetik hem de sağlık açısından bireylerin yaşam kalitesini önemli ölçüde etkileyen yaygın sağlık problemlerindendir. Dünya genelinde her yıl milyonlarca insan cilt hastalıklarının çeşitli türlerinden etkilenmekte olup, bu durum erken ve doğru teşhisin önemini artırmaktadır(Rigel & Stein Gold, 2013). Özellikle malign melanom gibi bazı cilt hastalıklarının erken evrede tespit edilmesi, tedavi başarısını doğrudan etkilemektedir. Ancak deri lezyonlarının görsel olarak birbirine oldukça benzer olması, uzman dermatologlar için bile doğru teşhisi güçleştirmektedir(Abunadi & Senan, 2021). Bu nedenle, bilgisayar destekli tanı sistemlerinin geliştirilmesi son yıllarda önemli bir araştırma alanı haline gelmiştir.

Yapay zekâ ve derin öğrenme teknolojileri, özellikle görüntü işleme tabanlı tıbbi tanı sistemlerinde yüksek başarı göstermektedir. Evrişimli Sinir Ağları (CNN), medikal görüntülerin teşhisinde öne çıkan derin öğrenme mimarilerindendir. Bu modeller, sağlık alanındaki görsel verilerde (bilgisayarlı tomografi, röntgen, MR vb.) yüksek doğruluk oranlarına ulaşabilmektedir (Çetin-Kaya, 2024; Kaya, 2024; Kaya & Çetin-Kaya, 2024).

Mevcut literatürde, cilt hastalıklarının sınıflandırılması ve teşhisi üzerine yapılan çalışmalarda, ResNet, DenseNet ve EfficientNet gibi önceden eğitilmiş CNN mimarileri sıklıkla tercih edilmektedir(Shanthi ve ark., 2020; Wu ve ark., 2019). Bu tür modeller, özellikle sınırlı sayıda eğitim verisiyle hızlı bir şekilde öğrenme kabiliyeti sundukları için başlangıçta cazip görünmektedir. Ancak, önceden eğitilmiş olmalarından kaynaklanan bazı sınırlamalar mevcuttur. Başlıca sorunlardan biri, modellerin eğitim veri setine hızlıca adapte olmaları sonucunda doğrulama ve test setlerinde performans düşüşleri göstermeleri ve dolayısıyla aşırı öğrenme (overfitting) eğilimi göstermeleridir. Ayrıca, bu modellerin performansı genellikle belirli veri kümelerine bağımlı kalmakta ve farklı veri dağılımlarında genelleme yetenekleri sınırlı kalmaktadır(İman ve ark., 2023; Weiss ve ark., 2016).

Bu durum, özellikle medikal görüntü sınıflandırma alanında, transfer öğrenme yaklaşımının çeşitli yöntemlerle güçlendirilmesinin önemini ortaya koymaktadır. Bu yöntemlerden biri de dikkat mekanizmalarıdır. Dikkat (attention) temelli yapıların derin

ağlara entegre edilmesi, modelin görsel öznetelikler arasındaki ilişkileri daha iyi öğrenmesini ve önemli bölgeleri ön plana çıkarmasını sağlamaktadır (Niu ve ark., 2021). Son yıllarda SE, CBAM ve BAM gibi mekanizmalar, hem kanal hem de uzamsal düzeylerde bilgi akışını optimize ederek CNN tabanlı modellerin performansını anlamlı biçimde artırmıştır (Hu ve ark., 2018; Park ve ark., 2018; Yin ve ark., 2023; Woo ve ark., 2018).

Öte yandan, bir modelin başarısı yalnızca mimarisine değil, aynı zamanda hiperparametrelerinin doğru biçimde optimize edilmesine de bağlıdır. Hiperparametrelerin uygun seçilmesi, modelin öğrenme sürecini dengeleyerek aşırı öğrenme riskini azaltmakta ve daha kararlı sonuçlar elde edilmesine katkı sağlamaktadır. Bu kapsamda, klasik yöntemlere alternatif olarak doğadan esinlenen metasezgisel algoritmalar, karmaşık hiperparametre uzaylarında etkili arama yapabilme kabiliyetleri sayesinde son yıllarda popüler hale gelmiştir (Kaya & Çetin-Kaya, 2024). Özellikle, Equilibrium Optimizer (EO) algoritması, global ve yerel aramayı dengeleyerek derin öğrenme modellerinin hiperparametre optimizasyonunda başarılı sonuçlar elde etmektedir(Çetin-Kaya, 2024; Faramarzi ve ark., 2020).

Bu çalışmada, ISIC 2019 veri seti kullanılarak cilt hastalıklarının sınıflandırılması için transfer öğrenme tabanlı ve dikkat mekanizmalarıyla modifiye edilmiş bir EfficientNetV2S modeli önerilmiştir. Veri seti, sekiz farklı cilt hastalığı sınıfını içermekte ve sınıf başına farklı sayıda görüntü sayıları içermektedir. Modelin eğitimi sırasında, veri %80-20 oranında eğitim ve test olarak ayrılmış, sınıf dengesizliğini gidermek ve eksik olan örnekleri artırmak amacıyla veri artırma (data augmentation) teknikleri uygulanmıştır. Ayrıca, medikal görüntülerde doğruluk tek başına yanıltıcı olabileceği için model performansı F1 skoru üzerinden değerlendirilmiş ve dengesiz test seti nedeniyle macro F1 metriği kullanılmıştır.

İlk aşamada, beş farklı önceden eğitilmiş CNN mimarisi test edilmiş ve en yüksek F1 skoruna ulaşan EfficientNetV2S modeli temel model olarak seçilmiştir. Modelin performansını değerlendirmek amacıyla, sınıf başına 250, 500 ve 750 örnek içeren üç farklı eğitim veri seti kullanılmıştır. Yapılan analizler, eğitim örneği sayısının modelin F1 skoru üzerinde doğrudan etkili olduğunu ortaya koymuştur. Örneğin, aynı model 250

örnekle eğitildiğinde %67.4 F1 skoru elde ederken, 500 örnekte %72, 750 örnekte ise %75.9 F1 skoruna ulaşmıştır. Bu bulgular, veri miktarının modelin öğrenme kapasitesi ve genelleme performansı açısından kritik bir faktör olduğunu göstermektedir.

Takip eden aşamada, EfficientNetV2S modeline SE, CBAM, BAM gibi kanal ve uzamsal dikkat mekanizmaları entegre edilmiştir. Bu modifikasyonlar sonucunda modelin anlamlı öz nitelikleri daha etkin biçimde yakaladığı ve sınıflar arasındaki ayrımı güçlendirdiği gözlemlenmiştir. Sonrasında, modelin hiperparametreleri Equilibrium Optimizer (EO) algoritmasıyla optimize edilerek performans daha da artırılmıştır.

Son olarak eğitim setinde sınıf başına 2 400 görüntü içeren iki farklı veri seti kullanılmıştır. Bu iki farklı veri setinden ilki veri artırma tekniğinin yanlış uygulanmasının(önce veri artırma sonra eğitim-test ayırma), ikincisi ise doğru uygulanmasının(önce eğitim-test ayırma sonra sadece eğitim kısmına veri artırma) sonuçlarını gözlemek için kullanılmıştır. Son aşamada optimize edilmiş model bu iki farklı veri seti ile yeniden eğitilmiş ve F1 skorunda anlamlı bir artış elde edildiği gözlemlenmiştir.

Bu çalışma transfer öğrenme yöntemlerinde dikkat mekanizmalarının entegrasyonunun, EO algoritmasıyla yapılan hiperparametre optimizasyonunun, veri seti büyüklüğünün ve veri artırma yöntemlerinin doğru uygulanmasının cilt hastalığı sınıflandırma performansına etkisini kapsamlı biçimde ortaya koymaktadır. Elde edilen sonuçlar, bu üç faktörün birleşiminin medikal görüntü sınıflandırma alanında yüksek F1 skoru, iyi genelleme kabiliyeti ve düşük hesaplama maliyeti sağlayan etkili bir yaklaşım sunduğunu göstermektedir.

## 2. İLGİLİ ÇALIŞMALAR

Yapay zeka ve görüntü işleme teknolojilerinin son yıllardaki önemli gelişmeleri bu alandaki çalışma sayısını da doğrudan etkilemiştir. 2019 yılında Wu ve arkadaşları tarafından yapılan çalışmada altı yaygın yüz cilt hastalığını içeren toplamda 2 656 görüntüden oluşan Xiangya–Derm verisetini kullanarak yüz bölgesinde bulunan cilt hastalıklarının teşhisini yapacak bir çalışma yapmışlardır. Araştırmacılar, ResNet-50, Inception-v3, DenseNet121, Xception ve Inception-ResNet-v2 olmak üzere beş farklı CNN mimarisini bu veri seti üzerinde karşılaştırmış ve modellerin yüz bölgesine özgü klinik görüntülerdeki performanslarını incelemiştir. Elde edilen sonuçlar, Inception-ResNet-v2 mimarisinin ortalama %77 doğruluk ile en yüksek performansı sergilediğini göstermiştir. Ek olarak çalışma, transfer öğrenmenin etkisini değerlendirmek amacıyla, yüz dışındaki vücut bölgelerine ait benzer hastalık görüntüleriyle ön eğitim gerçekleştirmiştir. Bu yöntem sonucunda tüm modellerde anlamlı performans artışları gözlenmiş; özellikle çapraz bölge eğitiminin, belirtileri farklı bölgelerde benzer şekilde görülen hastalıkların sınıflandırılmasında avantaj sağladığı ortaya konmuştur. Bununla birlikte AK ve SK gibi görsel olarak birbirine çok benzeyen hastalıklarda model performansının belirgin şekilde düştüğü, bunun hem görüntü benzerliğinden hem de veri setindeki sınıf dengesizliğinden kaynaklandığı belirtilmiştir. Bu çalışma, yüz bölgesi için özelleştirilmiş klinik görüntü veri setlerinin eksikliğini vurgulaması, transfer öğrenmenin önemini göstermesi ve farklı CNN mimarilerini karşılaştırmalı olarak değerlendirmesi açısından literatüre önemli bir katkı sunmaktadır. Ayrıca araştırma, sınıf benzerliği ve veri dengesizliği gibi sorunların mevcut CNN mimarilerinin performansını sınırlandırmaya devam ettiğini göstermiş; bu nedenle daha özel mimariler, veri artırma stratejileri ve daha dengeli veri setleri üzerine yapılacak çalışmaların gerekliliğini ortaya koymuştur (Wu ve ark., 2019).

Anand ve arkadaşları 2023 yılında yaptıkları çalışmada 7 farklı cilt hastalığı sınıfına ait 10 015 farklı görüntüden oluşan HAM10000 verisetini kullanmıştır. Bu çalışmada araştırmacılar U-Net ile kendi özgün CNN modellerini birleştirerek görüntüyü ön işleme adımından geçirdikten ve görüntüdeki hastalıklı bölgeyi kırptıktan sonra sınıflandırma işlemini yapacak katmana iletmışlerdir. Araştırmacılar kullandıkları veri seti üzerinde veri artırma işlemi yapmamıştır. Çalışma veri artırma yöntemi ile performans artırmak

yerine segmentasyon üzerine odaklanarak performansı artırmayı amaçlamıştır. Son olarak sınıflandırma katmanında Adam ve Adadelta algoritmalarının farkını da incelemişler ve %97.96 başarı oranı ile en başarılı model ve optimizasyon algoritmasını (Adadelta) bulmuşlardır(Anand ve ark., 2023).

Rezaana ve arkadaşları 2020 yılında Kaggle'dan alındığı belirtilen toplamda 9 farklı sınıfta 25 780 cilt hastalığı görüntüsü bulunan verisetini kullanmışlardır. VGG-16 ve VGG-19 gibi yaygın mimariler ile eğitim işlemi yaptıktan sonra kendi özgün modellerini tasarlayarak bu mimarilere kıyasla daha yüksek sonuçlar elde etmişlerdir. Özgün mimarilerinde kullandıkları yöntem paralel CNN bloklarıdır (concatenation). Bu sayede %79.45 doğruluk oranı ve %76.92 F1-Skoru ile en başarılı model kendi tasarladıkları modelleri olmuştur (Rezaana ve ark., 2020).

2020 yılında yapılan bir diğer çalışmada, bu çalışmamızda kullandığımız ISIC 2019 veriseti kullanılmıştır. Kassem ve arkadaşları GoogleNet mimarisini baz almış ve bu mimarinin son katmanlarını devre dışı bırakıp yerine yeni birkaç katman ekleyerek hibrit bir model mimarisi ile çalışmışlardır. Elde edilen bu model ile %94.92 accuracy ve %80.07 F1-Skor elde ettiklerini belirtmişlerdir. Ayrıca eğitim süresince 3 farklı veriseti ile çalışıp bunlardan en başarılı olanın her sınıfta eşit sayıda görüntü olan veriseti olduğunu bildirmişlerdir(Kassem ve ark., 2020).

Ahammed ve arkadaşlarının 2022 yılında yaptığı çalışmada ISIC 2019 veriseti kullanılmıştır. Çalışmanın başında, veriler ön işleme adımına sokularak görüntülerdeki kıllar ve gürültüler temizlenmiştir. Ardından Grabcut algoritması ile hastalıklı bölgenin segmentasyonu yapılmış ve segmente edilen görüntü sınıflandırma adımına verilmiştir. Sınıflandırmada CNN yerine SVM, KNN ve DT makine öğrenme yöntemleri kullanılmış olup %18.38 F1 Skor elde edilmiştir. Akabinde veri çoğaltma işlemi yapılarak sınıflar arasındaki dengesizlik giderilmiş ve bu sayede F1 Skor %94.88 oranına yükselmiştir(Ahammed ve ark., 2022).

2024 yılında Naveed ve diğer araştırmacılar HAM10000 ve ISIC2019 verisetlerini ayrı olarak kullanmış ve çok sınıflı sınıflandırma problemine çözüm aramıştır. Veri setinde dengesizlik olduğu için önce azınlık sınıftaki görüntüler çoğaltılarak çoğunluk sınıftaki

görüntü sayısına eşitlenmiştir. Bu sayede veri dengesizliği problemi çözülmüştür. Ardından, veri setleri %60 eğitim, %20 doğrulama (validation) ve %20 test olarak üç bölüme ayrılmıştır. Daha sonra ayrılan bu verisetine döndürme(0-180 derece), yatay-dikey kaydırma, yakınlaştırma-uzaklaştırma ve yatay-dikey çevirme yöntemleri uygulanarak veri artırma yöntemi uygulanmıştır. Çalışmada önerilen yaklaşım, temel DenseNet-121(Huang ve ark., 2017) modeline Aşamalı Sınıf Bazlı Dikkat Mekanizması (Progressive Class-wise Attention - PCA) entegre edilmesidir. Dikkat mekanizması ardışık yoğun bloklardan sonra (2., 3. ve 4. bloklar) uygulanmıştır. Modelin eğitimi için kayıp fonksiyon Focal Loss ve optimizasyon algoritması da NAdam olarak kullanılmıştır. Sonuç olarak bu çalışmada %97.43 F1 Skor elde edilmiştir(Naveed ve ark., 2024).

