

## Parçacık Sürüsü Optimizasyon Algoritması ile Optimize Edilmiş Evrimsel Sinir Ağı Kullanılarak Dermoskopik Görüntülerden Cilt Kanserinin Sınıflandırılması

Erdal ÖZBAY<sup>1\*</sup>, Feyza ALTUNBEY ÖZBAY<sup>2</sup>

<sup>1</sup> Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

<sup>2</sup> Yazılım Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

\*<sup>1</sup>erdalozbay@firat.edu.tr, <sup>2</sup>faltunbey@firat.edu.tr

(Geliş/Received: 10/11/2022;

Kabul/Accepted: 30/11/2022)

**Öz:** Dermoskopik görüntülerden cilt lezyonlarını sınıflandırmak için güçlü bir tıbbi karar destek sistemi oluşturmak cilt kanserinin teşhisi için önemli bir adımdır. Laboratuvarlarda cilt kanseri teşhisi için gerçekleştirilen manuel araştırma, insan yorgunluğu, birlikte çalışabilirlik hataları vb. gibi belirli faktörler nedeniyle hatalara açıktır. Bununla birlikte, cilt lezyonlarının karmaşık morfolojik yapısından dolayı eğitilmiş verilerin kullanılmasında ciddi sorunlar yaşanmaktadır. Son yıllarda, Evrimsel Sinir Ağı (CNN) kullanılarak dermoskopik görüntülerden cilt kanseri türlerini tespit etmede önemli ilerlemeler kaydedilmiştir. Bu çalışmanın temel amacı, farklı sınıf sayılarına sahip cilt kanseri türlerini içeren dermoskopik görüntüleri yüksek doğrulukla otomatik olarak sınıflandırmak için CNN tabanlı bir model geliştirmektir. Çalışmada, evrimsel bir algoritmanın yanlış sınıflandırma oranını azaltmak üzere bir derin öğrenme modeline entegre edildiği bir metodoloji önerilmiştir. CNN hiper-parametreleri, cilt lezyonlarını dört farklı türde sınıflandırmada ağ performansını iyileştirmek için Parçacık Sürüsü Optimizasyon (PSO) algoritması kullanılarak optimize edilmiştir. Önerilen yöntem ile %99,33 doğruluk, %94,65 duyarlılık, %98,87 özgüllük ve 0,983 AUC sonuçlarına ulaşılarak birleştirilmiş ISIC-2019 ve Asian-dermoscopy veri kümeleri üzerinde test edilmiştir. Sonuçlar, Genetik Algoritmalar (GA), Diferansiyel Evrim (DE) ve Gri Kurt Optimizasyonu (GWO) algoritmaları gibi benzer kanıtlanmış algoritmalarla karşılaştırılmıştır. Deneysel sonuçlar, cilt kanseri sınıflandırması için CNN hiper-parametrelerini optimize etmede PSO'nun verimliliğini göstermiştir.

**Anahtar kelimeler:** Cilt kanseri, CNN, Dermoskopik görüntü, Sınıflandırma, PSO.

### Classification of Skin Cancer from Dermoscopic Images using Convolutional Neural Network Optimized with Particle Swarm Optimization Algorithm

**Abstract:** Creating a powerful medical decision support system to classify skin lesions from dermoscopic images is an important step for the diagnosis of skin cancer. Manual research for skin cancer diagnosis in laboratories, human fatigue, interoperability errors, etc. It is prone to errors due to certain factors such as However, there are serious problems in using educated data due to the complex morphological structure of skin lesions. In recent years, significant advances have been made in detecting types of skin cancer from dermoscopic images using the Convolutional Neural Network (CNN). The main aim of this study is to develop a CNN-based model to automatically classify dermoscopic images containing skin cancer types with different class numbers with high accuracy. In the study, a methodology is proposed in which an evolutionary algorithm is integrated into a deep learning model to reduce the misclassification rate. CNN hyper-parameters were optimized using the Particle Swarm Optimization (PSO) algorithm to improve network performance in classifying skin lesions into four different types. The proposed method was tested on the combined ISIC-2019 and Asian-dermoscopy datasets, achieving 99.33% accuracy, 94.65% sensitivity, 98.87% specificity, and 0.983 AUC results. The results are compared with similar proven algorithms such as Genetic Algorithms (GA), Differential Evolution (DE), and Gray Wolf Optimization (GWO) algorithms. Experimental results demonstrated the efficiency of PSO in optimizing CNN hyper-parameters for skin cancer classification.

**Key words:** Skin cancer, CNN, Dermoscopic image, Classification, PSO.

#### 1. Giriş

İnsan vücudundaki en büyük organ olan deri, tüm vücudu kaplar ve patojenlerin istilasını ve su kaybını önlemede önemli bir engeldir. Deri hastalıkları dünyada en sık görülen insan hastalıklarından biridir [1]. Birçok cilt hastalığı insanlarda çeşitli rahatsızlıklara neden olabilmekte ve yaşam kalitesini olumsuz etkileyebilmektedir, bunun yanında malign melanom gibi bazı hastalıklar insan yaşamını tehdit edici bile olabilmektedir. Dermoskopi, cilt hastalıklarını teşhis etmek için mikroskopik görüntü analiz tekniklerini kullanan invaziv olmayan ve invivo bir incelemedir [2]. Deri yüzeyini onlarca kez büyütürken dermatologların canlı bir deri yüzeyinin altındaki

\* Sorumlu yazar: [erdalozbay@firat.edu.tr](mailto:erdalozbay@firat.edu.tr). Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-9004-4802, <sup>2</sup> 0000-0003-0629-6888

mikroskobik yapıyı ve pigmentleri gözlemlemesine olanak tanımaktadır [3]. Doktorların teşhisine dayanan bir yöntem subjektiftir ve o sırada bir dermatoloğun görsel değerlendirmesi ve tanısal deneyiminden kolayca etkilenmektedir, bu nedenle bildirilen duyarlılık ve özgüllük çalışmalar arasında önemli ölçüde farklılık gösterebilmektedir [4].

İnsanlarda en tehlikeli ve yaygın kanser türlerinden bir tanesi cilt kanseridir. Cilt kanseri, genel olarak melanom ve melanom olmayan şeklinde sınıflandırılabilir gibi melanom dışı, bazal hücreli karsinom ve skuamöz hücreli karsinomu olarak ta sınıflandırılabilir. Malign melanom, cilt kanserinin en ölümcül formlarından biri olarak kabul edilmekte ve dünya genelindeki vaka sayıları katlanarak artmaktadır. Diğer tüm kanser türlerinde olduğu gibi cilt kanserinin ölüm oranını azaltmak için de erken teşhis çok önemlidir, çünkü kanser erken bir aşamada tespit edildiğinde ve tedavi edildiğinde yüksek bir iyileşme oranı sağlamaktadır. Cilt kanseri tanısı klinisyenler tarafından zaman alıcı, hataya açık ve daha öznel olan görsel bir muayene ile taranmaktadır. Dermoskopi, lekelerin netliğini artırmak için cilt lezyonlarının aydınlatılmış ve büyütülmüş görüntülerini yakalayabilen, cildin yüzey yansımalarını ortadan kaldıran invaziv olmayan bir görüntüleme tekniğidir. Bununla birlikte, dermatolog tarafından dermoskopik görüntülerden melanom tespiti, rutin klinik ortamlarında %80'den daha az doğruluk oranı ile elde edilmiştir [5]. Cilt kanseri tespitinin etkinliğini ve verimliliğini artırmak için, karar verme sürecini geliştirmek amacıyla klinisyenlere yardımcı olacak bir otomatik teşhis sistemi mutlak gereklidir. Otomatik tanılama araçları geliştirmek ve farklı kategorideki cilt kanserlerini sınıflandırmak için geleneksel Makine Öğrenmesi (ML) algoritmaları kullanılmaktadır. Ancak, ML algoritmaları el yapımı özellikler gerektirdiğinden ve ayrıca dermoskopik görüntülerin yüksek sınıf içi ve sınıflar arası varyasyonları düşük olduğundan, yüksek tanı performansı elde etmek çok zordur [6]. Cilt kanseri hastalıklarının her türlü erken teşhisi ve tedavisi için yansız teşhis çok önemlidir. Son yıllarda birçok araştırmacı, tahmin doğruluğunda önemli bir gelişme sağladığı için Evrişimli Sinir Ağı (CNN) tabanlı yöntemlere odaklanmaktadır [7, 8]. Birçok araştırmacı, otomatik özellik mühendisliği ve kendi kendine öğrenme yetenekleri nedeniyle Derin Öğrenme (DL) tabanlı yöntemler kullanarak cilt kanseri sınıflandırmasına odaklanmaktadır. Derin sinir ağları ile CNN'i daha geniş, daha derin ve artan çözünürlük ile genişletme pahasına yüksek performans elde edilebilmektedir, bu da mimarinin eğitim ve test için yüksek hesaplama gücü ile sonuçlanan ek parametrelere sahip olmasına neden olmaktadır [9].

Son yıllarda CNN içeren DL yöntemleri cilt kanseri sınıflandırmasında kullanılmaktadır. Son çalışmalar, CNN'lerin konuşlandırılmasının, ML yöntemlerinde el yapımı özellik çıkarmanın dezavantajını önleyerek özellikleri otomatik olarak çıkaran sınıflandırma doğruluk oranını arttırdığını göstermiştir [10]. CNN modellerinde örnekleri eğitmek ve test etmek için çok sayıda veri seti kullanılabilir. DL yöntemleri, daha iyi parametre eğitimi ile umut verici sonuçlar vermiş olsa da, bu yöntemler, görüntü kalitesi ve ölçekte çeşitli veri kümelerinde farklı performanslar ortaya koymuştur [11]. DL, çeşitli mimarilere ve hiper-parametrelere izin vermektedir ancak bu tür optimal özelliklerin belirlenmesi zorlu ve kritik bir görevdir [12]. Bu nedenle, bu çalışmada, evrimsel bir algoritma ile entegre edilmiş CNN'i içeren bir derin öğrenme metodolojisi önerilmektedir. CNN hiper-parametreleri, cilt kanser türlerini dört kategoride sınıflandırmada ağın performansını iyileştirmek için PSO algoritmasını kullanarak optimize edilmiştir. Bu, optimum hiper-parametreler için manuel arama işlemleri ortadan kaldırılmıştır.

Bu çalışmamızın temel katkıları şöyle özetlenebilir:

- Uçtan uca eğitilebilir bir CNN ile cilt kanserinin otomatik olarak dört kategoride sınıflandırılması; melanoma (MEL), melanocytic nevus (MN), basal cell carcinoma (BCC), benign keratosis (BK).
- CNN hiper-parametreleri, optimum özellikler için manuel arama yerine PSO kullanılarak optimize edilmiştir.
- Duyarlılık oranı artırılarak Bilgisayar Destekli Tasarım (CAD) sürecindeki yanlış pozitifler azaltılmaktadır.
- Önerilen yöntem ile sınıflandırma doğruluğunda önemli düzeyde iyileştirme sağlanmıştır.

Makalenin geri kalanı şöyle özetlenebilir; ikinci bölümde mevcut ilgili çalışmalar ana hatlarıyla incelenmiştir, üçüncü bölümde çalışma için kullanılan veri kümeleriyle birlikte önerilen metodoloji detaylandırılmaktadır, deneysel sonuçlar ve tartışma dördüncü bölümde ele alınmaktadır ve bölüm 5'te sonuçların özetlenmesiyle çalışma sonlandırılmaktadır.

## 2. İlgili Çalışmalar

Son yıllarda ML algoritmalarının genişletilmesi, araştırmacıların tıbbi görüntü analizi alanında birçok uygulama geliştirmesine imkân sağlamıştır. Moldovanu vd., giriş görüntülerine eşik yöntemini uygulayarak

bölgelere ayırmış ve bir dizi Gabor özneliğini çıkararak çok seviyeli bir sinir ağı ile eğitmiştir [13]. Bir başka çalışmada, Destek Vektör Makinesi (SVM) modeli kullanılarak melanom cilt kanseri tespiti için bir çerçeve önerilmiş ve dermoskopik görüntülerden elde edilen optimize edilmiş HOG özneliklerinin yardımıyla eğitilmiştir [14]. Monisha vd., iyi huylu lezyonları melanomdan ayırmak için kullanılan görüntülerin ABCD kuralı olarak bilinen asimetri, sınır, renk ve çap özellikleri yardımıyla dermoskopik skor hesaplamasını gerçekleştirmiştir [15].