Ghazouani HAM10000, ISIC2019 ve PH2 verisetlerini kullanarak yaptığı çalışmada çok sınıflı ve ikili sınıflandırma problemlerini çözmeye çalışmıştır. Bu çalışmada görüntüler önce eğitim-test ve doğrulama olarak sırasıyla %80-%10-%10 olarak ayrıştırılmış ve sonrasında yalnızca eğitim kısmına veri artırma yöntemi uygulanmıştır. Bu yöntem uygulanarak aşırı öğrenmenin ve veri dengesizliğinin önüne geçildiği belirtilmiştir. Çalışmada sunulan yöntem çok Çok Kalıntılı Dikkat Ağıt (Multi-Residual Attention Network - MuRANet) olarak isimlendirilmiştir. Bu yöntem-mimari Çok Ölçekli Genişletilmiş Evrişim Dikkat (MSD) bloğu gibi çeşitli dikkat mekanizmalarını kullanmıştır. Kullanılan bu model ile elde edilen sonuçlar incelendiğinde ISIC2019 veri setinde %92 doğruluk oranı elde ettiği gözlemlenmiştir(Ghazouani, 2025).

2024 yılında yapılan başka bir çalışmada ise araştırmacılar Xception ve ResNet101 mimarilerinin avantajlarını tek bir çatı altında birleştirerek yeni bir derin öğrenme modeli (X\_R101) önermiştir. Önerilen mimaride bu iki modelin çıktıları birleşir (concatenation). Ardından bu çıktıyı kanal sayısını azaltmak için sıkıştırma katmanına (bottleneck) verir ve bu katmandan sonra tam bağlı katmanlar ile sınıflandırma yapar. Önerilen bu yöntem PH2, DermPK ve HAM10000 verisetlerinde denenmiş %98.37 F1 skor ve %98.21 doğruluk oranı elde etmiştir. Lakin çalışmada belirtildiği gibi önce veri çoğaltma işlemi yapıp sonra ayırma işlemi gerçekleştirilmiştir(Naeem & Anees, 2024).

ISIC2019 ve CPTAC-CM veriseti kullanılarak yapılan başka bir çalışmada araştırmacılar derin öğrenme yönteminin verimliliğini artırmak ve aşırı öğrenmeyi önlemek amacıyla

veri artırma yöntemleri uygulamışlardır. Orjinal görüntü boyutunun on katı büyüklüğünde veri elde etmek için veri artırma yöntemlerinde tuz biber gürültüsü ekleme, yatay eksende çevirme, 90° derece sağa döndürme gibi yöntemler kullanılarak resimler çoğaltılmıştır. Resimler çoğaltıldıktan sonra tamamen rastgele olacak şekilde %70 eğitim ve %30 test için ayrılmıştır. Akabinde görüntülerde segmentasyon işlemi yapılarak görüntüdeki yalnızca ilgili alanın çıkarılmasıyla veri ön işleme adımı tamamlanmıştır. Önerilen yöntemde önceden eğitilmiş dört farklı mimari (GoogleNet, ResNet-50, AlexNet ve VGG19) yalnızca FC katmanları eğitilecek şekilde yeniden eğitilmiş ve çıktıları birleştirilerek destek vektör makinesi (SVM) sistemine verilmiştir. Bu sayede ISIC2019 veriseti için %99.8 ve CPTAC-CM için %99.9 doğruluk oranına ulaşıldığı belirtilmiştir(Diab ve ark., 2022)

Mridha ve arkadaşlarının 2023 yılındaki çalışmasında HAM10000 veri seti kullanılmış ve çok sınıflı sınıflandırma problemine çözüm aranmıştır. Kullanılan veri setine uygulanan veri artırma tekniklerinden daha önceki çalışmalardan farklı olarak kontrast germe yöntemi kullanılmış ve bu sayede görüntülerin kontrastı artırılmıştır. Orijinal veri seti boyutu 10 015 iken veri artırma ile 40 157 adet görüntü üretilerek veri seti yaklaşık 4 kat büyütülmüştür. Yine önceki çalışmalardaki gibi veri setinin ayrıştırılması veri artırma tekniği uygulandıktan sonra yapılmıştır. Veri seti %70 eğitim, %15 doğrulama ve %15 test olacak şekilde ayrılmıştır. Çalışmada önerilen yöntem CNN ve yorumlanabilir yapay zeka (XAI) sistemlerinin birleştirilmesiyle oluşturulan bir yaklaşımdır. CNN mimarisinde görüntü girdi boyutu 100x100x3 olarak belirlenmiş ve 2 farklı blok kullanılmıştır. Bu bloklardan ikisi de çekirdek boyutu (kernel size) 3x3 olan iki evrişim katmanı, ReLU aktivasyonu, maksimum havuzlama ve dropout (D) katmanından oluşmuştur. Çıktı için düzleştirme (flatten) yöntemi kullanılmış ve 128 boyutlu bir yoğun (dense) katmanından geçirilmiştir. Son olarak yedi sınıfı ayrıştıracak ve softmax fonksiyonunu içeren yoğun (dense) katman kullanılmıştır. Önerilen yöntemin performansı iki farklı optimizasyon fonksiyonu (Adam ve RMSprop) ve üç farklı aktivasyon fonksiyonu (ReLU, Swish, Tanh) ile değerlendirilmiştir. Modelin kararlarını daha isabetli kılmak için Grad-CAM ve Grad-CAM++ teknikleri kullanılmıştır. Bu sayede modelin bir görüntüyü sınıflandırırken görüntünün en çok hangi kısmına odaklanarak bu kararı verdiği belirtilir. Kullanılan bu yöntem ile elde edilen sonuçlar

incelendiğinde sınıflandırma doğruluğunun %79 olduğu belirtilmektedir. En yüksek doğruluk ReLU ve Adam kullanılarak elde edilmiştir(Mridha ve ark., 2023).

Hoang ve arkadaşlarının (2022) Wide-ShuffleNet isimli mimariyi önerdikleri çalışmada ISIC2019 ve HAM10000 veri setleri kullanılmıştır. Bu çalışmada veri artırma yöntemi kullanılmamıştır. Araştırmacılar verisetinde ki dengesizliğin ciddi oranda yüksek olduğunu belirtmiş fakat bu konuya çözüm getirecek bir çalışma veya yöntem önermemişlerdir. Çalışma, akıllı sağlık sistemleri gibi mobil sistemler için uygun, düşük parametrelili ve hafif bir derin öğrenme çerçevesi geliştirmeyi amaçlamaktadır. Önerilen çerçeve, yeni bir segmentasyon tekniği ile yeni bir CNN mimarisini birleştirmektedir. İlk aşamada görüntüler özel olarak geliştirilen bir segmentasyon tekniği kullanılarak arka plan veya ilgili kısımlardan ayrıştırılmıştır. Ardından Wide-ShuffleNet isimli yeni bir mimari geliştirilmiştir. Bu mimari özellikle taşınabilir (mobil) cihazlar için tasarlanmış ve hafif bir yapıya sahiptir (1.8M parametre sayısı). Bu yapı ShuffleNet mimarisinin bloklarını ve ResNet mimarisinin bağlantı atlama (skip connections) yöntemini birleştirerek oluşturulmuştur. Bu metot ile üç farklı şekilde deney yapılarak sonuçlar karşılaştırılmıştır. Birincisinde HAM10000 veriseti %80 eğitim ve %20 test olarak ayrıştırılmış, ikicisinde HAM10000 veri seti %90 eğitim ve %10 test olarak ayrıştırılmış ve üçüncü deneyde ise ISIC2019 veri seti %90 eğitim ve %10 test olarak ayrıştırılmıştır. Bu üç farklı veri seti ile eğitilen modelin test işlemi sonrasında elde doğruluk oranları sırasıyla %84.80, %86.33 ve %82.56 olarak raporlanmıştır(Hoang ve ark., 2022).

Rashid ve arkadaşları 2022 yılında yaptıkları bir çalışmada ISIC2020 veri setini kullanarak iki sınıflı sınıflandırma problemine çözüm aramışlardır. Veri seti 584 kötü huylu (melanom) ve 32 542 iyi huylu (benign) olmak üzere toplamda 33 126 deri lezyonu görüntüsünden oluşmaktadır. Araştırmacılar veri setini dengelemek amacıyla ISIC2019 veri setinden 4522 melanom görüntüsü alarak ISIC2020 verisetine eklemişlerdir. Akabinde sınıf dengesizliğini gidermek amacıyla çeşitli veri artırma teknikleri uygulamışlardır. Uygulanan yöntemler arasında yeniden ölçekleme (rescaling), genişlik kaydırma (width shift), döndürme (rotation), kayma aralığı (shear range), yatay çevirme (horizontal flip) ve kanal kaydırma (channel shift) yer almaktadır. Döndürme için 25°, kayma için 20° ve yakınlaştırma için 0.2 değeri kullanılmıştır. Araştırmacılar bu yöntemlerin yalnızca iyi huylu sınıftan 11 670 ve kötü huylu sınıftan 584 görüntüye

uygulanarak veri artırma işleminin gerçekleştirildiğini belirtmişlerdir. Tüm bu işlemler tamamlandıktan sonra elde edilen veri seti %70 eğitim, %15 test ve %15 doğrulama olarak ayrılmıştır. Lakin tüm bu yapılanların yanısıra araştırmacılar veri artırma yönteminin eğitim kısmına yapıldığını belirtmektedir. Burada belirtilen kısım eğitim esnasında yapılan veri artırma yöntemidir (on the fly augmentation). Çalışmada kullanılan yöntemde öncelikle veriler ön işleme adımına sokularak 256x256 boyutuna indirgenir, bu sayede eğitim hızının dramatik oranda artışı belirtilmektedir. Sınıflandırma işlemi için MobileNetV2 mimarisi kullanılmış ve %98.2 doğruluk oranı ve %98.1 F1 skor elde edilmiştir(Rashid ve ark., 2022).

Başka bir çalışmada ISIC 2019, HAM10000 ve Peking Union Tıp Koleji Hastanesi tarafından sağlanan özel bir veriseti kullanılmıştır. Bu özel veriseti toplamda altı sınıfa ait 2 900 görüntü içermektedir. Kullanılan yöntem her üç veri seti üzerinde de deneysel olarak değerlendirilmiş ve elde edilen sonuçlar bu veri setlerinin test bölümleri üzerinden raporlanmıştır. Yapılan bu çalışmada veri artırma işlemi çalışma anında yapılmış ve veri sayısı sabit kalmıştır. Kullanılan veri artırma yöntemleri aşırı öğrenmeyi hafifletmek ve görüntü bilgisinin çeşitliliğini artırmak amacıyla yalnızca eğitim setinde gerçekleştirilmiştir. Bu yöntemler döndürme, yatay çevirmedir. Tüm veri setleri %80 eğitim ve %20 test olacak şekilde ayrılmıştır. Çalışmada cilt lezyonu sınıflandırma görevi için gelişmiş özellik füzyonu ve dikkat mekanizmalarını kullanan bir model önerilmektedir. Model, temel olarak ConvNeXt ağına dayanmakta olup, artık bağlantıları kullanan ConvNeXt bloğu ve paralel bağlantıları kullanan ConvNeXt bloğunun çıktılarının artık bağlantılar yöntemi ile birleştirilmesi (concatenation) sonucu meydana gelmiştir. ISIC2019 ile eğitilen ve değerlendirilen bu modelin doğruluk oranı %92.3'ken HAM10000 veriseti ile eğitim ve değerlendirme sonucu %93.95 olarak raporlanmıştır. Son aşamada Peking Union Tıp Koleji Hastanesi'nden elde edilen veri seti ile eğitilmiş, değerlendirilmiş ve doğruluk oranının %94.31 olduğu raporlanmıştır(Ji ve ark., 2024).

Nawaz ve arkadaşlarının(2025) Kaggle üzerinden elde ettiği 10 015 dermoskopik görüntü içeren veri seti ile yaptıkları çalışmada çok sınıflı sınıflandırma problemi ele alınmıştır. Veri setinde ciddi bir dengesizlik bulunduğu için, eğitim sürecinde hem veri artırma (rotation, flipping, scaling, zooming gibi) hem de sınıf ağırlıklandırma teknikleri uygulanarak bu dengesizliğin etkisi azaltılmaya çalışılmıştır. Veri seti önce %90 eğitim

ve %10 test olarak ikiye ayrılmış, veri artırma işlemleri ise ayırım işleminden sonra yalnızca eğitim setine eğitim esnasında uygulanmıştır. Çalışmada ResNet152V2, EfficientNetV2B0, InceptionResNetV2 ve MobileNetV3 gibi önceden eğitilmiş modeller ile sıfırdan tasarlanmış FCDS-CNN mimarisi karşılaştırılmıştır. FCDS-CNN modeli; ayrılabilir evrişim katmanları, batch normalization, havuzlama ve dropout katmanları ile oluşturulmuş olup çok sınıflı sınıflandırma için softmax aktivasyon fonksiyonu kullanılmıştır. Modelin eğitimi Adam optimizasyon algoritması ve categoric cross entropy kayıp fonksiyonu ile gerçekleştirilmiştir. Sonuç olarak, önerilen FCDS-CNN mimarisinin %96.66 doğruluk ve %96 F1 Skoru ile tüm önceden eğitilmiş modellerden daha yüksek performans sergilediği belirtilmiştir. Ayrıca özellikle azınlık sınıflarında (örneğin AK ve VASC) ve görsel olarak benzer sınıfların ayırımında (BKL, NV gibi) daha başarılı olduğu ifade edilmiştir(Nawaz ve ark., 2025).

2023 yılında Raghavendra ve arkadaşları HAM10000 veri setini kullanarak çok sınıflı sınıflandırma problemini ele almıştır. Bu çalışmada veri setinde ciddi bir sınıf dengesizliği bulunduğu için, öncelikle veri dengeleme ve veri artırma yöntemleri uygulanmıştır. Veri seti %80 eğitim ve %20 test olarak ikiye ayrıldıktan sonra sadece eğitim verisine Siyah Şapka Filtreleme (Black Hat Filtering) uygulanmış ve ardından ImageDataGenerator ile döndürme, kaydırma, kayma, yakınlaştırma ve yatay-dikey çevirme teknikleri kullanılarak veri artırma yapılmıştır. Test verisine herhangi bir veri artırma işlemi uygulanmamıştır. Bu işlemler sonucunda eğitim setindeki görüntü sayısı 8 012'den 45 756'ya yükselmiş ve sınıflar arasında dengeli bir yapı elde edilmiştir.Çalışmada önerilen yaklaşım, VGG16 tabanlı bir CNN mimarisinin değiştirilmiş bir versiyonudur. Özellikle, geleneksel flatten katmanı yerine Küresel Ortalama Havuzlama (Global Average Pooling - GAP) kullanılarak hem parametre sayısı azaltılmış hem de aşırı öğrenme riski düşürülmüştür. Model, beş evrişim bloğu ve bunları takip eden Maxpool katmanlarından oluşmakta; GAP katmanının ardından 64 nöronlu bir yoğun katman ve 7 sınıfı temsil eden softmax çıktı katmanı yer almaktadır. Eğitim sürecinde Adam optimizasyon algoritması ve categoric cross entropy kayıp fonksiyonu kullanılmıştır. Sonuç olarak önerilen model, düşük hesaplama maliyetine rağmen VGG16, ResNet50, MobileNetV2 ve DenseNet121 gibi önceki aktarım öğrenimi modellerinden daha yüksek performans göstermiştir. Test doğruluğu %97.20, eğitim

doğruluđu %99.96 ve ağırlıklı ortalama F1 Skoru %97 olarak elde edilmiştir. Ayrıca ROC-AUC değeri 0.9969 ile karşılaştırılan diğerk tüm modellerden üstün bulunmuştur (Raghavendra ve ark., 2023).