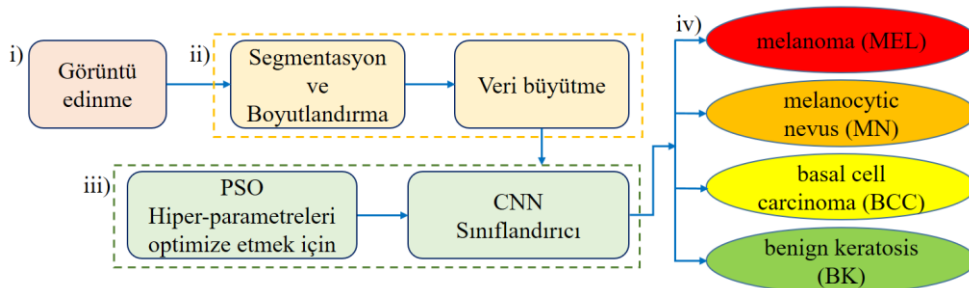
Bir diğer çalışmada, SVM sınıflandırıcısında kullanılmak üzere global öznelikler ve yerel desenler modeli eğitmek için birleştirilmiştir [16]. Renk ve lezyon şekli gibi global özellikler geleneksel görüntü işleme teknikleri vasıtasıyla çıkarılırken, yerel desenler Derin Sinir Ağı (DNN) kullanılarak çıkarılmıştır. Moura vd., ABCD kuralı ve çeşitli ön-eğitilmiş CNN ile gelen özellikleri birleştiren bir hibrit tanımlayıcı kullanarak modelin eğitildiği çok katmanlı algılayıcıyı kullanan bir ikili cilt sınıflandırma yöntemi önermişlerdir [17]. Başka bir çalışmada DenseNet201 kullanılarak öznelikler çıkarıldıktan ve yineleme kontrollü Newton-Raphson (ICNR) yöntemiyle ayırt edici öznelikler seçildikten sonra, çok katmanlı ileri beslemeli sinir ağı kullanılarak cilt kanseri lokalizasyonu ve tanınması için bir yöntem önerilmiştir [18]. Bir diğer çalışmada, ABCD kuralıyla edinilen el yapımı öznelikler ile birlikte transfer öğrenmeden derin öğrenmeyle edinilen öznelikler birleştirilmiştir, böylece karşılıklı bilgi metriğini kullanan bir öznelik birleştirme yaklaşımı önerilmiştir [10].

Naeem vd., CNN kullanarak melanom teşhisi için derin bir öğrenme tekniği önermiştir. Benzerlikler ve farklılıklar temelinde yaşanan zorlukların sistematik bir incelemesini sağlamışlardır [19]. Çok boyutlu, çok ölçekli, çok çözünürlüklü ve düşük kontrastlı görüntülerin eğitilmesiyle ilgili sorunlarla ilgilenilen bir çalışmada DCNN kullanılarak uçtan uca ve piksel bazında bir öğrenme önerilmiştir [20]. Bir diğer çalışma U-net mimarisinde yerel ikili evrişimi kullanarak cilt lezyonlarının teşhisi problemini ele almıştır [21]. Burada ilişkili bölge tabanlı bir CNN tekniğini kullanan ve ResNet152 mimarisi kullanılarak ikili sınıflandırma yapılan iki aşamalı bir bölütleme yöntemi önerilmiştir. Bir başka çalışmada AlexNet ile desteklenen bir transfer öğrenme tekniğini kullanan ön-eğitilmiş bir model sunulmuştur [22]. Bir çalışmada InceptionV3, Xception, NASNetLarge, InceptionV2, ve ResNet101 derin öğrenme modellerinin en iyi hiper-parametre kurulumuna sahip eğitimi, ImageNet'in önceden eğitilmiş farklı modelleri arasından daha iyi performans gösterdiğini ortaya koymuştur [23]. Lee vd., değiştirilmiş U-Net ile segmentasyon için piksel bazında öznelikleri öğrenen ve DenseNet kodlayıcıdan çıkarılan öznelikler kullanılarak sınıflandırılan bir boru hattı önermiştir [24]. Harangi, sınıflandırma doğruluğunu geliştirmek için CNN'lerin ağırlıklı çıktısına dayalı mimarileri birleştiren bir metodoloji önermiştir [9]. Mahbod vd., eğitilmiş SVM sınıflandırma çıktısını, SVM'yi önceden eğitilmiş çeşitli CNN'lerden alınan derin özelliklerle eğittikten sonra birleştirilmesini önermişlerdir [25].

Genel olarak, herhangi bir DL modelinin doğruluğu, deneme yanılma yöntemleriyle manuel olarak yapılan hiper-parametre ayarına doğrudan bağlıdır. Bu nedenle, herhangi bir modelin yüksek doğruluk elde etmesi için uygun parametrelerin belirlenmesi çok önemlidir. Bu nedenle bu çalışmada, Tan ve Le tarafından EfficientNet modeliyle birlikte tanımlanan bileşik ölçekleme yöntemiyle elde edilen hiper-parametrelere dayalı modellerde otomatik ince ayar yöntemini cilt lezyonlarının teşhisi için önermekteyiz [26].

### 3. Materyal ve Yöntem


Cilt lezyonlarının sınıflandırması için Şekil 1'de gösterildiği gibi önerilen metodoloji şu adımlara sınıflandırılmaktadır; (i) kullanılan veri setlerini veri toplama ile detaylandırma, (ii) segmentasyon, yeniden boyutlandırma ve girdi görüntülerinin büyütme ön-işlemi, (iii) PSO tarafından optimize edilmiş CNN kullanılarak dört kategoride cilt lezyonlarına göre sınıflandırma ve (iv) sonuçların değerlendirilmesi.



Şekil 1. Önerilen yöntemin akış diyagramı.

### 3.1. Veri Kümeleri

Bu çalışmada kullanılan dermoskopik görüntü veri kümelerinden ilki, Tschandl vd., Codella vd., ve Combalia vd., tarafından sağlanan International Skin Imaging Colaboration (ISIC-2019) sınıflandırma veri kümesidir [27-29]. İkincisi ise Pekin Birliği Tıp Koleji Hastanesi Dermatoloji Departmanı tarafından sağlanan Asian-dermoscopy veri kümesidir.




#### 3.1.1. ISIC-2019 Veri Kümesi

ISIC-2019 veri seti, 8 farklı kategoride toplamda 25331 görüntü içermektedir. Deneysel sonuçların sağlıklı yürütülmesi için gerekli veri kümesinin oluşturulmasında 8 kategorideki örnek görüntü sayısı eşit olmayan bir şekilde dağıldığından örnek sayısı 1000 adetten fazla olan 4 kategori; melanoma (MEL), melanocytic nevus (MN), basal cell carcinoma (BCC), benign keratosis (BK) olacak şekilde seçilmiştir. Böylelikle toplamda 23344 adet cilt lezyonu görüntüsü bu veri kümesinden kullanılmak üzere tercih edilmiştir. Çalışmada kullanılan bu veri setine ait temel bilgilere Şekil 2’de yer verilmiştir.

#### 3.1.2. Asian-dermoscopy Veri Kümesi

Asian-dermoscopy veri seti, 8 farklı kategoride toplamda 7974 görüntü içermektedir. Deneysel sonuçların sağlıklı yürütülmesi için ISIC-2019 veri kümesinde seçilen 4 kategoriye ait görüntüler kullanılmıştır. Böylelikle melanoma (MEL), melanocytic nevus (MN), basal cell carcinoma (BCC), benign keratosis (BK) olmak üzere toplamda 4377 adet cilt lezyonu görüntüsü bu veri kümesinden kullanılmak üzere tercih edilmiştir. Çalışmada kullanılan bu veri setine ait temel bilgilere Şekil 2’de yer verilmiştir.


### 3.2. Segmentasyon ve Boyutlandırma



Şekil 3. Veri kümelerinin farklı kategorideki görüntü örnekleriyle segmentasyon sonuçları.

Veri kümelerinden elde edilen cilt lezyon görüntüleri gereksiz ve alakasız arka plan öğeleri içermektedir. Bu gereksiz içeriklere ait bilgiler sınıflandırmaya katkıda bulunmadıkları gibi geniş bir yer kapladıklarından sınıflandırma doğruluk oranında düşüşe neden olmaktadır. Bu durum, CNN'in eğitim aşamasını olumsuz yönde etkilemekte ve performansını düşürmektedir. Bu bakımdan, veri tabanına sağlanan bir maskeleyme işlemi uygulanarak cilt lezyonlarını tek başına bölümlere ayırma ihtiyacı doğmuştur. Bölünmüş lezyon görüntüleri daha sonra oluşturulan modelin sorunsuz yürütüleceği şekilde yeniden boyutlandırılmaktadır. Farklı kategorilere karşılık gelen maskelere sahip lezyon örnekleri Şekil 3'te gösterilmektedir. Bölünmüş cilt lezyon görüntüleri  $28 \times 28$  piksele yeniden boyutlandırılır ve CNN'e girdi olarak verilmektedir. Görüntü yeniden boyutlandırma, sabit giriş nöronları gerektiren ağın en başında tamamen bağlı bir katman mevcut olduğundan gerçekleştirilmek zorundadır [30].

### 3.3. Veri Büyütme



Şekil 4. Veri kümelerinin farklı kategorideki görüntü örnekleriyle segmentasyon sonuçları.

Derin öğrenme modelleri CNN'i etkili bir şekilde eğitmek için genellikle çok büyük eğitim verilerine ihtiyaç duymaktadır. Eğitim için yetersiz verilerle, cilt lezyonlarının tespiti ve doğru bir sınıflandırma sisteminin oluşturulması imkansızdır. Genellikle, cilt lezyonlarına ait veri setlerinde çok fazla morfolojik varyasyon gözlemlenmektedir. Bu durum, önyargılı öğrenmeye neden olan veri sınıfı dengesizliği yaratmakta ve test sırasında modelin performansının düşmesine yol açmaktadır [31]. Veri kümesine ait örnek sayısının azlığı, verilerin yapay olarak artırılmasıyla veri büyütme işlemi gerçekleştirilmektedir. Ek veri örnekleri oluşturmak adına orijinal veri kümesindeki görüntüleri dönüştürme teknikleri uygulanmaktadır. Orijinal veri kümesine uygulanan görüntü dönüştürme teknikleri,  $0-360^\circ$  ( $90^\circ$ ,  $180^\circ$ ,  $270^\circ$  vb.) arasında rastgele döndürmelerle ya da istenen sayıda örnek oluşturulana kadar rastgele dikey ve yatay çevirmelerle gerçekleştirilir. Döndürülmüş veya çevrilmiş görüntüler sırasıyla 0,5 ve 1,5'e ölçeklendirilmiştir. Veri büyütme işlemi sayesinde, öğrenme için veri sayıları artırılır ve aşırı uyum sorununun önüne geçilir. Bununla birlikte alakasız özelliklerin öğrenilmesi de engellenmiş olur. Zemin gerçeği etiketli görüntüleri de benzer şekilde artırılmaktadır. Bu dönüşüm kullanılarak istenilen veri örneklerini elde etmek mümkündür. Bu dönüştürülmüş görüntüler, farklı CNN modellerini eğitmek için kullanılabilir. Çalışmada veri kümesinin artırılan görüntülerine de segmentasyon ve boyutlandırma işlemi uygulanarak CNN modelinde eğitim için hazır hale getirilir. Görüntü sınıflandırma ile ilgili çeşitli literatür çalışmaları, bu tür dönüşümlerin eğitilmiş CNN modellerinin performansını artırabileceğini göstermiştir. Rastgele büyütülmüş örnek görüntüler Şekil 4'te gösterilmektedir.

### 3.4. Sınıflandırma

Veri büyütme operasyonunun sonrasında, ön-işlemden geçirilmiş ve yeniden boyutlandırılmış her bir cilt lezyon görüntüsü, cilt kanserini dört ayrı kategoride sınıflandırmak üzere ayıran bir CNN'i beslemek üzere girdi olarak verilmektedir. CNN, girdileri temsil eden kalıpların örtük özelliklerini otomatik olarak çıkarmaktadır ve çıkarılan özelliklerden kalıpları daha fazla sınıflandırmaktadır [32]. CNN normalde katlamalı katmanlara, havzalama, aktivasyon katmanlarına ve katmanların uygulanmasına göre değişen hiper-parametrelere sahip tamamen evrişimli katmanlara sahiptir. CNN'in etkinliği, CNN'i çeşitli uygulamalar için eğitmeye bağlıdır. CNN, el yapımı özelliklerin kullanımından kaçınarak bu aşamada otomatik olarak öğrenmektedir. CNN'deki temel mantık, özellikleri çıkarmak için kullanılan ağırlık ve eğitim aşamasında hesaplanan görüntüleri sınıflandırmak için tam bağlantılı katmanı kullanmaktır [33]. Her katman için optimum hiper-parametrelerin manuel olarak belirlenmesi oldukça pahalı ve zahmetli olduğundan, CNN için optimum hiper-parametreleri elde etme görevini

kolaylaştırmak için görüntülerin sınıflandırılmasında PSO kullanılmıştır [11]. PSO, biyolojik olarak sürü popülasyonlarının davranışından ilham alan, yaygın olarak kullanılan bir evrimsel algoritmadır [34]. PSO, kısa bir hesaplama süresi içinde kaliteli çözümler üretme yeteneğine sahiptir. PSO, diğer biyo-ilhamlı algoritmalara kıyasla optimum bir çözüme yakınsamada etkili kararlılık sergilemektedir. Parçacıklar,  $G_{best}$  (başarılı parçacık) ile ilgili bilgileri kullandığından sürünün çeşitliliği de daha etkin bir şekilde korunmaktadır [35].

### 3.4.1. CNN ve PSO

Bu çalışmada kullanılan CNN, evrişimli katmanlarına (Conv1 ve Conv2), ReLU aktivasyonuna ve bir dropout katmanına sahip havuzlama katmanlarına (Pool1 ve Pool2) sahiptir. Tam bağlı katman (FC), giriş katmanını, ReLU aktivasyonu ve dropout katmanı ile başarılı olan gizli katmanı ve son olarak SoftMax aktivasyonuna sahip çıktı katmanını sunmak için kullanılmaktadır. Havuzlama katmanları için  $2 \times 2$  çekirdek boyutu seçilmiştir. Bu çalışmada bir ön-eğitilmiş CNN mimarisi yerine yeni bir CNN modeli geliştirilmiştir. PSO'nun amacı, Conv1 ve Conv2'de kullanılan filtrelerin sayısını, gizli katman nöronlarını, havuzlama türünü, parti boyutunu, eğitilebilir filtre boyutunu ve Conv1, Conv2 ve FC'de kullanılacak dropout düzenleme olasılıklarını optimize etmektir. Parçacık koordinatları, Tablo 1'de listelendiği gibi hiper-parametrelere karşı tanımlanmıştır.