Bütün bu çalışmalardan elde edilen bilgiler kullanılarak, literatürdeki başarılı ve eksik yönler gözlemlenmiş olup çalışmamız bu eksik yönleri tamamlayacak ve başarılı yöntemlerden de ilham alınarak yeni yaklaşımlar kullanılacaktır. Bu yönüyle çalışma, literatürdeki boşlukları doldurmakta ve gelecekte yapılacak araştırmalar için sağlam bir temel sunmaktadır.



### **3. MATERYAL VE YÖNTEM**

#### **3.1. Yapay Zeka ve Derin Öğrenme**

##### **3.1.1. Yapay zeka**

Günümüzde yapay zeka popülerliğini hızlıca artıran bir problem çözme yaklaşımıdır. Bu yaklaşım büyük veri kümelerindeki örüntüleri, bağlamları yakalamak üzerine kurulmuştur. Yapay zekanın makine öğrenmesi, derin öğrenme, doğal dil işleme gibi birçok alt alanı bulunmaktadır. Tüm bu alanların ortak noktası ise daha önce de belirtildiği gibi içerisinde anlam bulunan bir verinin anlam kısmını tespit etmeye çalışması ve benzer bir veriyle karşılaştığında bu anlamı tespit etmeye, yakalamaya çalışmasıdır. Yapay zekanın en büyük avantajlarından biri de çok büyük verilerden, insanların dahi çıkarmakta zorlandığı bağlamları çıkarıp, verideki anlam olarak nitelendirilen kısmı kolaylıkla tespit edebilmesidir. Yine geleneksel algoritmalarda olmayıp yapay zekada olan bir avantaj ise veriyi yorumlama yeteneğidir. Böylelikle incelenen veri ile daha önce karşılaşılmış olmasa bile yapay zeka veri içerisindeki anlamı çıkarıp yorum yapabilme kabiliyetine sahiptir(Alzubaidi ve ark., 2021; Hamet & Tremblay, 2017).

##### **3.1.2. Derin öğrenme**

Derin öğrenme yapay zekanın alt alanıdır. Bu alan özellikle büyük veri kümelerindeki anlamların çıkarılmasında başarı göstermektedir. Derin öğrenmenin esin kaynağı ise insanın beynindeki sinir hücreleri, nöronlardır. Bu yapı kullanılarak ve birbirine bağlanarak adeta yapay bir beyin üretilmesini tasvir etmektedir. Tamamen sayılarla çalışan bu yapı devasa sistemlerin en kritik parçası haline gelmiştir, tıpkı insandaki beyin gibi. Sayıların birbirileri ve sonuçlar ile arasındaki ilişkiyi arayarak ve bu sayede mantık dediğimiz kavramı yakalayarak öğrenme işlemini gerçekleştirir. Bu sayede günümüzde hemen hemen her alanda bulunan sistemlerin vazgeçilmez parçası olur(Kim, 2016; LeCun ve ark., 2015).

### 3.2. Evrişimsel Sinir Ağları (CNN)

CNN'ler yakın tarihte popülerliğini hızla artırmış yapay zeka yöntemidir. Bu yöntem dijital ortamdaki görselleri belli bir kural ve çerçeve doğrultusunda sıkıştırarak özelliklerini çıkarır ve içerisinde anlamları kaybetmeden işler. Ardından bu işlenmiş veriyi derin öğrenmede bahsedilen yapay sinir ağlarına, yani nöronlara iletir. İletilen bu veriler doğrultusunda görselin ne olduğu bilgisayar tarafından anlaşılmaya çalışılır(Alzubaidi ve ark., 2021).


#### 3.2.1. CNN mimarisi ve temel bileşenleri

##### Evrişim katmanları

CNN'lerin en önemli katmanı olan evrişim katmanı görsel üzerinde kullanıcı tarafından belirtilen boyutlarda bir matris gezdirerek, bu matris ile görselin eşleşen kısmını çarpar, toplar. Bu sayede görselden kenarlar, dokular vb. görsel özellikler elde edilmiş, çıkarılmış olur. Oluşturulan bu yeni matrise özellik haritası denir. Özellik haritaları resimlerin içerisindeki anlamları saklayan sayfalar gibi düşünülebilir(Hossain & Sajib, 2019)

##### Aktivasyon fonksiyonları

Aktivasyon fonksiyonları CNN mimarisinin yapıtaşlarındandır. Bu fonksiyonların temel görevi önceki katmanlardan gelen verinin belirli bir fonksiyon ile dönüşümünü sağlar(Hao ve ark., 2020). Bu sayede öğrenme mantığı devreye girmiş olur. Bütün yapı tamamen bir matematik işleminden ziyade belirli kurallar dahilinde sonuçlar üreten doğrusal olmayan bir yapay beyin gibi davranır. Günümüzde sıkça kullanılan aktivasyon fonksiyonlarından bazıları ReLU, Sigmoid, Swish'tir(Agarap, 2019; Y. Wang ve ark., 2020).



Şekil 3.1 ReLU fonksiyon grafiği (Agarap, 2019)

#### Havuzlama katmanları

Havuzlama katmanları görsellerin içerisindeki önemi yüksek anlamları kaybetmeden, bu anlamlı kısımları ön plana sürerek görseli sıkıştırmayı sağlar. Bu sayede işlenen görselin daha az piksele sahip olması ve işlem yükü açısından hafifletilmesi sağlanır. Ayrıca görseldeki her bir piksele bağlı olunmaması ve bağlamların anlam üzerinden öğrenilmesi doğrusal olmayan problemlerin çözümü için de sağlıklı bir yöntemdir (Gholamalinezhad & Khosravi, 2020; Nirthika ve ark., 2022).

#### Tam bağlı katmanlar (FC)

Her bir parametrenin, yani nöronun başka bir katmana yani nörona bağlanması sayesinde oluşan yapıya Tam Bağlı Katman (FC) ismi verilir. CNN mimarisi ise evrişim, havuzlama ve aktivasyon katmanlarıyla birlikte FC içerecek şekilde yapılandırılır (Basha ve ark., 2020; Liu ve ark., 2018).

### 3.2.2. Dikkat mekanizmaları

Dikkat Mekanizmaları CNN veya diğer derin öğrenme modellerinde önemli özellikleri öne çıkarmak ve gereksiz görülen önemsiz bilgileri bastırmak için kullanılmaktadır. Bu yaklaşım önemli özellikleri daha da ön plana çıkarırken, önemsiz olan özellikleri ise arka plana atar (J. Li ve ark., 2020; Roy ve ark., 2019).

Bu çalışmada dikkat mekanizmaları FC'dan hemen önce kullanılmış ve etkileri gözlemlenmiştir.

#### Kanal dikkat mekanizmaları


Kanal dikkat mekanizmesinin temel mantığı özellik haritalarından hangilerinin daha önemli ve öncelikli olduğu tespit etmesidir(Chen ve ark., 2017; J. Zhang ve ark., 2021). Birçok özellik haritası bulunan bir görselin bazı katmanları diğerlerine nazaran daha az önemlidir; bazı katmanlar ise diğerlerine göre daha önemlidir. Kanal dikkat mekanizması bu katmanları tespit eder ve ağırlıklarını yeniler(Roy ve ark., 2019).

#### Uzamsal dikkat Mekanizmaları

Uzamsal dikkat mekanizmaları özellik haritalarının hangi bölgelerinin daha önemli olduğunu bulmaya çalışır. Bu sayede görüntüdeki odaklanılması gereken konunun ağırlık oranını artırır(Chen ve ark., 2017).

#### Hibrit dikkat yapıları

Hibrit yapılar bölüm 3.2.2.1 ve 3.2.2.2'de bahsedilen kanal ve uzamsal dikkat mekanizmalarını birleştirerek kullanan yapılardır. Bu yapılardan en bilinenleri CBAM yapısıdır. CBAM giriş vektörlerini alarak önce kanal dikkat fonksiyonundan geçirir ardından uzamsal dikkat fonksiyonundan geçirerek yeni bir ağırlıklandırılmış özellik haritası üretir (Yin ve ark., 2023).



Şekil 3.2 CBAM yöntemi (Woo ve ark., 2018)

### 3.3. Veri Seti ve İşlemleri

#### 3.3.1. Veri seti

Bu çalışmada kullanılan veri seti açık kaynaklı olup kullanılan görüntüler, “International Skin Imaging Collaboration (ISIC)” tarafından yayımlanan ISIC 2019: Skin Lesion Analysis Towards Melanoma Detection veri setinden elde edilmiştir. ISIC 2019, cilt hastalıklarının sınıflandırılması amacıyla oluşturulmuş geniş çaplı dermoskopik görüntü koleksiyonudur. Veri seti, gerçek klinik ortamlardan toplanmış yüksek çözünürlüklü görüntüler içermesi nedeniyle literatürde yaygın olarak tercih edilen referans veri setlerinden biridir(Kassem ve ark., 2020; Saeed ve ark., 2023). Veri setinde 8 farklı cilt hastalığından toplam 25 331 adet dermoskopik görüntü bulunmaktadır.


Tablo 3.1 ISIC 2019 sınıf bilgileri

| Numara | Sınıf                | Kısaltma | Görüntü Sayısı |
|--------|----------------------|----------|----------------|
| 1      | Actinic Keratosis    | AK       | 867            |
| 2      | Basal Cell Carcinoma | BCC      | 3 323          |
| 3      | Bening Keratosis     | BKL      | 2 624          |
| 4      | Dermatofibroma       | DF       | 239            |

Tablo 3.2 (Devam) ISIC 2019 sınıf bilgileri


| Numara        | Sınıf                   | Kısaltma | Görüntü Sayısı |
|---------------|-------------------------|----------|----------------|
| 5             | Melanoma                | MEL      | 4 522          |
| 6             | Melanocytic Nevi        | NV       | 12 875         |
| 7             | Squamous Cell Carcinoma | SCC      | 628            |
| 8             | Vascular Lesions        | VASC     | 253            |
| <b>Toplam</b> |                         |          | 25 331         |

Tablo 3.1’de ayrıntılarına değinilen bu sınıfların her biri, farklı klinik özelliklere ve görsel yapıya sahip hastalık tiplerini temsil eder. Şekil 3.1’ de bu sınıflar içerisinde bulunan görüntülerden birer örnek gösterilmiştir.



Şekil 3.3 ISIC 2019 veri setinden örnek görüntüler (Saeed ve ark., 2023)

Tüm görüntüler RGB formatında olup, farklı çözünürlüklerde kaydedilmiştir. Veri setinde görsel açıdan birbirinden farklı olan görüntülerin yanı sıra benzer görüntüler de bulunmaktadır.



Şekil 3.4 ISIC 2019 veri setinde bulunan farklı sınıflardaki benzer görüntüler

### 3.3.2. Alt veri setlerinin oluşturulması ve dengeleme çözümü

Bu çalışmada her biri farklı boyut ve özelliklerde birden fazla alt veri seti oluşturulmuş ve her birinin sonuçları ayrı ayrı raporlanmıştır. İlk olarak Tablo 3.1’de ayrıntıları görülen ana veri setinden her sınıfta en fazla 1 000 görüntü olacak şekilde alt bir veri seti oluşturulmuştur.

Tablo 3.3 Alt veri seti – A (AVS-A)

| Numara        | Sınıf                   | Kısaltma | Görüntü Sayısı |
|---------------|-------------------------|----------|----------------|
| 1             | Actinic Keratosis       | AK       | 867            |
| 2             | Basal Cell Carcinoma    | BCC      | 1 000          |
| 3             | Bening Keratosis        | BKL      | 1 000          |
| 4             | Dermatofibroma          | DF       | 239            |
| 5             | Melanoma                | MEL      | 1 000          |
| 6             | Melanocytic Nevi        | NV       | 1 000          |
| 7             | Squamous Cell Carcinoma | SCC      | 628            |
| 8             | Vascular Lesions        | VASC     | 253            |
| <b>Toplam</b> |                         |          | <b>5 987</b>   |

Her sınıf için kullanılan görüntüler ana veri setinden rastgele ve tekil olarak seçilmiş, böylece hiçbir görüntü yinelenmemiştir. Ayrıntıları Tablo 3.3’de görülen AVS-A tamamen rastgele olacak şekilde % 80 eğitim ve % 20 test olarak ayrıştırılmıştır.

Elde edilen %80’lik eğitim kısmına veri artırma yöntemleri uygulanarak tüm sınıfların eşit sayıda görüntüye sahip olmaları sağlanmıştır. Her görüntü eşit sayıda kullanılarak çoğaltılmıştır.

Tablo 3.4 Veri artırmada kullanılan parametreler

| Parametre                         | Oranı (Rastgele Aralık) |
|-----------------------------------|-------------------------|
| <i>Döndürme</i>                   | 0-60 °                  |
| <i>Yatay Kaydırma</i>             | % 0-20                  |
| <i>Dikey Kaydırma</i>             | % 0-20                  |
| <i>Kesme Dönüşümü</i>             | % 0-20                  |
| <i>Yakınlaştırma/Uzaklaştırma</i> | % 70-130                |
| <i>Parlaklık Değişimi</i>         | % 70-130                |
| <i>Yatay Çevirme</i>              | 0,1 (Evet, Hayır)       |
| <i>Doldurma Yöntemi</i>           | Yansıtma                |
| <i>Renk Değişikliği</i>           | % 0-30                  |

Eğitim kısmına veri artırma işlemi uygulandıktan sonra elde edilen çoğaltılmış ve dengelenmiş veri, seti sınıf başına sırasıyla 250, 500 ve 750 görüntüden oluşan alt eğitim setlerine bölünmüştür. Bunlar sırasıyla Dengelenmiş Alt Veri Seti-A (DAVS-A), DAVS-B ve DAVS-C olarak isimlendirilecektir.

Tablo 3.5 Çalışmada kullanılan alt veri setleri

| No.           | Sınıf | DAVS-A   | DAVS-B   | DAVS-C   | Test Seti (AVS-A %20) |
|---------------|-------|----------|----------|----------|-----------------------|
|               |       | Gör. Ad. | Gör. Ad. | Gör. Ad. | Gör. Ad.              |
| 1             | AK    | 250      | 500      | 750      | 174                   |
| 2             | BCC   | 250      | 500      | 750      | 200                   |
| 3             | BKL   | 250      | 500      | 750      | 200                   |
| 4             | DF    | 250      | 500      | 750      | 48                    |
| 5             | MEL   | 250      | 500      | 750      | 200                   |
| 6             | NV    | 250      | 500      | 750      | 200                   |
| 7             | SCC   | 250      | 500      | 750      | 126                   |
| 8             | VASC  | 250      | 500      | 750      | 51                    |
| <b>Toplam</b> |       | 2 000    | 4 000    | 6 000    | 1 199                 |

Bu çalışma sürecinde Tablo 3.5’te görülen veri setleri ile kullanılmış olup doğrulama için ayrı bir veri seti tanımlanmamıştır. Bu sayede amaç derin öğrenme modelinin eğitim seti ile eğitilerek daha önce görmediği bir veri setinde (Test Seti) yüksek başarı oranını elde etmesini sağlamak ve bununla beraber hastalıklarının karakterize edici görsel farklarını öğrenme işleminin doğrulanmasıdır.

Çalışmanın son aşamasında, Tablo 3.1’de gösterilen ISIC 2019 veri seti kullanılarak her sınıf için en fazla 3 000 görüntü içeren yeni bir AVS oluşturulmuş ve AVS-B olarak adlandırılmıştır. Ayırıştırma işlemi sırasında görüntüler ana veri setinden tamamen rastgele ve tekil olarak seçilmiş, böylece hiçbir görselin tekrar edilmesine izin verilmemiştir.

Tablo 3.6 AVS-B

| Numara        | Sınıf                   | Kısaltma | Görüntü Sayısı |
|---------------|-------------------------|----------|----------------|
| 1             | Actinic Keratosis       | AK       | 867            |
| 2             | Basal Cell Carcinoma    | BCC      | 3 000          |
| 3             | Bening Keratosis        | BKL      | 2 624          |
| 4             | Dermatofibroma          | DF       | 239            |
| 5             | Melanoma                | MEL      | 3 000          |
| 6             | Melanocytic Nevi        | NV       | 3 000          |
| 7             | Squamous Cell Carcinoma | SCC      | 628            |
| 8             | Vascular Lesions        | VASC     | 253            |
| <b>Toplam</b> |                         |          | 13 611         |

Bu aşamadan sonra çalışmanın sonunda kullanılacak iki yeni DAVS iki farklı strateji izlenerek hazırlanmıştır. İlk yaklaşımda, Tablo 3.4’te belirtilen veri artırma kuralları tüm sınıflara uygulanmış ve her bir sınıftaki görüntü sayısı 3 000’e tamamlanmıştır. Ardından veri seti %80 eğitim ve %20 test olarak ayrıştırılmıştır. Oluşturulan bu veri seti DAVS-D olarak isimlendirilmiştir. İkinci yaklaşımda ise veri seti önce %80 eğitim ve %20 test olarak ayrıştırılmış ve yalnızca eğitim bölümüne veri artırma uygulanarak bütün sınıflardaki görüntü sayısı 2 400’e çıkarılmıştır. Oluşturulan bu veri seti ise DAVS-E olarak isimlendirilmiştir.

Tablo 3.7 Çalışmanın son aşamasında kullanılan DAVS'leri

| No. | Sınıf | DAVS-D                  |                       | DAVS-E                  |                       |
|-----|-------|-------------------------|-----------------------|-------------------------|-----------------------|
|     |       | Eğitim Seti<br>Gör. Ad. | Test Seti<br>Gör. Ad. | Eğitim Seti<br>Gör. Ad. | Test Seti<br>Gör. Ad. |
| 1   | AK    | 2 400                   | 600                   | 2 400                   | 174                   |
| 2   | BCC   | 2 400                   | 600                   | 2 400                   | 600                   |
| 3   | BKL   | 2 400                   | 600                   | 2 400                   | 525                   |
| 4   | DF    | 2 400                   | 600                   | 2 400                   | 48                    |
| 5   | MEL   | 2 400                   | 600                   | 2 400                   | 600                   |
| 6   | NV    | 2 400                   | 600                   | 2 400                   | 600                   |

Tablo 3.8 (Devam) Çalışmanın son aşamasında kullanılan DAVS'leri

| No.           | Sınıf | DAVS-D                  |                       | DAVS-E                  |                       |
|---------------|-------|-------------------------|-----------------------|-------------------------|-----------------------|
|               |       | Eğitim Seti<br>Gör. Ad. | Test Seti<br>Gör. Ad. | Eğitim Seti<br>Gör. Ad. | Test Seti<br>Gör. Ad. |
| 7             | SCC   | 2 400                   | 600                   | 2 400                   | 126                   |
| 8             | VASC  | 2 400                   | 600                   | 2 400                   | 51                    |
| <b>Toplam</b> |       | 19 200                  | 4 800                 | 19 200                  | 2 724                 |

Tablo 3.7’de de gözüken bu iki farklı hazırlama stratejisi ile hazırlanan veri setleri, önceki aşamalarda elde edilen en iyi model ve hiperparametreler kullanılarak ayrı ayrı eğitilmiş; böylece veri artırma işleminin ayrıştırmadan önce uygulanması ile ayrıştırmadan sonra uygulanması arasındaki performans farkları karşılaştırılarak raporlanmıştır. Bu son çalışmanın temel amacı, veri miktarının artırılmasıyla öğrenme kapasitesinin yükseldiğini ve aşırı öğrenme, ezberleme gibi problemlerin azaldığını göstermek ve veri artırma stratejisinin doğru şekilde uygulanmamasının yanıltıcı sonuçlar üretebileceğini göstermektir.

### 3.3.3. Veri ön işleme

Veri ön işleme adımı, literatürde ki çalışmaların hemen hemen hepsinde vazgeçilmez bir adımdır (Alzubaidi ve ark., 2021; Chen ve ark., 2017; Hao ve ark., 2020; Hossain & Sajib, 2019; J. Li ve ark., 2020; Rezaoana ve ark., 2020; J. Zhang ve ark., 2021). Bu yaklaşım verileri eğitilecek modele vermeden önce gürültü temizleme, ilgili alanı kırpma, verilerin ezberlenmemesi için ufak değişimlere tabii tutma vb. yöntemleri içerebilir. Bu çalışmada kullanılan veri ön işleme yöntemi literatürde “On-the-fly Augmentation” olarak isimlendirilmektedir. Bu yöntem verileri ilgili modele vermeden önce kısmi değişimlere tabii tutar ve bu sayede görüntülerin model tarafından ezberlenmemesini sağlar.

Tablo 3.9 Veri ön işlemede kullanılan parametreler

| Parametre                         | Oranı (Rastgele Aralık) |
|-----------------------------------|-------------------------|
| <i>Döndürme</i>                   | 0-15 °                  |
| <i>Yatay Kaydırma</i>             | % 0-10                  |
| <i>Dikey Kaydırma</i>             | % 0-10                  |
| <i>Kesme Dönüşümü</i>             | % 0-10                  |
| <i>Yakınlaştırma/Uzaklaştırma</i> | % 90-110                |
| <i>Parlaklık Değişimi</i>         | % 80-120                |
| <i>Yatay Çevirme</i>              | 0,1 (Evet, Hayır)       |
| <i>Doldurma Yöntemi</i>           | En Yakın                |

### 3.4. Transfer öğrenme

Transfer öğrenme daha önce eğitilmiş bir CNN modelinin bilgi ve ağırlıklarını güncelleyerek yeni bir veri kümesiyle yeniden eğitme yöntemidir. Bu sayede sıfırdan eğitim yapılmamış ve zamandan tasarruf edilmiş olunur. Aynı zamanda transfer öğrenmede kullanılan modellerin başarıları daha önce kanıtlandığı için elde edilecek sonuçlarda da belli bir oranda başarı görülmesi beklenir (Gupta ve ark., 2022; Hussain ve ark., 2019; Salehi ve ark., 2023; Shin ve ark., 2016).

#### 3.4.1. Önceden eğitilmiş modeller

Önceden eğitilmiş modeller, büyük veri setleri üzerinde eğitilmiş ve öğrenilmiş ağırlıkları barındıran CNN modelleridir. Bu modeller genellikle ImageNet, COCO gibi geniş veri setlerinde eğitilmiş olup, farklı görevlerde transfer öğrenme ile yeniden kullanılabilir. Bu modellerden bazıları DenseNet (Huang ve ark., 2017), Inception ResNet v2 (Szegedy ve ark., 2017), EfficientNet (Tan & Le, 2019)'dir.

### 3.4.2. Transfer öğrenme stratejileri

#### Feature extraction

Özellik çıkarımı yöntemi, önceden eğitilmiş bir modelin sadece özellik çıkaran katmanlarını kullanıp, üzerine ek olarak yeni bir sınıflandırıcı katmanı ekleyerek modeli bu şekilde eğitmeyi kapsar. Bu sayede modelin üst katmanları yeni göreve adapte edilir, alt katmanları ise sabit tutulur(Shaha & Pawar, 2018).

#### Ön eğitim (Warmup)

Isınma aşaması olarak da isimlendirilen bu yöntemde model asıl eğitime alınmadan önce, ağırlıkları yavaşça güncellenecek şekilde asıl eğitimden daha kısa bir eğitime tabii tutulur. Bu yöntem ile ani değişikliklerden kaynaklı öğrenme bozuklukları önlenmiş olur(Kalra & Barkeshli, 2024).

#### İnce ayar

İnce ayar (Fine-tuning), önceden eğitilmiş modelin ağırlıklarının kademeli olarak tüm katmanlarda yeniden optimize edilmesi işlemidir. Bu sayede model, yeni veri setine daha iyi uyum sağlar ve performans artışı elde edilir(Vrbančić & Podgorelec, 2020).

### 3.4.3. Transfer öğrenme çalışması

#### En iyi mimarinin belirlenmesi

Bu çalışmanın transfer öğrenme aşamasında beş farklı önceden eğitilmiş CNN mimarisi kullanılmıştır. Kullanılan mimariler sırasıyla: DenseNet201, MobileNetV3Large, Inception-ResNetV2, EfficientNetV2S ve EfficientNetV2B3'tür (Huang ve ark., 2017; Qian ve ark., 2021; Szegedy ve ark., 2017; Tan & Le, 2019, 2021; S.-H. Wang & Zhang, 2020). Kullanılan mimarilerin "ImageNet" ağırlıkları korunmuş eğitime rastgele ağırlıklar ile başlanmamıştır. Eğitim sürecinde, mimarilerin evrişim katmanlarına müdahale edilmemiştir. Lakin sonrasında bulunan FC'lar kaldırılmıştır. Son evrişim

katmanından sonra, tüm mimarilerin sınıflandırma performansını artırmak ve hesaplama yükünü azaltmak için bir Küresel Ortalama Havuzlama (GAP) katmanı eklenmiş, ardından iki yoğun (dense) ve bir Dropout (D) katmanı ile modellerin genelleme yeteneği artırılmıştır. Sekiz sınıflı bir sınıflandırma çalışması olduğundan, çıktı katmanında sekiz nörona sahip bir dense katmanı kullanılmıştır. Bu aşamada yoğun katmanın nöron sayısı 1024 ve Dropout oranı 0.7 olarak kullanılmıştır. Modellerin eğitiminde, Adam(1e-4) optimizasyon algoritması kullanılmış ve kayıp fonksiyonu olarak categorical crossentropy kullanılmıştır.

Akabinde tüm bu mimariler sırasıyla DAVS-A, DAVS-B, DAVS-C ile ön eğitime alınmıştır. Ön eğitimin bitmesine müteakip yalnızca BatchNormalization katmanları dondurularak tam olarak eğitilmiş ve test edilmiştir. Aralarından en yüksek F1 skoruna ulaşan mimari temel mimari olarak seçilmiştir.


#### Seçilen mimarinin dikkat mekanizmaları ile güçlendirilmesi

Seçilen bu temel mimari FC'a geçilmeden hemen önce bölüm 3.2.2'de bahsedilen çeşitli dikkat mekanizmaları ile güçlendirilip tekrar eğitilmiştir. Denenen dikkat mekanizması yöntemleri sırasıyla: Kanal Dikkat, Uzamsal Dikkat, CBAM, BAM ve SE yöntemleridir. Bu yöntemlerin her biri farklı hiperparametre kümeleriyle farklı sonuçlar vereceği için EO algoritmasıyla hiperparametre optimizasyonuna sokularak her yöntemin denenmesi uygun görülmüştür.

### **3.5. Hiperparametre Optimizasyonu**

#### **3.5.1. Optimizasyon algoritması: Equilibrium Optimizer**

Equilibrium Optimizer (EO), mühendislik ve yapay zekâ problemlerinde kullanılan meta-sezgisel bir optimizasyon algoritmasıdır. EO algoritması, fiziksel sistemlerdeki denge durumundan esinlenerek oluşturulmuştur. Temel olarak, aday çözümler (bunlara ajan ismi verilir) bir popülasyon olarak başlatılır ve her bir çözüm, denge durumu ve rastgele değişimlerle güncellenir(Faramarzi ve ark., 2020).



Şekil 3.5 EO algoritması(Faramarzi ve ark., 2020)

EO, özellikle çok boyutlu ve karmaşık optimizasyon problemlerinde, yerel minimuma takılmadan global optimuma yaklaşabilmesiyle tercih edilir. Derin öğrenme bağlamında ise hiperparametre optimizasyonu için kullanılabilir; örneğin LR parametreleri, dropout oranı gibi parametrelerin ayarlanmasında EO algoritması kullanılabilir (Çetin-Kaya, 2024).

### 3.5.2. Optimize edilecek hiperparametreler

Tablo 3.10 Optimize edilen hiperparametreler ve değerleri

| Hiperparametre           | Değer                                                      |
|--------------------------|------------------------------------------------------------|
| LR Başlangıç             | 1e-4; 5e-4; 1e-5                                           |
| LR Düşüş Katsayısı       | 0.1; 0.25; 0.5                                             |
| LR Değişim Sabrı         | 3; 4; 5                                                    |
| Dropout (D)              | 0.1; 0.15; 0.2; 0.25; 0.3; 0.35; 0.4; 0.45; 0.5; 0.55; 0.6 |
| L2 Düzenleyicisi         | 1e-4; 5e-4; 1e-3; 5e-3; 1e-2; 5e-2; 0.1; 0.25; 0.5         |
| Aktivasyon Fonksiyonu    | GELU; ReLU; Swish; Leaky ReLU                              |
| FC Nöron Sayısı          | 32; 64; 96; 128; 190; 256; 384; 512; 768; 1024; 1536; 2048 |
| Dikkat Mekanizması       | Channel; Spatial; CBAM; BAM; SE                            |
| Optimizasyon Algoritması | Adam; RMSProp; AdamW                                       |

Bu tabloda 3.5.2 numaralı bölüm altında detayları verilen hiperparametre setleri sunulmakta olup, tüm deneysel kurulum bu parametreler üzerinden gerçekleştirilmiştir.

### Öğrenme oranı (LR)

Öğrenme oranı (LR), bir derin öğrenme modelinin kayıp fonksiyonunda ne kadar büyük adımlarla ilerleyeceğini belirleyen en kritik hiperparametrelerden biridir. Modelin ağırlıkları her güncellemede bu oran kadar değiştirilir. Bu sebeple LR'nın doğru seçilmesi eğitim süreci için çok önemlidir(Smith, 2017).