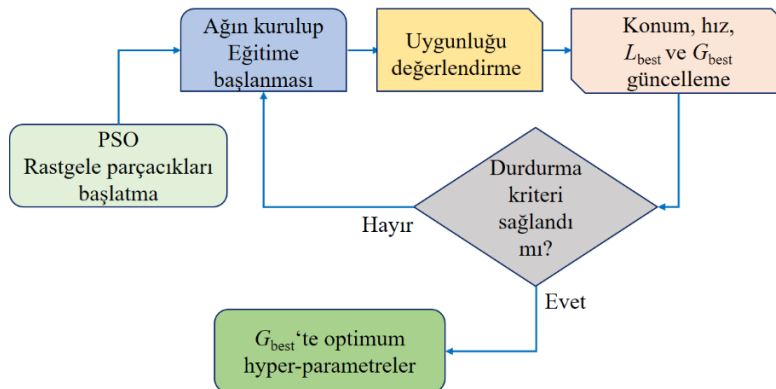
**Tablo 1.** Hiper-parametrelere karşılık gelen parçacıkların tanımlanması.

Parçacık	Hiper-parametre
$\times 1$	Conv1'deki filtre sayısı
$\times 2$	Conv2'deki filtre sayısı
$\times 3$	Gizli katmanın nöron sayısı
$\times 4$	Conv1 ve Conv2'de eğitilebilir filtre boyutu
$\times 5$	Pool1 ve Pool2'de havuzlama türü
$\times 6$	Eğitim parti (batch) boyutu
$\times 7$	Evrışim katmanında dropout olasılığı
$\times 8$	FC katmanında dropout olasılığı

İlk sürünün parçacıklarının rastgele başlatılması, katmanlarda daha fazla nörondan kaçınılacak şekilde aşırı uyumu önlemek için yapılmıştır.  $\times 1$ ,  $\times 2$  ve  $\times 3$ 'e 4-100 arasında değerler atanmıştır.  $\times 4$ 'e giriş görüntülerinin boyutuna bağlı olarak 3 veya 5 değerleri atanmıştır. Ortalama havuzlama için  $\times 5$  seçilmiştir.  $\times 6$ , dönem başına büyük hesaplama süresini engellemek adına 10 ile 100 olarak atanmıştır.  $\times 7$  ve  $\times 8$ , sırasıyla 0,1 ve 0,9 değerleriyle başlatılmıştır. Her parçacığın maliyet fonksiyonu Denklem 1'de verilen uygunluk fonksiyonu ile hesaplanmıştır.

$$Uygunluk\ fonksiyonu = 2 * duyarlılık + doğruluk + özgüllük \quad (1)$$

Her parçacığın konum ve hıza göre güncellenmesi, arama uzayındaki her yinelemede  $L_{best}$  (lokal-en iyi) ve  $G_{best}$  (global-en iyi) temelinde gerçekleşmektedir. Durdurma koşulu, gerekli sayıda yinelemenin elde edilmesinden sonra gerçekleştirilir. Sonlandırma üzerine,  $G_{best}$  ile temsil edilen parçacıklar, cilt kanseri kategorilerinin sınıflandırılması için optimal hiper-parametreler olarak kabul edilmiştir. Şekil 5, önerilen CNN-PSO optimizasyonunun akış şemasını göstermektedir.



**Şekil 5.** CNN-PSO akış diyagramı.

Görüntü işleme sistemlerinin analizi için CAD’da izlenen ve yaygın olarak kabul edilen performans ölçütleri kullanılarak önerilen çalışma doğrulanmıştır [36]. Önerilen modeli doğrulamak için doğruluk, duyarlılık ve özgüllük performans ölçütleri kullanılmıştır. Çalışmada kullanılan performans ölçütleri Tablo 2’de gösterilmiştir.

**Tablo 2.** Performans değerlendirme ölçütleri.

Parametre	Denklem
	$\frac{TP + TN}{TP + FN + TN + FP}$
Doğruluk (Ac)	$\frac{TP}{TP + FN + TN + FP}$
Duyarlılık (Se)	$\frac{TP + FN}{TN}$
Özgüllük (Sp)	$\frac{TN + FP}{TN + FP}$

#### 4. Deneysel Sonuçlar ve Tartışma

Bu çalışmada önerilen yöntem için elde edilen deneysel sonuçlarda Intel Core i7, 3.60 GHz işlemci, Nvidia GTX1080Ti GPU, Windows 10 ve 16 GB RAM içeren bir cihaz kullanılmıştır. Gerçekleştirilen tüm süreçlerde, Tensor Flow ile Keras derin öğrenme çerçevesini kullanan, Python’da pydicom kütüphanesi kullanılarak uygulanmıştır. PSO optimum değerlerin belirlenmesi için tanımlanan parametreleri göstermektedir [37]. Kullanılan parametreler Tablo 3’te verilmiştir.

**Tablo 3.** PSO’nun başlangıç parametreleri.

Parametre	Değer
Popülasyon boyutu	10
Yineleme sayısı	50
Bilişsel parametre	2
Sosyal parametre	2
Atalet ağırlığı	0,6

Bu çalışmada, genel erişime açık ve ulaşılabilir iki ayrı veri seti olan ISIC-2019 ve Asian-dermoscopy kullanılmıştır. Her bir veri setindeki orijinal görüntü dağılımı Şekil 2’de gösterilmiştir. Tablo 4’te, artırılmış görüntülerin eklenmesiyle değiştirilen veri kümelerinin görüntü sayılarının kategorilere göre dağılımı gösterilmektedir.

**Tablo 4.** ISIC-2019 ve Asian dermoscopy veri kümelerinin orijinal ve artırılmış örnek sayıları.

Cilt kanseri kategorileri	ISIC-2019		Asian dermoscopy		Toplam
	Orijinal	Veri büyütme	Orijinal	Veri büyütme	
Melanoma (MEL)	4522	27132	242	1452	28584
Melanocytic nevus (MN)	12875	77250	1702	10212	87462
Basal cell carcinoma (BCC)	3323	19938	720	4320	24258
Benign keratosis (BK)	2624	15744	1713	10278	26022
Toplam	23344	140064	4377	26262	166326

Veri kümeleri, cilt kanserinin farklı türlerine ait daha fazla görüntü örneğini oluşturmak üzere birleştirilmiştir. Her kategori için veri setlerinden rastgele eşit sayıda görüntü alınmaktadır ve büyütme tekniği ile görüntü sayısı artırılmaktadır. Eğitim sürecini iyileştirmek ve optimum hiper-parametreleri belirlemek amacıyla, artırılmış veri kümesi, her biri sınıf başına sırasıyla 750 örnek ve 1000 örnek içerecek şekilde Test1 ve Test2 olmak üzere iki gruba ayrılmıştır. Böylelikle veri dengesi, ayrı bir veri kümesi oluşturularak sağlanmış olur. Tablo 5, iki ayrı veri seti (Test1 ve Test2) oluşturmak için her bir veri setinden alınan görüntülerin sayısını göstermektedir.

Parçacıkları karşılaştırmak için, PSO tarafından üretilen CNN konfigürasyonlarının her birinin eğitimi ve testi benzer setlerle yapılmıştır. Gözetimli eğitim, çapraz entropi kaybı fonksiyonu ile amaçlanan çıktı ve gerçek çıktı arasındaki farklılıkları azaltmak için SGDM optimize kullanılarak gerçekleştirilmiştir [38, 39]. Ağırlık başlatma, normalleştirme işlemi ile yapılmaktadır ve ağırlık güncellemesi, 50 tur (epoch) için standart geri yayılım (Back

Propagation-BP) algoritması ile gerçekleştirilmiştir [40]. Küresel minimum hesaplama için öğrenme oranı 0,01 olarak sabitlenmiştir. Toplam veri seti %60 eğitim ve %40 test için kullanılacak şekilde ayarlanmıştır.

**Tablo 5.** Test1 ve Test2 test setlerinin görüntü bölümleri.

Cilt kanseri kategorileri	Test1 (Rastgele seçim)		Test2 (Rastgele seçim)	
	ISIC-2019	Asian-der	ISIC-2019	Asian-der
Melanoma (MEL)	250	500	700	300
Melanocytic nevus (MN)	250	500	700	300
Basal cell carcinoma (BCC)	250	500	700	300
Benign keratosis (BK)	250	500	700	300
Toplam	3000		4000	

#### 4.1. Test Sonuçları

Tablo 6,  $G_{best}$  tarafından son sürüde temsil edilen parçacıklar için Test1 ve Test2 olmak üzere iki ayrı test setinde elde edilen sonuçları rapor etmektedir. Bu iki test alt kümesinden sayısız örnek kullanılarak,  $G_{best}$  parçacığında bulunan hiper-parametreler aşağıda verilmiştir:

- Conv1'deki filtre sayısı: 61 boyut 3
- Conv2'deki filtre sayısı: 60 boyut 3
- Gizli katman nöronlarının sayısı: 73
- Parti boyutu (batch size): 14
- Ort. Havuzlama (Avg pooling)
- FC katmanında dropout olasılığı: 0,04

**Tablo 6.** İki test örnekleriyle  $G_{best}$  parçacıklarından elde edilen sonuçlar (%).

Test setleri	Sınıf başına örnek sayısı (toplam)	Doğruluk (Ac)	Duyarlılık (Se)	Özgüllük (Sp)	AUC
Test1	750 (3000)	97,93	92,89	98,75	0,963
Test2	1000 (4000)	99,33	94,65	98,87	0,983
	Ortalama (mean)	98,63	93,77	98,81	0,973
	Varyasyon katsayısı: Standart sapma/mean	0,709	0,938	0,061	1,027

Tablo 6'da verilen sonuçlar, birleştirilmiş veri kümesinden cilt kanseri sınıflandırması için CNN-PSO modelinin performansını göstermektedir. Ortalama %98.63 doğrulukla birlikte Test2 veri seti ile %99.33 gibi kayda değer bir yüksek doğruluk elde edilmiştir. Buna karşılık gelen duyarlılık, özgüllük ve AUC sırasıyla %94,65, %98,87 ve 0,983'dir. Ayrıca, sınıflandırma çeşitliliğini temsil eden etkinliği kanıtlayan  $G_{best}$  tarafından düşük bir varyasyon katsayısı değerine de ulaşıldığı tablodan fark edilebilmektedir. Ayrıca, cilt kanseri lezyonlarının şeklinin dokusundan çok, durumlarda yanlış pozitiflerden sorumlu olabileceği deneylerden gözlemlenmiştir. Ayrıca, bir parçacığın eğitilmesi için ortalama sürenin yaklaşık 50 dakika olduğu ve PSO için toplam işlem süresinin 15 saat olduğu gözlemlenmiştir.

**Tablo 7.** İki veri kümesinde CNN modelinin 10-kat (fold) Cross-Validation (CV) doğruluğu.

CV	Doğrulama (Ac%)	
	ISIC-2019	Asian dermoscopy
1	92,59	91,07
2	93,69	91,42
3	94,59	93,49
4	95,59	94,97
5	95,89	96,21
6	96,89	96,74
7	97,69	97,94
8	98,39	98,65
9	99,49	99,13
10	99,69	99,49
Ortalama	96,45	95,91



PSO ile optimize edilmiş CNN'nin performansı, yöntemin bireysel veri kümeleri üzerindeki güvenilirliğini kanıtlamak için 10 kat çapraz doğrulama CV stratejisi aracılığıyla yürütülmüştür [41]. Bu stratejide, verilen verilerden 9'unun CNN'i eğitmek üzere ve geri kalanının modeli doğrulamak üzere kullanıldığı 10 parçaya bölünmektedir. İşlem 10 kez tekrarlanmaktadır. Tek bir cilt kanseri lezyon görüntüsü için test süresi ortalama 1,5 s'dir. Tablo 7, on farklı veri kıvrımının ortalaması kullanılarak hesaplanan CV'nin nihai tahminini göstermektedir.

Cilt kanseri lezyon görüntülerini sınıflandırmada CNN-PSO'nun performansını karşılaştırmak için iki test veri seti üzerinde istatistiksel bir deney yapılmıştır. Önerilen yöntem, Genetik Algoritmalar (GA), Diferansiyel Evrim (DE) ve Gri Kurt Optimizasyonu (GWO) gibi benzer optimizasyon algoritmaları ile karşılaştırılmıştır. Çok sayıda yapılmış uygulamalarda tahmin ve optimizasyon modeli olarak kullanılan bu algoritmaların performansına dayalı olarak, karşılaştırmalar yapılmıştır. Mevcut literatür çalışmalarından edinilen bilgiler neticesinde bu algoritmalar için kullanılan parametrelerin ayarlanması Tablo 8'de verildiği gibidir. Değerlendirme için kullanılan istatistiksel kriterlerin hesaplanması Denklem 2-5'te verilmiştir [42].