- LR çok yüksek seçilirse, model büyük adımlar atar, minimum noktaları aşar ve öğrenme süreci kararsız hâle gelir.
- LR çok düşük seçilirse, model küçük adımlarla ilerler, öğrenme yavaşlar hatta yerel minimumlara da takılabilir.

Bu nedenle derin öğrenme modellerinde genellikle LR'nı değiştiren stratejiler kullanılır. Özellikle son yıllarda ön plana çıkan learning rate ısınması diğer araştırmacılar tarafından da sıkça kullanılmaktadır. Isınma, LR'nın eğitimin başında düşük değerlerden yavaşça yükselmesini sağlar; böylece model, daha iyi bölgelere ulaşır ve daha iyi sonuçlar elde edebilir(Lewkowycz ve ark., 2020; Z. Li & Arora, 2019).

Bu çalışmada LR'nın başlangıç değeri, kaç epoch boyunca iyileşme sağlanmazsa değiştirilmesi gerektiği ve değiştirilme oranının EO algoritması tarafından bulunması sağlandı.

### Düzenleştirme parametreleri

Derin öğrenme modelleri yüksek sayıda öğrenilebilir parametreye sahip oldukları için, eğitim verisini aşırı şekilde ezberlemeye eğilimlidir. Bu durum, modelin eğitim kümesinde yüksek başarı göstermesine rağmen doğrulama ve test kümelerinde düşük performans sergilemesine neden olur. Düzenleştirme (regularization) yöntemleri bu

problemi baskılamak amacıyla kullanılan temel tekniklerdir ve modelin daha dengeli, daha genellenebilir bir şekilde öğrenmesini sağlar(Moradi ve ark., 2020).

Bu çalışmada kullanılan düzenleme parametreleri D, L2 ceza katsayısı ve aktivasyon fonksiyonları üzerinden optimize edilmiştir.

D, eğitim sırasında ağırların belirli nöronlarını rastgele devre dışı bırakarak modelin farklı alt ağlar öğrenmesini sağlar. Böylece nöronlar arasındaki gereksiz bağımlılıklar zayıflar ve modelin daha sağlam, daha esnek bir anlam geliştirmesi sağlanır(Garbin ve ark., 2020).Bu çalışmada D oranı 0.1'den 0.6'ya kadar geniş bir aralıkta taranmış ve en uygun değer deneysel olarak belirlenmiştir.

L2 düzenleme (weight decay), büyük ağırlıkları cezalandırarak ağırlıkların daha küçük ve dengeli değerlere indirilmesini sağlar. Bu yaklaşım, modelin karar sınırlarını daha yumuşak hâle getirir ve gürültülü örnekler üzerine aşırı uyum sağlamasını engeller(Laarhoven, 2017). Bu çalışmada L2 ceza katsayısı 0.0001 ile 0.5 arasında denenmiş ve optimum değer hiperparametre arama sürecinde belirlenmiştir.

Son olarak, modelin doğrusal olmayan özellikleri işlemesini sağlayan aktivasyon fonksiyonları da düzenleme etkisine dolaylı olarak katkı sunmaktadır. Örneğin ReLU, Swish, GELU ve LeakyReLU gibi fonksiyonlar; gradyan akışını düzenleyerek derin ağlarda öğrenme dengesini korur(Agarap, 2019; Hao ve ark., 2020; Y. Wang ve ark., 2020). Aktivasyon fonksiyonu seçimi, modelin genelleme performansını doğrudan etkilediğinden, bu parametre de çalışma kapsamında optimize edilmiştir.

Bu düzenleme parametrelerinin birlikte değerlendirilmesi, modelin hem yüksek doğrulukta hem de aşırı uyumdan uzak, kararlı bir yapıda öğrenmesini sağlamıştır. Böylece model performansı üzerinde kritik bir rol oynayan düzenleme süreci, kapsamlı şekilde optimize edilerek en verimli kombinasyon elde edilmiştir.

### Derin katman yapıları

Derin öğrenme modellerinin performansı, yalnızca kullanılan optimizasyon yöntemlerine veya düzenleme tekniklerine değil, aynı zamanda ağın mimari derinliğine ve katmanların birbirleriyle kurduğu yapısal ilişkilere de doğrudan bağlıdır(Basha ve ark., 2020). Derin katman yapıları, modelin girdilerdeki karmaşık örüntüleri yakalama kapasitesini belirleyen temel unsurdur. Özellikle görüntü sınıflandırma görevlerinde, farklı seviyelerdeki anlamları öğrenebilmek için ağın yeterli sayıda parametreye sahip olması kritik bir gerekliliktir(Salehi ve ark., 2023).

Bu çalışmada kullanılan derin katman yapıları; aktif nöron sayısı değişen FC'lar ve dikkat mekanizmaları gibi bileşenlerin farklı kombinasyonlarıyla oluşturulmuştur. Mimarideki parametre sayısı arttıkça modelin temsil gücü yükselmekte, ancak aynı zamanda aşırı öğrenme riski ve hesaplama maliyeti de artmaktadır. Bu nedenle FC'daki nöron sayısı ve hangi dikkat mekanizmasının kullanılacağı, hiperparametre arama sürecinde dikkatle optimize edilmiştir.

Özellikle FC'da kullanılan nöron sayıları, modelin son karar verme aşamasındaki soyutlama gücünü belirler. Bu doğrultuda bu çalışmada 32 ile 2048 arasında değişen geniş bir nöron aralığı değerlendirilmiştir. Buna ek olarak FC'a geçmeden hemen önce CBAM, SE, BAM gibi dikkat mekanizmalarının eklenmesi, ağın daha anlamlı özelliklere odaklanmasını sağlayarak derin yapının verimliliğini artırması beklenmiştir.

### Optimizasyon algoritmaları

Derin öğrenme modellerinin başarılı bir şekilde eğitilebilmesi için, ağın sahip olduğu milyonlarca parametrenin doğru yönde ve doğru miktarda güncellenmesi gerekir. Optimizasyon algoritmaları (optimizer), bu parametre güncellemelerinin nasıl yapılacağını belirleyen temel yapılardır. Amaç, kayıp fonksiyonunu olabildiğince hızlı ve kararlı bir şekilde minimize ederek modelin hedef sınıfları doğru tahmin etmeyi öğrenmesini sağlamaktır(Soydaner, 2020).

Bu çalışmada Adam, RMSProp ve AdamW gibi güncel ve yaygın kullanılan optimizasyon algoritmaları değerlendirilmiştir. Adam, adaptif LR yaklaşımı sayesinde hem momentum hem de ölçeklendirilmiş gradyan bilgisini bir arada kullanarak hızlı ve dengeli bir öğrenme sağlar(Z. Zhang, 2018). RMSProp, özellikle gürültülü ve değişken gradyanlara sahip veri setlerinde daha stabil güncellemeler üreterek kararsızlıkları azaltır(Zaheer & Shaziya, 2019). AdamW ise klasik Adam algoritmasının L2 düzenleme üzerindeki hatalı ağırlık çürütmesi etkisini düzelterek daha tutarlı bir genelleme performansı sunar(Reyad ve ark., 2023).Bu algoritmalar, farklı hiperparametre kombinasyonları ile birlikte denenmiş ve EO tarafından belirlenen en uygun parametrelerle eğitime dahil edilmiştir. Böylece modelin hem daha hızlı eğitilmesi hem de daha yüksek doğruluk seviyelerine ulaşması hedeflenmiştir.

#### Sabit tutulan diğer hiperparametreler

Eğitim sürecinde kullanılan tüm hiperparametreler optimizasyon işlemine sokulmamıştır. Bunlardan bir kısmı önceki çalışmaları referans alarak(Ahammed ve ark., 2022; Anand ve ark., 2023; Çetin-Kaya, 2024; Hussain ve ark., 2019, 2019; Kassem ve ark., 2020; Kaya, 2024; Kaya & Çetin-Kaya, 2024; Rezaouana ve ark., 2020; Saeed ve ark., 2023; Salehi ve ark., 2023, 2023; Shaha & Pawar, 2018; Shanthi ve ark., 2020; Wu ve ark., 2019), bir kısmı da kendi deneysel gözlemlerimiz sonucunda sabit tutulmuştur. Bu sabit tutulan hiperparametreler Tablo 3.11’de sunulmuştur.

Tablo 3.11 Bu çalışmada sabit tutulan hiperparametreler

| Hiperparametre               | Değer                                       |
|------------------------------|---------------------------------------------|
| <i>Image Input Size</i>      | 224x224x3                                   |
| <i>Image Normalization</i>   | Her mimarinin kendine özgü                  |
| <i>Batch Size</i>            | 32                                          |
| <i>Epoch</i>                 | 100                                         |
| <i>Wamup Epoch</i>           | 10                                          |
| <i>FC Katman Özellikleri</i> | 2 Dense; 1 D (dense katmanlarının arasında) |
| <i>LR Minimum</i>            | 1e-7                                        |
| <i>Kayıp Fonksiyonu</i>      | Categorical Crossentropy                    |


### 3.6. Performans Metrikleri

Derin öğrenme modellerinin sınıflandırma başarılarını değerlendirmek için çeşitli performans metrikleri kullanılabilir. Bu metriklerden bazıları: doğruluk, kesinlik, duyarlılık, F1 skoru ve benzeri değerlerdir. Bu değerler modelin tahminlerinin özetlendiği karışıklık matrisi üzerinden türetilir. Yani bu matris derin öğrenme modellerinin performanslarının değerlendirilmesinde temel ve öncü bir araçtır(Heydarian ve ark., 2022; Sathyanarayanan, 2024).

Bu çalışmada kullanılan performans metrikleri: Doğruluk (Accuracy), Dengeli Doğruluk (Balanced Accuracy (BA)), Kesinlik (Precision), Duyarlılık (Recall), F1-Skoru ve ROC-AUC Skoru'dur.

#### 3.6.1. Karışıklık matrisi

Derin öğrenme modellerinin sınıflandırma başarısını değerlendirmek için kullanılan tüm metriklerin temelinde Karışıklık Matrisi bulunur. Bu matris, modelin yaptığı tahminleri dört ayrı kategoriye ayırarak sınıflandırma sürecinin hem güçlü hem de zayıf yönlerini görünür kılar: Doğru Pozitif (TP), Yanlış Pozitif (FP), Doğru Negatif (TN) ve Yanlış Negatif (FN). Böylelikle modelin hangi sınıfı doğru tanıdığı, hangisini karıştırdığı ve hangi örnekleri gözden kaçırdığı açık bir biçimde ortaya çıkar. Bu yapı, tıpkı bir pusula gibi, sonraki tüm performans metriklerinin yönünü belirler(Krstinić ve ark., 2020).



Şekil 3.6 Bu çalışmada elde edilen bir karışıklık matrisi

### 3.6.2. Accuracy & balanced accuracy (BA)

Accuracy, modelin genel olarak ne kadar doğru tahmin yaptığını ifade eder. TP ve TN toplamının, tüm örnekler oranı şeklinde hesaplanır. Ancak sınıf dengesizliği yüksek veri setlerinde, özellikle tıbbi görüntüleme çalışmalarında accuracy tek başına anlamlı değildir; çünkü azınlık sınıfındaki hataları örtebilir. BA ise, her sınıfın doğruluk oranını ayrı ayrı hesaba katarak sınıf dengesizliğinin etkisini azaltır. Böylece her sınıfın modele eşit ağırlıkla katkı sağlaması hedeflenir. ISIC gibi dengesiz veri setlerinde daha adil bir performans değerlendirmesi sunar (Fernando & Tsokos, 2022; Johnson & Khoshgoftaar, 2019).

### 3.6.3. Precision

Precision, modelin "pozitif" dediği örneklerde ne kadar isabetli olduğunu ölçer. Pozitif tahminlerin ne kadarının gerçekten pozitif olduğunu gösterir. Yanlış pozitiflerin azaltılması istenen klinik uygulamalarda önemli bir metriktir (Wu ve ark., 2019).

#### **3.6.4. Recall**


Recall, gerçek pozitiflerin ne kadarının model tarafından yakalanabildiğini gösterir(Johnson & Khoshgoftaar, 2019). Özellikle melanoma gibi kritik sınıflarda kaçırılan her pozitif bir risk anlamına geldiğinden, recall klinik uygulamalar için hayati bir metriktir.

#### **3.6.5. F1-Skoru**

F1-Skoru, precision ve recall'un harmonik ortalamasıdır. Bu iki metriğin dengesini sağlar, özellikle precision yüksek ama recall düşük olduğunda ya da tam tersi bir durumda daha adil bir değerlendirme sunar(Yacoubby & Axman, 2020). Medikal görüntülerle hastalık teşhisi yapılan bu çalışmada, F1-Skoru (Macro) temel başarı göstergesi olarak tercih edilmiştir. Çünkü burada önemli olan sadece modelin doğru tahminlerde bulunması değildir. Yanlışın ağırlığı çok daha etkindir. Bir hastayı sağlıklı diye sınıflandırmak, gerçekte hastalığı gözden kaçırmak anlamına gelir. Ve sırf bu yüzden hastanın hayatını kaybetmesi ile sonuçlanabilir. Aynı şekilde sağlıklı bir bireyi hatalı biçimde hasta olarak işaretlemek de gereksiz kaygı ve ek incelemelere yol açar. F1-Skoru, bu iki uç arasında adil bir denge kurarak modelin gerçek performansını ortaya çıkarır. Bu nedenle, bu tez kapsamında geliştirilen CNN yapılarının değerlendirilmesinde F1-Skoru, karar verici bir unsur olarak kullanılmış ve modelin klinik açıdan başarısını temsil eden en güvenilir ölçüt olarak konumlandırılmıştır.

#### **3.6.6. ROC-AUC skoru**

ROC-AUC, modelin pozitif ve negatif sınıfları ayırt etme kapasitesini ölçer. AUC değeri 1'e yaklaştıkça modelin ayırıştırma başarısı artar. Sınıf dağılımından göreceli olarak daha az etkilenen, güçlü bir genel performans göstergesidir(Haenssle ve ark., 2018; Jaskowiak ve ark., 2022; Kanavati ve ark., 2020).



Şekil 3.7 ROC-AUC eğrisi(Jaskowiak ve ark., 2022)

### 3.7. Materyal

Kullanılan materyaller arasında yazılım üretme editörü, programlama dili ve gerekli kütüphaneleri yönetmek ve ortam kontrolünü sağlamak amacıyla Anaconda(“Anaconda (Python dağıtımı)”, 2024) uygulaması kullanılmıştır. Yazılım geliştirmede Spyder editörü tercih edilmiştir. Bu editör Anaconda uygulamasının içerisinde kullanılabilir ve yönetilebilirdir(“Spyder (Software)”, 2025). Çalışmada programlama dili olarak Python tercih edilmiştir. Python nesne yönelimli, modüler etkileşimli yüksek seviye bir programlama dilidir(“Python”, 2025). Derin öğrenme uygulamalarında Python ile sıkça kullanılan TensorFlow kütüphanesi açık kaynaklı ve ücretsiz bir yapay zeka geliştirme ortamıdır(“TensorFlow”, 2025).