**Tablo 8.** Optimizasyon algoritmalarında kullanılan parametre ayarları.

Optimizasyon algoritmaları	Parametre ayarları
Genetik Algoritma + CNN	Çaprazlama: 0,8, mutasyon: 0,01
Diferansiyel Evrim + CNN	F: 0,8, C: 0,4
Gri Kurt Optimizasyonu + CNN	$\rho$ : 0,3, $\gamma$ : 0,5, $\beta$ : 0,08, $n$ : 4, $s$ : 0,04, $l_0$ : 5

$$\text{Ortalama kare hatası (OKH)} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

$$\text{Ortalama mutlak hata (OMH)} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$\text{KökOKH (KOKH)} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$


$$\text{Coefficient belirleme (R}^2\text{)} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

Bu denklemlerde  $\hat{y}_i$ ,  $i$ . tahmin edilen elemanı,  $y_i$ ,  $i$ . ölçülen elemanı,  $n$ , örnek sayısını,  $\bar{y}$ , tahmin edilen karşılık gelen değerlerin ortalamasını temsil etmektedir.

**Tablo 9.** PSO+CNN'nin diğer optimizasyon algoritmalarıyla istatistiksel değerlendirme sonuçları.

Yöntem	OKH	OMH	KOKH	R <sup>2</sup>
Genetik Algoritma (GA) + CNN	0,0646	0,1498	0,1993	0,5942
Diferansiyel Evrim (DE) + CNN	0,0472	0,1474	0,1892	0,7738
Gri Kurt Optimizasyonu (GWO) + CNN	0,0287	0,1153	0,1582	0,8647
Önerilen yöntem - PSO + CNN	0,0176	0,0837	0,1108	0,9312

Tablo 9'da, önerilen PSO-CNN modelinin test veri setleri üzerinden diğer optimizasyon algoritmaları ile istatistiksel kriterler bakımından karşılaştırılması verilmiştir. OKH, OMH ve KOKH ile en düşük değerli sonuçlar en verimli yöntemi gösterirken, yüksek R<sup>2</sup> değeri daha iyi bağıntıyı göstermektedir. Tablo 9'da gösterildiği üzere, PSO-CNN'in diğer algoritmalara kıyasla daha iyi performans kriterlerini karşıladığı açıktır. Yüksek doğrulukta sınıflandırma üretmek için PSO'nun yakınsaması Şekil 6'da gösterilmektedir.



Şekil 6. PSO yakınsama grafiği (Doğruluk / Yineleme).

Tablo 10. Önerilen yöntemin mevcut ilgili çalışmalarla karşılaştırılması.

Çalışma	Yöntem	Doğruluk (%)
Xie vd., [43]	Segmentasyon	85,8
Shahin vd., [44]	CNN	89,9
Khan vd., [45]	CNN	89,8
Liu ve vd., [46]	ROI+CNN	90,67
Pour ve Seker [47]	Segmentasyon+CNN	95,62
Al-Masni vd., [48]	Segmentasyon+FrCN	90,78
Serte vd., [49]	Derin öğrenme	91
Dash vd., [50]	Segmentasyon+U-Net	94,8
Li vd., [51]	CNN	99,08
Cengil vd., [52]	CNN	77
Yıldırım ve Cinar [53]	Hybrid CNN	83,49
Önerilen yöntem	PSO ile optimize CNN	99,33

DeneySEL sonuçlar, CNN'nin optimum hiper-parametrelerinin keşfedilmesinde PSO'nun kullanılabilceğini gösterirken, bu uygulama 10 kez çalıştırılarak gerçekleştirilmiştir. Özetle, önerilen çalışmanın sınıf sayısı, CNN ve varyantları, aynı veya benzer veri kümeleri ve sınıflandırma oranı (%) bazında mevcut benzer yöntemlerle karşılaştırılması Tablo 10'da gösterilmiştir.

Önerilen yöntem, literatür bölümünde anlatılan benzer cilt kanseri lezyon görüntülerini sınıflandırma yaklaşımlarıyla karşılaştırılmıştır. Önerilen yöntemde, giriş görüntüsünün özelliğini uyarlamalı olarak öğrenilebilmektedir. Sınıf dengesizliğini önlemek için önerilen yöntem, rastgele seçilmiş görüntü örneklerine sahip birleştirilmiş veri kümesini kullanarak bu sorunu etkin bir şekilde ele almaktadır. Ayrıca, model sağlamlığını artıran ve yakınsamayı hızlandıran CNN parametrelerini optimize etmek için PSO algoritması kullanılmıştır. Karşılaştırılan yöntemler, birkaçı dışında aynı veya benzer veri kümelerini kullanmışlardır. Önerilen yaklaşımda 10. yinelemede maksimum puanla yakınsama sağlanmıştır. Yöntemlerden bazıları çok sınırlı veri kümeleriyle test edilmektedir ve kullanılan algoritmalar yavaştır. Ayrıca, performansın düşmesine yol açan uzamsal bilgiyi (özellikler arasındaki göreceli ilişki) ölçmekten yoksundurlar. Geleneksel yöntemlere göre önerilen yöntem, basitliği, orta düzeyde donanım gereksinimi ile uygulama kolaylığı ve çok sınıflı varyansı işleme yeteneği nedeniyle daha büyük bir potansiyele sahiptir.

Önerilen yöntemle elde edilen kayda değer performansa rağmen, önerilen tekniğin klinik kullanımını sınırlayabilecek bazı eksiklikler bulunmaktadır. Hesaplama süresini iyileştirmek için, bilgi işlem donanımının performansı artırılabilir ya da ağ yapısını ve veri boyutunu küçültmek için iyileştirmeler sağlanabilir. Bununla birlikte önerilen yöntem birden çok örtüşen cilt kanseri lezyon veri kümeleri üzerinde test edilmesi gerekmektedir.

## 5. Sonuçlar

Cilt kanseri lezyon bileşenlerinin analizi, bireylerin sağlık durumunu yansıtmaktadır ve bu nedenle patoloji ve mikro biyolojide önemli kabul edilmektedir. Cilt lezyonlarının görüntülerinin manuel olarak incelenmesi son derece hassastır ve sonuçları taraflı yapan çeşitli faktörler nedeniyle hataya açıktır. CAD sistemleri üzerinden makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak farklı cilt lezyonlarındaki morfolojik değişiklikleri

hızlandırmak ve doğru karar vermek mümkündür. Hiper-parametreleri PSO algoritmaları tarafından optimize edilen CNN kullanan bir derin öğrenme modeli olan bu çalışma sayesinde, bu morfolojik değişiklikleri kapsayan zorlu görev en aza indirilmiştir. Önerilen ağ ile hiper-parametreler optimize edilerek, CAD sistemlerinin yanlış pozitifleri azaltım sürecinde hassasiyet oranı artırılmaktadır. Önerilen model, cilt kanseri sınıflarını dört temel tipte melanoma, melanocytic nevus, basal cell carcinoma, benign keratosis olarak, özelliklerin manuel olarak çıkarılması ve ağın işlevsel hiper-parametrelerinin aranması adımı ortadan kaldırarak yüksek doğrulukla birbirinden ayırmaktadır. Ayrıca, önerilen ağ, diğer algoritmalar tarafından optimize edildiğinde PSO için optimize edilmiş CNN'in aynı CNN tarafından karşılaştırılmalı olarak daha iyi performans gösterdiği ortaya konmuştur. Benzer çalışmalarla karşılaştırıldığında, önerilen yöntem, cilt lezyonlarını kategorize etme konusundaki üstünlüğünü kanıtlamıştır. Umut verici sonuçlar elde edilmesine rağmen, sistemin daha genel ve sağlam olduğunu kanıtlamak için yerel yeni veri kümeleriyle ek deneyler yapılabilir.