### 3.8. Deneysel Araçlar

Çalışmada programlama dili olarak Python 3.9.23 sürümü kullanılmıştır. Derin öğrenme modelleri TensorFlow 2.10.0 kütüphanesi kullanılarak çağrılmış ve oluşturulmuştur. Model eğitimleri NVIDIA Geforce RTX 3060 GPU (12 GB VRAM) ile yerel ortamda gerçekleştirilmiştir.

## 4. BULGULAR VE TARTIŞMA

### 4.1. Transfer Öğrenme ile Eğitim Sonuçları

Transfer öğrenme kullanımının ilk aşamasında deneysel çalışmalar yapılmış ve bu çalışmalar sonucunda aşağıdaki bulgular elde edilmiştir:

- Ağırlıkların rastgele olarak başlatılması modelin kısa ve orta vadeli eğitiminde imagenet ağırlıklarının kullanılmasına göre olumsuz sonuçlar vermiştir.
- Dropout oranı sezgisel olarak 0.7 olacak şekilde başlatılmış, lakin hiperparametre seti oluşturulurken bu değerin çok büyük olduğu farkedilmiş ve hiperparametre kümesine eklenmemiştir.
- BatchNormalization katmanlarının tekrardan eğitilmesinin eğitim performansını ciddi oranda düşürdüğü gözlemlenmiş bu sebeple bu katmanlar ince ayar bölümünde dondurulmuştur.

Bu bulgular neticesinde tüm mimarilerde aynı hiperparametre değerleri ve eğitim yöntemleri kullanılmıştır.

3 farklı eğitim seti (DAVS-A, DAVS-B, DAVS-C) ile eğitilen 5 farklı mimarinin (DenseNet201, MobileNetV3Large, Inception-ResNetV2, EfficientNetV2S ve EfficientNetV2B3) Bölüm 3.3.2’de bahsedilen test seti ile yapılan değerlendirme sonuçları Tablo 4.1’de sunulmuştur. Elde edilen bulgular neticesinde tüm mimarilerde veri seti boyutu büyüdükçe BA’nın ve F1 skorun arttığı açıkça görülmektedir. Dolayısı ile en başarılı mimariler her zaman DAVS-C veri seti ile eğitilen mimariler olmuştur. Tüm bu eğitilen mimariler arasında en yüksek F1 Skora ulaşan hem hafif hem kararlı yapısı ile EfficientNetV2S modeli olmuştur. Bu mimarinin elde ettiği F1 skor ise tabloda kırmızı renk ile vurgulanmış ve 0.776 değerindedir.

Tablo 4.1 Transfer öğrenmede kullanılan mimarilerin değerlendirme sonuçları

| Mimari                    | DAVS-A  |       | DAVS-B  |       | DAVS-C  |       |
|---------------------------|---------|-------|---------|-------|---------|-------|
|                           | F1 Skor | BA    | F1 Skor | BA    | F1 Skor | BA    |
| <b>DenseNet201</b>        | 0.661   | 0.682 | 0.724   | 0.721 | 0.743   | 0.735 |
| <b>MobileNetV3Large</b>   | 0.626   | 0.649 | 0.708   | 0.697 | 0.727   | 0.717 |
| <b>Inception-ResNetV2</b> | 0.674   | 0.689 | 0.720   | 0.729 | 0.759   | 0.757 |
| <b>EfficientNetV2S</b>    | 0.686   | 0.698 | 0.764   | 0.767 | 0.776   | 0.772 |
| <b>EfficientNetV2B3</b>   | 0.685   | 0.703 | 0.762   | 0.765 | 0.773   | 0.765 |

## 4.2. Seçilen Temel Mimari ve Değerlendirme Sonuçları

### 4.2.1. Mimari/model bilgileri

Bölüm 4.1’de bahsedildiği üzere DAVS-A, DAVS-B ve DAVS-C ile ayrı ayrı eğitilerek aynı test seti üzerinde değerlendirilen mimarilerden en başarılı olan modelin EfficientV2S olduğu tespit edildi. Bu modele ait ayrıntılı bilgiler Tablo 4.2’de sunulmuştur.

Tablo 4.2 Seçilen temel modelin bilgileri

| Detay                           | Değer         |
|---------------------------------|---------------|
| <i>Parametre Sayısı</i>         | 21.7 Milyon   |
| <i>Aktivasyon Fonksiyonları</i> | GELU; Softmax |
| <i>Optimizasyon Algoritması</i> | Adam          |
| <i>Öğrenme Oranı</i>            | 1e-4          |
| <i>FC Boyutu</i>                | 2             |

Tablo 4.3 (Devam) Seçilen temel modelin bilgileri

| <b>Detay</b>                     | <b>Değer</b>                      |
|----------------------------------|-----------------------------------|
| <i>FC Nöron Sayıları</i>         | 1024; 8                           |
| <i>D Oranı</i>                   | 0.7                               |
| <i>Yığın Boyutu (Batch Size)</i> | 32                                |
| <i>Görüntü Girdi Boyutu</i>      | 224x224x3                         |
| <i>Epoch</i>                     | 100                               |
| <i>Eğitim Seti</i>               | DAVS-C                            |
| <i>Doğrulama Seti</i>            | Tablo 3.5’te bahsedilen Test Seti |
| <i>Test Seti</i>                 | Tablo 3.5’te bahsedilen Test Seti |
| <i>Eğitim Süresi (sa:dk:sn)</i>  | 01:33:09                          |

#### 4.2.2. Değerlendirme sonuçları


Seçilen temel modelin test seti ile değerlendirme sonuçlarına ait bilgiler Tablo 4.4’de sunulmuştur.

Tablo 4.4 Seçilen temel modelin değerlendirme sonuçları

| <b>Sonuç</b>                    | <b>Değer</b>                      |
|---------------------------------|-----------------------------------|
| <i>Eğitim Seti</i>              | DAVS-C                            |
| <i>Doğrulama Seti</i>           | Tablo 3.5’te bahsedilen Test Seti |
| <i>Test Seti</i>                | Tablo 3.5’te bahsedilen Test Seti |
| <i>Eğitim Süresi (sa:dk:sn)</i> | 01:33:09                          |
| <i>Loss</i>                     | 1.253                             |
| <i>Accuracy</i>                 | 0.755                             |
| <i>Balanced Accuracy</i>        | 0.772                             |
| <i>Precision Score</i>          | 0.785                             |
| <i>Recall Score</i>             | 0.772                             |
| <i>Macro F1 Score</i>           | 0.776                             |
| <i>ROC-AUC Score</i>            | 0.868                             |

### Doğruluk ve kayıp grafikleri


İlgili modelin eğitim-doğrulama doğruluk ve kayıp grafikleri Şekil 4.1’de sunulmuştur.



Şekil 4.1 Seçilen temel modelin eğitim-doğrulama doğruluk ve kayıp grafikleri

### Karışıklık matrisi

İlgili modelin test seti sonuçları ile oluşturulan karışıklık matrisi Şekil 4.2’de sunulmuştur.



Şekil 4.2 Seçilen temel modelin karışıklık matrisi

### 4.3. Seçilen Mimarinin Dikkat Mekanizmaları İle Güçlendirilmesi

Dikkat mekanizmalarıyla güçlendirilmiş modellerin performansları incelendiğinde, bazı yapıların temel mimariden daha yüksek, bazılarının ise daha düşük sonuçlar ürettiği gözlemlenmiştir. Temel mimaride GAP katmanından önce konumlandırılan farklı dikkat mekanizmalarıyla oluşturulan yeni yapıların eğitiminin ardından yapılan test sonuçları Tablo 4.5’te sunulmuştur.

Tablo 4.5 Çeşitli dikkat mekanizmaları ile güçlendirilmiş modellerin sonuçları

| Model No. | Kullanılan Dikkat Mekanizması | F1 Skor |
|-----------|-------------------------------|---------|
| 1         | SE + Spatial                  | 0.778   |
| 2         | SE                            | 0.775   |
| 3         | Spatial                       | 0.770   |
| 4         | CBAM                          | 0.766   |
| 5         | BAM                           | 0.765   |

Tablo 4.5’te görüldüğü üzere farklı dikkat yapılarının ürettiği farklı sonuçlar, elde edilen performansın yalnızca eklenen dikkat bloğuna değil, aynı zamanda diğer hiperparametre ayarlarına da duyarlı olduğunu göstermektedir. Bu nedenle, dikkat mekanizması seçiminin de hiperparametre optimizasyonu kapsamında EO algoritması tarafından belirlenmesine karar verilmiştir.

Örneğin, temel mimariye SE bloğunun eklenmesiyle elde edilen model 0.778 F1 skoru elde etmiş ve temel mimarinin üzerinde bir performans sergilemiştir. Ancak hiperparametrelerin farklı kombinasyonlarında bu değerin artabileceği veya azalabileceği, hatta diğer dikkat mekanizmalarının uygun ayarlarla çok daha yüksek performanslara ulaşabileceği öngörülmektedir. EO algoritmasının kullanılması da tam olarak bu gerekçeye dayanmaktadır. Bu gerekçe model performansının dikkat mekanizması ve hiperparametre etkileşimi çerçevesinde bütüncül olarak optimize edilmesidir.

#### 4.4. EO Algoritması ile Hiperparametre Optimizasyonu Sonuçları

EO algoritmasıyla gerçekleştirilen hiperparametre optimizasyonu sürecinin ardından elde edilen en iyi beş model Tablo 4.6’da ve bu modellere ait performans metrikleri Tablo 4.7’de sunulmuştur. Bu sonuçlar, yalnızca dikkat mekanizması-hiperparametre etkileşiminin karmaşıklığını ortaya koymakla kalmamış, aynı zamanda EO algoritmasının hiperparametre kümesinde etkili bir şekilde gezinerek yüksek performanslı çözümler üretebildiğini de göstermiştir.

Tablo 4.6 EO ile bulunan en iyi ilk 5 modelin özellikleri

| Ajan No. | LR Baş. | LR D. K. | LR D. S. | D    | L2   | Akt. F. | FC N. S. | Dik. Mek. | Opt. Alg. |
|----------|---------|----------|----------|------|------|---------|----------|-----------|-----------|
| 53       | 1e-4    | 0.5      | 4        | 0.6  | 0.5  | LReLU   | 256      | CBAM      | AdamW     |
| 31       | 1e-4    | 0.5      | 3        | 0.55 | 0.5  | Swish   | 96       | Spatial   | AdamW     |
| 13       | 1e-4    | 0.5      | 3        | 0.55 | 0.25 | Swish   | 128      | Spatial   | AdamW     |
| 8        | 1e-4    | 0.5      | 3        | 0.6  | 0.5  | Swish   | 128      | CBAM      | AdamW     |
| 3        | 1e-4    | 0.5      | 3        | 0.5  | 0.05 | ReLU    | 96       | Spatial   | RMSProp   |

LR Baş.: LR Başlangıcı, LR D.K.: LR Düşüş Katsayısı, LR D.S.: LR Değişim Sabrı, Akt. F.: Aktivasyon Fonksiyonu


FC N.S.: FC Nöron Sayısı, Dik. Mek.: Dikkat Mekanizması, Opt. Alg.: Optimizasyon Algoritması, LReLU: Leaky ReLU

Tablo 4.7 EO ile bulunan en iyi ilk 5 modelin performans metrikleri


| Model No. | Accuracy | Balanced Accuracy | Precision | Recall | F1 Skor | ROC-AUC Skor |
|-----------|----------|-------------------|-----------|--------|---------|--------------|
| 53        | 0.757    | 0.774             | 0.791     | 0.774  | 0.782   | 0.869        |
| 31        | 0.746    | 0.767             | 0.782     | 0.767  | 0.771   | 0.865        |
| 13        | 0.740    | 0.753             | 0.779     | 0.753  | 0.765   | 0.857        |
| 8         | 0.735    | 0.753             | 0.763     | 0.753  | 0.757   | 0.857        |
| 3         | 0.736    | 0.748             | 0.769     | 0.748  | 0.756   | 0.855        |

Elde edilen 53. numaralı modelin daha önce manuel ayarlamalar veya sınırlı arama yöntemleriyle ulaşılan en yüksek F1 skorunun da üzerine çıkması, EO algoritmasının hiperparametre optimizasyonunda sağladığı katkıyı açık biçimde doğrulamaktadır. Bu durum, EO'nun yalnızca yerel en iyilere sıkışmadan daha geniş bir arama alanını tarayabildiğini, dolayısıyla model performansını doğrudan etkileyen çok boyutlu hiperparametre kombinasyonlarını daha verimli biçimde keşfedebildiğini göstermektedir.

Ayrıca optimizasyon sürecinin zamansal gelişimi, yani ajanların çözüm uzayı içerisindeki hareketleri ve uyum sağlama davranışları, hem global en iyi ajan hem de lokal en iyi ajanların performans eğrileri incelenerek değerlendirilmiştir. Bu kapsamda elde edilen görseller Şekil 4.3 ve Şekil 4.4'te verilmiştir. Söz konusu şekiller, ajanların iterasyonlar boyunca çözüm kalitesini nasıl yükselttiğini ve sonuç olarak optimizasyon sürecinin kararlılığını açıkça ortaya koymaktadır.



Şekil 4.3 Global en iyi ajan performans grafiği




Şekil 4.4 Lokal en iyi ajan performans grafiği

Bu bulgular bir arada değerlendirildiğinde, EO algoritmasının CNN tabanlı deri hastalığı sınıflandırma probleminde hiperparametre optimizasyonu için uygun, başarılı ve etkili bir yöntem olduğu sonucuna varılabilir.

#### 4.4.1. Elde edilen en iyi modelin değerlendirme sonuçları

##### Doğruluk ve kayıp grafikleri


Elde edilen en iyi modelin eğitim-doğrulama doğruluk ve kayıp grafikleri Şekil 4.5'te sunulmuştur.



Şekil 4.5 En iyi modelin eğitim-doğrulama doğruluk ve kayıp grafikleri

## Karışıklık matrisi

Elde edilen en iyi modelin test seti sonuçları ile oluşturulan karışıklık matrisi Şekil 4.6’da sunulmuştur.



Şekil 4.6 En iyi modelin karışıklık matrisi

## 4.5. Elde Edilen En İyi Modelin Büyük Veri Setleri ile Eğitilmesi

EO algoritması ile elde edilen en iyi modelin sınıf başına daha fazla görüntü içeren birbirinden farklı 2 veri seti ile eğitimleri ve testleri tamamlanmış ve yapılan gözlem sonuçları alt bölümlerde belirtilmiştir.






### 4.5.1. DAVS-D eğitim ve değerlendirme sonuçları

Bölüm 4.4’te belirtilen, elde edilen en iyi model, DAVS-D ile eğitilmiş ve eğitim-test sonuçları Tablo 4.8’de sunulmuştur.

Tablo 4.8 En iyi modelin DAVS-D ile değerlendirme sonuçları

| Sonuç                           | Değer    |
|---------------------------------|----------|
| <i>Eğitim Seti</i>              | DAVS-D   |
| <i>Doğrulama Seti</i>           | DAVS-D   |
| <i>Test Seti</i>                | DAVS-D   |
| <i>Eğitim Süresi (sa:dk:sn)</i> | 04:13:41 |
| <i>Loss</i>                     | 0.556    |
| <i>Accuracy</i>                 | 0.909    |
| <i>Balanced Accuracy</i>        | 0.909    |
| <i>Precision Score</i>          | 0.909    |
| <i>Recall Score</i>             | 0.909    |
| <i>Macro F1 Score</i>           | 0.909    |
| <i>ROC-AUC Score</i>            | 0.948    |

Elde edilen sonuçlar incelendiğinde, modelin başarısında ciddi bir artış görülmektedir. Lakin daha önce de belirtildiği gibi bu artışın sebebi, veri setinde uygulanan veri artırma yönteminin hatalı yapılmasından kaynaklı olup, modelin hastalık teşhisi yerine görüntü tanıma işlemini başarılı şekilde yapmasıdır. Özetle model eğitim setinde ezberlediği görüntülerin veri artırma yöntemi ile elde edilen benzer kopyalarını test setinde tekrardan tanıyarak yüksek performans sergilemiştir.


|                    | AK                                                                                                              | DF                                                                                                               | SCC                                                                                                               | VASC                                                                                                               |
|--------------------|-----------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------|
| <b>Eğitim Seti</b> | <br>ISIC_0071020.jpg         | <br>ISIC_0060809.jpg          | <br>ISIC_0064094.jpg          | <br>ISIC_0066446.jpg          |
| <b>Test Seti</b>   | <br>aug_792_ISIC_0071020.jpg | <br>aug_1118_ISIC_0060809.jpg | <br>aug_1688_ISIC_0064094.jpg | <br>aug_1975_ISIC_0066446.jpg |

Şekil 4.7 DAVS-D eğitim ve test setinden örnekler

Şekil 4.7’de de görüldüğü üzere birbirinin kopyası denebilecek benzerlikte görüntüler hem eğitim hem test setinde bulunmaktadır. Bu yüzden veri setlerindeki eğitim ve test ayrıştırılması veri artırmadan önce yapılmalı ve veri artırma yöntemi yalnızca eğitim seti üzerinde uygulanmalıdır.

### Doğruluk ve kayıp grafikleri


En iyi modelin DAVS-D ile eğitim-doğrulama doğruluk ve kayıp grafikleri Şekil 4.8’de sunulmuştur.



Şekil 4.8 En iyi modelin DAVS-D ile eğitim-doğrulama doğruluk ve kayıp grafikleri

### Karışıklık matrisi

En iyi modelin DAVS-D test seti sonuçları ile oluşturulan karışıklık matrisi Şekil 4.9’da sunulmuştur.



Şekil 4.9 En iyi modelin DAVS-D test seti ile oluşturulan karışıklık matrisi

#### 4.5.2. DAVS-E eğitim ve değerlendirme sonuçları

Bölüm 4.4’te belirtilen, elde edilen en iyi model, DAVS-E ile eğitilmiş ve eğitim-test sonuçları Tablo 4.9’da sunulmuştur.

Tablo 4.9 En iyi modelin DAVS-E ile değerlendirme sonuçları


| Sonuç                           | Değer    |
|---------------------------------|----------|
| <i>Eğitim Seti</i>              | DAVS-E   |
| <i>Doğrulama Seti</i>           | DAVS-E   |
| <i>Test Seti</i>                | DAVS-E   |
| <i>Eğitim Süresi (sa:dk:sn)</i> | 03:31:23 |
| <i>Loss</i>                     | 1.059    |
| <i>Accuracy</i>                 | 0.819    |
| <i>Balanced Accuracy</i>        | 0.808    |
| <i>Precision Score</i>          | 0.835    |
| <i>Recall Score</i>             | 0.808    |
| <i>Macro F1 Score</i>           | 0.820    |
| <i>ROC-AUC Score</i>            | 0.890    |

Eğitim ve test bulguları incelendiğinde veri seti boyutunun ve veri artırma tekniklerinin doğru kullanımının modelin başarısına doğrudan etki ettiği açıkça görülmektedir. Ayrıca veri seti boyutunun modelin başarısı ile doğru orantıda olduğu açıkça gözlemlenebilir.

Sonuç olarak elde edilen modelin daha kapsamlı bir verisetiyle eğitilmesi, modelin başarı oranını olumlu yönde etkileyip gelecekteki çalışmalar için veri seti boyutunun önemini vurgulamakta ve bu boyutun veri artırma yöntemleri ile artırılabilmesinin mümkün olduğunu göstermiştir.

#### Doğruluk ve kayıp grafikleri


En iyi modelin DAVS-E ile eğitim-doğrulama doğruluk ve kayıp grafikleri Şekil 4.10'da sunulmuştur.



Şekil 4.10 En iyi modelin DAVS-E ile eğitim-doğrulama doğruluk ve kayıp grafikleri

### Karışıklık matrisi

En iyi modelin DAVS-E test seti sonuçları ile oluşturulan karışıklık matrisi Şekil 4.11’de sunulmuştur.



Şekil 4.11 En iyi modelin DAVS-E test seti ile oluşturulan karışıklık matrisi

## 5. SONUÇ

Günümüzde tıbbi görüntüleme teknolojilerinin gelişmesiyle birlikte, otomatik tanı sistemlerine duyulan ihtiyaç giderek artmaktadır. Özellikle cilt kanseri gibi erken teşhisin hayati önem taşıdığı hastalıklarda, doğru ve hızlı sınıflandırma yapabilen derin öğrenme modelleri, klinik süreçleri hem destekleyici hem de hızlandırıcı bir potansiyele sahiptir. Ancak cilt lezyonu veri setlerinin sınıf dağılımlarının dengesiz olması, görüntü çeşitliliğinin yetersizliği ve aşırı öğrenme eğilimi gibi problemler, bu tür modellerin güvenilir şekilde eğitilmesini zorlaştırmaktadır. Bu nedenle veri artırma stratejilerinin, doğru mimari seçiminin ve optimize edilmiş hiperparametrelerin model performansı üzerindeki etkisinin dikkatle incelenmesi gerekmektedir.

Bu tez çalışmasında, ISIC 2019 veri seti temel alınarak cilt lezyonlarının sınıflandırılması problemi ele alınmıştır. İlk aşamada veri seti dengeli hâle getirilmiş, her sınıf için belirli sayıda görüntü seçilerek alt veri setleri oluşturulmuştur. Ardından veri artırmanın ayrıştırma işleminden önce ve sonra uygulanmasının model performansı üzerindeki etkisini değerlendirmek amacıyla DAVS-D ve DAVS-E isimli yeni birer alt veri setleri oluşturulmuştur. Bu süreçte sınıflar tamamen rastgele seçilerek en fazla 3 000 görüntü içerecek şekilde ayrıştırılmış, ardından belirli kurallar çerçevesinde data augmentation uygulanarak tüm sınıflarda 3 000 görüntü olacak biçimde dengeleme yapılmıştır. Böylece veri artırma stratejisinin eğitim-test ayrımı öncesi ve sonrası uygulanmasının performansa etkisi kapsamlı biçimde incelenmiştir.

Çalışma boyunca çeşitli derin öğrenme mimarileri, tam bağlı katman yapıları ve dikkat mekanizmaları değerlendirilmiş; aynı zamanda öğrenme oranı, düzenleştirme katsayıları, optimizasyon algoritmaları ve katman derinliği gibi hiperparametreler optimize edilmiştir. Elde edilen sonuçlar, doğru veri ön işleme stratejileri ile desteklenen optimize edilmiş modellerin, sınıf dengesizliği ve aşırı öğrenme gibi problemlere karşı daha dayanıklı hâle geldiğini göstermiştir. Özellikle optimizasyon algoritmalarının ve öğrenme oranı planlamasının sınıflandırma başarısı üzerinde belirleyici bir etkiye sahip olduğu görülmüştür.

Yapılan deneyler sonucunda, optimize edilen model belirli senaryolarda yüksek doğruluk, yüksek F1 skor ve dengeli sınıflandırma performansları sergilemiştir. Veri artırma işleminin ayrıştırmadan önce uygulanmasının aşırı öğrenmeyi azalttığı ve modelin genelleme kabiliyetini artırdığı gözlemlenmiştir. Ayrıca BA ve Macro F1 skorları üzerinden yapılan değerlendirmeler, modelin özellikle az örnekli sınıflarda daha istikrarlı sonuçlar üretebildiğini ortaya koymuştur.

Gelecek çalışmalar kapsamında, daha geniş ve yüksek çözünürlüklü veri setlerinin kullanılması, farklı dikkat mekanizmalarının entegrasyonu, hibrit mimarilerin denenmesi ve modelin gerçek zamanlı klinik sistemlere uyarlanması önerilmektedir. Bunun yanında, açıklanabilir yapay zekâ yöntemlerinin daha kapsamlı biçimde kullanılması, model kararlarının klinisyenler tarafından daha şeffaf şekilde değerlendirilebilmesine katkı sağlayacaktır. Bu yönde yapılacak çalışmalar, cilt lezyonu tanı süreçlerinde yapay zekâ tabanlı sistemlerin daha güvenilir, erişilebilir ve etkili bir araç hâline gelmesine yardımcı olabilir.

## 6. KAYNAKÇA

- Abunadi, I., & Senan, E. M. (2021). Deep Learning and Machine Learning Techniques of Diagnosis Dermoscopy Images for Early Detection of Skin Diseases. *Electronics*, 10(24), 3158. <https://doi.org/10.3390/electronics10243158>
- Agarap, A. F. (2019). *Deep Learning using Rectified Linear Units (ReLU)* (No. arXiv:1803.08375). arXiv. <https://doi.org/10.48550/arXiv.1803.08375>
- Ahammed, M., Al Mamun, M., & Uddin, M. S. (2022). A machine learning approach for skin disease detection and classification using image segmentation. *Healthcare Analytics*, 2, 100122. <https://doi.org/10.1016/j.health.2022.100122>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Anaconda (Python dağıtımı). (2024). İçinde *Wikipedi*. [https://tr.wikipedia.org/w/index.php?title=Anaconda\\_\(Python\\_da%C4%9F%C4%B1t%C4%B1m%C4%B1\)&oldid=33993201](https://tr.wikipedia.org/w/index.php?title=Anaconda_(Python_da%C4%9F%C4%B1t%C4%B1m%C4%B1)&oldid=33993201)
- Anand, V., Gupta, S., Koundal, D., & Singh, K. (2023). Fusion of U-Net and CNN model for segmentation and classification of skin lesion from dermoscopy images. *Expert Systems with Applications*, 213, 119230. <https://doi.org/10.1016/j.eswa.2022.119230>
- Basha, S. S., Dubey, S. R., Pulabaigari, V., & Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112-119. <https://doi.org/10.1016/j.neucom.2019.10.008>
- Chen, L., Zhang, H., Xiao, J., Nie, L., Shao, J., Liu, W., & Chua, T.-S. (2017). Sca-cnn: Spatial and channel-wise attention in convolutional networks for image captioning. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 5659-5667. [http://openaccess.thecvf.com/content\\_cvpr\\_2017/html/Chen\\_SCA-CNN\\_Spatial\\_and\\_CVPR\\_2017\\_paper.html](http://openaccess.thecvf.com/content_cvpr_2017/html/Chen_SCA-CNN_Spatial_and_CVPR_2017_paper.html)
- Çetin-Kaya, Y. (2024). Equilibrium Optimization-Based Ensemble CNN Framework for Breast Cancer Multiclass Classification Using Histopathological Image. *Diagnostics*, 14(19), 2253. <https://doi.org/10.3390/diagnostics14192253>
- Diab, A. G., Fayez, N., & El-Seddek, M. M. (2022). Accurate skin cancer diagnosis based on convolutional neural networks. *Indonesian Journal of Electrical Engineering and Computer Science*. <https://doi.org/10.11591/IJEECS.V25.I3.PP1429-1441>
- Faramarzi, A., Heidarinejad, M., Stephens, B., & Mirjalili, S. (2020). Equilibrium optimizer: A novel optimization algorithm. *Knowledge-based systems*, 191, 105190. <https://doi.org/10.1016/j.knosys.2019.105190>
- Fernando, K. R. M., & Tsokos, C. P. (2022). Dynamically Weighted Balanced Loss: Class Imbalanced Learning and Confidence Calibration of Deep Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 33(7), 2940-2951. <https://doi.org/10.1109/TNNLS.2020.3047335>

- Garbin, C., Zhu, X., & Marques, O. (2020). Dropout vs. batch normalization: An empirical study of their impact to deep learning. *Multimedia Tools and Applications*, 79(19), 12777-12815. <https://doi.org/10.1007/s11042-019-08453-9>
- Ghazouani, H. (2025). Multi-residual attention network for skin lesion classification. *Biomedical Signal Processing and Control*, 103, 107449. <https://doi.org/10.1016/j.bspc.2024.107449>
- Gholamalinezhad, H., & Khosravi, H. (2020). *Pooling Methods in Deep Neural Networks, a Review* (No. arXiv:2009.07485). arXiv. <https://doi.org/10.48550/arXiv.2009.07485>
- Gupta, J., Pathak, S., & Kumar, G. (2022). Deep learning (CNN) and transfer learning: A review. *Journal of Physics: Conference Series*, 2273(1), 012029. <https://iopscience.iop.org/article/10.1088/1742-6596/2273/1/012029/meta>
- Haenssle, H. A., Fink, C., Schneiderbauer, R., Toberer, F., Buhl, T., Blum, A., Kalloo, A., Hassen, A. B. H., Thomas, L., Enk, A., Uhlmann, L., Alt, C., Arenbergerova, M., Bakos, R., Baltzer, A., Bertlich, I., Blum, A., Bokor-Billmann, T., Bowling, J., ... Zalaudek, I. (2018). Man against machine: Diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Annals of Oncology*, 29(8), 1836-1842. <https://doi.org/10.1093/annonc/mdy166>
- Hamet, P., & Tremblay, J. (2017). Artificial intelligence in medicine. *metabolism*, 69, S36-S40. <https://doi.org/10.1016/j.metabol.2017.01.011>
- Hao, W., Yizhou, W., Yaqin, L., & Zhili, S. (2020). The role of activation function in CNN. *2020 2nd international conference on information technology and computer application (ITCA)*, 429-432. <https://doi.org/10.1109/ITCA52113.2020.00096>
- Heydarian, M., Doyle, T. E., & Samavi, R. (2022). MLCM: Multi-Label Confusion Matrix. *IEEE Access*, 10, 19083-19095. <https://doi.org/10.1109/ACCESS.2022.3151048>
- Hoang, L., Lee, S.-H., Lee, E.-J., & Kwon, K.-R. (2022). Multiclass Skin Lesion Classification Using a Novel Lightweight Deep Learning Framework for Smart Healthcare. *Applied Sciences*, 12(5), 2677. <https://doi.org/10.3390/app12052677>
- Hossain, M. A., & Sajib, M. S. A. (2019). Classification of image using convolutional neural network (CNN). *Global Journal of Computer Science and Technology*, 19(2), 13-14.
- Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 7132-7141. [http://openaccess.thecvf.com/content\\_cvpr\\_2018/html/Hu\\_Squeeze-and-Excitation\\_Networks\\_CVPR\\_2018\\_paper.html](http://openaccess.thecvf.com/content_cvpr_2018/html/Hu_Squeeze-and-Excitation_Networks_CVPR_2018_paper.html)
- Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2017). *Densely Connected Convolutional Networks*. 4700-4708. [https://openaccess.thecvf.com/content\\_cvpr\\_2017/html/Huang\\_Densely\\_Connected\\_Convolutional\\_CVPR\\_2017\\_paper.html](https://openaccess.thecvf.com/content_cvpr_2017/html/Huang_Densely_Connected_Convolutional_CVPR_2017_paper.html)
- Hussain, M., Bird, J. J., & Faria, D. R. (2019). A Study on CNN Transfer Learning for Image Classification. İcinde A. Lotfi, H. Bouchachia, A. Gegov, C. Langensiepen, & M. McGinnity (Ed.), *Advances in Computational Intelligence Systems* (C. 840, ss. 191-202). Springer International Publishing. [https://doi.org/10.1007/978-3-319-97982-3\\_16](https://doi.org/10.1007/978-3-319-97982-3_16)

- Iman, M., Arabnia, H. R., & Rasheed, K. (2023). A Review of Deep Transfer Learning and Recent Advancements. *Technologies*, 11(2), 40. <https://doi.org/10.3390/technologies11020040>
- Jaskowiak, P. A., Costa, I. G., & Campello, R. J. G. B. (2022). The area under the ROC curve as a measure of clustering quality. *Data Mining and Knowledge Discovery*, 36(3), 1219-1245. <https://doi.org/10.1007/s10618-022-00829-0>
- Ji, Z., Wang, X., Liu, C., Wang, Z., Yuan, N., & Ganchev, I. (2024). EFAM-Net: A Multi-Class Skin Lesion Classification Model Utilizing Enhanced Feature Fusion and Attention Mechanisms. *IEEE Access*, 12, 143029-143041. <https://doi.org/10.1109/ACCESS.2024.3468612>
- Johnson, J. M., & Khoshgoftaar, T. M. (2019). Survey on deep learning with class imbalance. *Journal of Big Data*, 6(1), 27. <https://doi.org/10.1186/s40537-019-0192-5>
- Kalra, D. S., & Barkeshli, M. (2024). Why Warmup the Learning Rate? Underlying Mechanisms and Improvements. *Advances in Neural Information Processing Systems*, 37, 111760-111801. <https://doi.org/10.52202/079017-3549>
- Kanavati, F., Toyokawa, G., Momosaki, S., Rambeau, M., Kozuma, Y., Shoji, F., Yamazaki, K., Takeo, S., Iizuka, O., & Tsuneki, M. (2020). Weakly-supervised learning for lung carcinoma classification using deep learning. *Scientific Reports*, 10(1), 9297. <https://doi.org/10.1038/s41598-020-66333-x>
- Kassem, M. A., Hosny, K. M., & Fouad, M. M. (2020). Skin Lesions Classification Into Eight Classes for ISIC 2019 Using Deep Convolutional Neural Network and Transfer Learning. *IEEE Access*, 8, 114822-114832. <https://doi.org/10.1109/ACCESS.2020.3003890>
- Kaya, M. (2024). Feature fusion-based ensemble CNN learning optimization for automated detection of pediatric pneumonia. *Biomedical Signal Processing and Control*, 87, 105472. <https://doi.org/10.1016/j.bspc.2023.105472>
- Kaya, M., & Çetin-Kaya, Y. (2024). A novel deep learning architecture optimization for multiclass classification of Alzheimer's disease level. *IEEE Access*, 12, 46562-46581. <https://doi.org/10.1109/ACCESS.2024.3382947>
- Kim, K. G. (2016). Book Review: Deep Learning. *Healthcare Informatics Research*, 22(4), 351. <https://doi.org/10.4258/hir.2016.22.4.351>
- Krstinić, D., Braović, M., Šerić, L., & Božić-Štulić, D. (2020). Multi-label Classifier Performance Evaluation with Confusion Matrix. *Computer Science & Information Technology*, 01-14. <https://doi.org/10.5121/csit.2020.100801>
- Laarhoven, T. van. (2017). *L2 Regularization versus Batch and Weight Normalization* (No. arXiv:1706.05350). arXiv. <https://doi.org/10.48550/arXiv.1706.05350>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Lewkowycz, A., Bahri, Y., Dyer, E., Sohl-Dickstein, J., & Gur-Ari, G. (2020). *The large learning rate phase of deep learning: The catapult mechanism* (No. arXiv:2003.02218). arXiv. <https://doi.org/10.48550/arXiv.2003.02218>
- Li, J., Jin, K., Zhou, D., Kubota, N., & Ju, Z. (2020). Attention mechanism-based CNN for facial expression recognition. *Neurocomputing*, 411, 340-350. <https://doi.org/10.1016/j.neucom.2020.06.014>
- Li, Z., & Arora, S. (2019). *An Exponential Learning Rate Schedule for Deep Learning* (No. arXiv:1910.07454). arXiv. <https://doi.org/10.48550/arXiv.1910.07454>

- Liu, K., Kang, G., Zhang, N., & Hou, B. (2018). Breast cancer classification based on fully-connected layer first convolutional neural networks. *IEEE Access*, 6, 23722-23732. <https://doi.org/10.1109/ACCESS.2018.2817593>
- Moradi, R., Berangi, R., & Minaei, B. (2020). A survey of regularization strategies for deep models. *Artificial Intelligence Review*, 53(6), 3947-3986. <https://doi.org/10.1007/s10462-019-09784-7>
- Mridha, K., Uddin, Md. M., Shin, J., Khadka, S., & Mridha, M. F. (2023). An Interpretable Skin Cancer Classification Using Optimized Convolutional Neural Network for a Smart Healthcare System. *IEEE Access*, 11, 41003-41018. <https://doi.org/10.1109/ACCESS.2023.3269694>
- Naeem, A., & Anees, T. (2024). A Multiclassification Framework for Skin Cancer detection by the concatenation of Xception and ResNet101. *Journal of Computing & Biomedical Informatics*, 6(02), 205-227. <https://doi.org/10.56979/602/2024>
- Naveed, A., Naqvi, S. S., Khan, T. M., & Razzak, I. (2024). PCA: Progressive class-wise attention for skin lesions diagnosis. *Engineering Applications of Artificial Intelligence*, 127, 107417. <https://doi.org/10.1016/j.engappai.2023.107417>
- Nawaz, K., Zanib, A., Shabir, I., Li, J., Wang, Y., Mahmood, T., & Rehman, A. (2025). Skin cancer detection using dermoscopic images with convolutional neural network. *Scientific Reports*, 15(1), 7252. <https://doi.org/10.1038/s41598-025-91446-6>
- Nirthika, R., Manivannan, S., Ramanan, A., & Wang, R. (2022). Pooling in convolutional neural networks for medical image analysis: A survey and an empirical study. *Neural Computing and Applications*, 34(7), 5321-5347. <https://doi.org/10.1007/s00521-022-06953-8>
- Niu, Z., Zhong, G., & Yu, H. (2021). A review on the attention mechanism of deep learning. *Neurocomputing*, 452, 48-62. <https://doi.org/10.1016/j.neucom.2021.03.091>
- Park, J., Woo, S., Lee, J.-Y., & Kweon, I. S. (2018). *BAM: Bottleneck Attention Module* (No. arXiv:1807.06514). arXiv. <https://doi.org/10.48550/arXiv.1807.06514>
- Python. (2025). İçinde *Wikipedi*. <https://tr.wikipedia.org/w/index.php?title=Python&oldid=35681172>
- Qian, S., Ning, C., & Hu, Y. (2021). MobileNetV3 for Image Classification. *2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*, 490-497. <https://doi.org/10.1109/ICBAIE52039.2021.9389905>
- Raghavendra, P. V. S. P., Charitha, C., Begum, K. G., & Prasath, V. B. S. (2023). Deep Learning-Based Skin Lesion Multi-class Classification with Global Average Pooling Improvement. *Journal of Digital Imaging*, 36(5), 2227-2248. <https://doi.org/10.1007/s10278-023-00862-5>
- Rashid, J., Ishfaq, M., Ali, G., Saeed, M. R., Hussain, M., Alkhalifah, T., Alturise, F., & Samand, N. (2022). Skin Cancer Disease Detection Using Transfer Learning Technique. *Applied Sciences*, 12(11), 5714. <https://doi.org/10.3390/app12115714>
- Reyad, M., Sarhan, A. M., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization. *Neural Computing and Applications*, 35(23), 17095-17112. <https://doi.org/10.1007/s00521-023-08568-z>
- Rezaoana, N., Hossain, M. S., & Andersson, K. (2020). Detection and classification of skin cancer by using a parallel CNN model. *2020 IEEE international women in*

- engineering (WIE) conference on electrical and computer engineering (WIECON-ECE), 380-386. <https://doi.org/10.1109/WIECON-ECE52138.2020.9397987>
- Rigel, D. S., & Stein Gold, L. F. (2013). The importance of early diagnosis and treatment of actinic keratosis. *Journal of the American Academy of Dermatology*, 68(1, Supplement 1), S20-S27. <https://doi.org/10.1016/j.jaad.2012.10.001>
- Roy, A. G., Navab, N., & Wachinger, C. (2019). Recalibrating Fully Convolutional Networks With Spatial and Channel “Squeeze and Excitation” Blocks. *IEEE Transactions on Medical Imaging*, 38(2), 540-549. <https://doi.org/10.1109/TMI.2018.2867261>
- Saeed, M., Naseer, A., Masood, H., Rehman, S., & Gruhn, V. (2023). The Power of Generative AI to Augment for Enhanced Skin Cancer Classification: A Deep Learning Approach. *IEEE Access*, PP, 1-1. <https://doi.org/10.1109/ACCESS.2023.3332628>
- Salehi, A. W., Khan, S., Gupta, G., Alabdullah, B. I., Almjally, A., Alsolai, H., Siddiqui, T., & Mellit, A. (2023). A study of CNN and transfer learning in medical imaging: Advantages, challenges, future scope. *Sustainability*, 15(7), 5930. <https://doi.org/10.3390/su15075930>
- Sathyanarayanan, S. (2024). Confusion Matrix-Based Performance Evaluation Metrics. *African Journal of Biomedical Research*, 4023-4031. <https://doi.org/10.53555/AJBR.v27i4S.4345>
- Shaha, M., & Pawar, M. (2018). Transfer learning for image classification. *2018 second international conference on electronics, communication and aerospace technology (ICECA)*, 656-660. <https://doi.org/10.1109/ICECA.2018.8474802>
- Shanthi, T., Sabeenian, R. S., & Anand, R. (2020). Automatic diagnosis of skin diseases using convolution neural network. *Microprocessors and Microsystems*, 76, 103074. <https://doi.org/10.1016/j.micpro.2020.103074>
- Shin, H.-C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Yao, J., Mollura, D., & Summers, R. M. (2016). Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE transactions on medical imaging*, 35(5), 1285-1298. <https://doi.org/10.1109/TMI.2016.2528162>
- Smith, L. N. (2017). Cyclical Learning Rates for Training Neural Networks. *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 464-472. <https://doi.org/10.1109/WACV.2017.58>
- Soydaner, D. (2020). A Comparison of Optimization Algorithms for Deep Learning. *International Journal of Pattern Recognition and Artificial Intelligence*, 34(13), 2052013. <https://doi.org/10.1142/S0218001420520138>
- Spyder (software). (2025). İçinde *Wikipedia*. [https://en.wikipedia.org/w/index.php?title=Spyder\\_\(software\)&oldid=1320635745](https://en.wikipedia.org/w/index.php?title=Spyder_(software)&oldid=1320635745)
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 31(1). <https://doi.org/10.1609/aaai.v31i1.11231>
- Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *International conference on machine learning*, 6105-6114. <https://proceedings.mlr.press/v97/tan19a.html?ref=ji>

- Tan, M., & Le, Q. (2021). EfficientNetV2: Smaller Models and Faster Training. *Proceedings of the 38th International Conference on Machine Learning*, 10096-10106. <https://proceedings.mlr.press/v139/tan21a.html>
- TensorFlow. (2025). İçinde *Vikipedi*. <https://tr.wikipedia.org/w/index.php?title=TensorFlow&oldid=35981787>
- Vrbančič, G., & Podgorelec, V. (2020). Transfer learning with adaptive fine-tuning. *IEEE Access*, 8, 196197-196211. <https://doi.org/10.1109/ACCESS.2020.3034343>
- Wang, S.-H., & Zhang, Y.-D. (2020). DenseNet-201-Based Deep Neural Network with Composite Learning Factor and Precomputation for Multiple Sclerosis Classification. *ACM Trans. Multimedia Comput. Commun. Appl.*, 16(2s), 60:1-60:19. <https://doi.org/10.1145/3341095>
- Wang, Y., Li, Y., Song, Y., & Rong, X. (2020). The influence of the activation function in a convolution neural network model of facial expression recognition. *Applied Sciences*, 10(5), 1897. <https://doi.org/10.3390/app10051897>
- Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big Data*, 3(1), 9. <https://doi.org/10.1186/s40537-016-0043-6>
- Woo, S., Park, J., Lee, J.-Y., & Kweon, I. S. (2018). CBAM: Convolutional Block Attention Module. İçinde V. Ferrari, M. Hebert, C. Sminchisescu, & Y. Weiss (Ed.), *Computer Vision – ECCV 2018* (C. 11211, ss. 3-19). Springer International Publishing. [https://doi.org/10.1007/978-3-030-01234-2\\_1](https://doi.org/10.1007/978-3-030-01234-2_1)
- Wu, Z. H. E., Zhao, S., Peng, Y., He, X., Zhao, X., Huang, K., Wu, X., Fan, W., Li, F., & Chen, M. (2019). Studies on different CNN algorithms for face skin disease classification based on clinical images. *IEEE Access*, 7, 66505-66511. <https://doi.org/10.1109/ACCESS.2019.2918221>
- Yacouby, R., & Axman, D. (2020). Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models. İçinde S. Eger, Y. Gao, M. Peyrard, W. Zhao, & E. Hovy (Ed.), *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems* (ss. 79-91). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2020.eval4nlp-1.9>
- Yin, M., Chen, Z., & Zhang, C. (2023). A CNN-transformer network combining CBAM for change detection in high-resolution remote sensing images. *Remote Sensing*, 15(9), 2406. <https://doi.org/10.3390/rs15092406>
- Zaheer, R., & Shaziya, H. (2019). A Study of the Optimization Algorithms in Deep Learning. *2019 Third International Conference on Inventive Systems and Control (ICISC)*, 536-539. <https://doi.org/10.1109/ICISC44355.2019.9036442>
- Zhang, J., Wu, J., Wang, H., Wang, Y., & Li, Y. (2021). Cloud detection method using CNN based on cascaded feature attention and channel attention. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-17. <https://doi.org/10.1109/TGRS.2021.3120752>
- Zhang, Z. (2018). Improved Adam Optimizer for Deep Neural Networks. *2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS)*, 1-2. <https://doi.org/10.1109/IWQoS.2018.8624183>

## ÖZGEÇMİŞ

---

**Adı Soyadı**

---

**Kişisel Bilgiler**

---

**İletişim Bilgileri**

---

**Öğrenim Bilgileri**

---

**İş Deneyimi**

---