## Teşekkür

Yazarlar makaleye eşit katkıdır. E.Ö. ve F.A.Ö. fikir sahibi, E.Ö. deneyleri gerçekleştirdi, E.Ö. ve F.A.Ö. modellemeyi gerçekleştirdi, E.Ö. ve F.A.Ö. sonuçları yorumladı, E.Ö. ve F.A.Ö. makaleyi yazdı.

## Kaynaklar

- [1] Karimkhani, C., Dellavalle, R. P., Coffeng, L. E., Flohr, C., Hay, R. J., Langan, S. M., ... & Naghavi, M. (2017). Global skin disease morbidity and mortality: an update from the global burden of disease study 2013. *JAMA dermatology*, 153(5), 406-412.
- [2] Braun, R. P., Rabinovitz, H. S., Oliviero, M., Kopf, A. W., & Saurat, J. H. (2005). Dermoscopy of pigmented skin lesions. *Journal of the American Academy of Dermatology*, 52(1), 109-121.
- [3] Argenziano, G., Soyer, H. P., Chimenti, S., Talamini, R., Corona, R., Sera, F., ... & Kopf, A. W. (2003). Dermoscopy of pigmented skin lesions: results of a consensus meeting via the Internet. *Journal of the American Academy of Dermatology*, 48(5), 679-693.
- [4] Kittler, H., Pehamberger, H., Wolff, K., & Binder, M. J. T. I. O. (2002). Diagnostic accuracy of dermoscopy. *The lancet oncology*, 3(3), 159-165.
- [5] Vestergaard, M. E., Macaskill, P. H. P. M., Holt, P. E., & Menzies, S. W. (2008). Dermoscopy compared with naked eye examination for the diagnosis of primary melanoma: a meta-analysis of studies performed in a clinical setting. *British Journal of Dermatology*, 159(3), 669-676.
- [6] Prathiba, M., Jose, D., & Saranya, R. (2019, October). Automated melanoma recognition in dermoscopy images via very deep residual networks. In *IOP Conference Series: Materials Science and Engineering* (Vol. 561, No. 1, p. 012107). IOP Publishing.
- [7] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [8] Özbay, E. (2022). An active deep learning method for diabetic retinopathy detection in segmented fundus images using artificial bee colony algorithm. *Artificial Intelligence Review*, 1-28. <https://doi.org/10.1007/s10462-022-10231-3>
- [9] Harangi, B. (2018). Skin lesion classification with ensembles of deep convolutional neural networks. *Journal of biomedical informatics*, 86, 25-32.
- [10] Almaraz-Damian, J. A., Ponomaryov, V., Sadovnychiy, S., & Castillejos-Fernandez, H. (2020). Melanoma and nevus skin lesion classification using handcraft and deep learning feature fusion via mutual information measures. *Entropy*, 22(4), 484.
- [11] Ameri, A. (2020). A deep learning approach to skin cancer detection in dermoscopy images. *Journal of Biomedical Physics and Engineering*, 10(6), 801-806.
- [12] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- [13] Moldovanu, S., Obreja, C. D., Biswas, K. C., & Moraru, L. (2021). Towards accurate diagnosis of skin lesions using feedforward back propagation neural networks. *Diagnostics*, 11(6), 936.
- [14] Bakheet, S. (2017). An SVM framework for malignant melanoma detection based on optimized HOG features. *Computation*, 5(1), 4.
- [15] Monisha, M., Suresh, A., Babu, B. R., & Rashmi, M. R. (2019). Classification of malignant melanoma and benign skin lesion by using back propagation neural network and ABCD rule. *Cluster Computing*, 22(5), 12897-12907.
- [16] Ge, Z., Demyanov, S., Bozorgtabar, B., Abedini, M., Chakravorty, R., Bowling, A., & Garnavi, R. (2017, April). Exploiting local and generic features for accurate skin lesions classification using clinical and dermoscopy imaging. In *2017 IEEE 14th international symposium on biomedical imaging (ISBI 2017)* (pp. 986-990). IEEE.

- [17] Moura, N., Veras, R., Aires, K., Machado, V., Silva, R., Araújo, F., & Claro, M. (2019). ABCD rule and pre-trained CNNs for melanoma diagnosis. *Multimedia Tools and Applications*, 78(6), 6869-6888.
- [18] Khan, M. A., Sharif, M., Akram, T., Bukhari, S. A. C., & Nayak, R. S. (2020). Developed Newton-Raphson based deep features selection framework for skin lesion recognition. *Pattern Recognition Letters*, 129, 293-303.
- [19] Naeem, A., Farooq, M. S., Khelifi, A., & Abid, A. (2020). Malignant melanoma classification using deep learning: datasets, performance measurements, challenges and opportunities. *IEEE Access*, 8, 110575-110597.
- [20] Adegun, A., & Viriri, S. (2020, February). Deep convolutional network-based framework for melanoma lesion detection and segmentation. In *International Conference on Advanced Concepts for Intelligent Vision Systems* (pp. 51-62). Springer, Cham.
- [21] Salih, O., & Viriri, S. (2020). Skin lesion segmentation using local binary convolution-deconvolution architecture. *Image Analysis & Stereology*, 39(3), 169-185.
- [22] Ameri, A. (2020). A deep learning approach to skin cancer detection in dermoscopy images. *Journal of Biomedical Physics and Engineering*, 10(6), 801-806.
- [23] Chaturvedi, S. S., Tembhrane, J. V., & Diwan, T. (2020). A multi-class skin Cancer classification using deep convolutional neural networks. *Multimedia Tools and Applications*, 79(39), 28477-28498.
- [24] Lee, Y. C., Jung, S. H., & Won, H. H. (2018). WonDerM: Skin lesion classification with fine-tuned neural networks. *arXiv preprint arXiv:1808.03426*.
- [25] Mahbod, A., Schaefer, G., Wang, C., Ecker, R., & Elling, I. (2019, May). Skin lesion classification using hybrid deep neural networks. In *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1229-1233). IEEE.
- [26] Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- [27] Tschandl, P., Rosendahl, C., & Kittler, H. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific data*, 5(1), 1-9.
- [28] Codella, N. C., Gutman, D., Celebi, M. E., Helba, B., Marchetti, M. A., Dusza, S. W., ... & Halpern, A. (2018, April). Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (isbi), hosted by the international skin imaging collaboration (isic). In *2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018)* (pp. 168-172). IEEE.
- [29] Combalia, M., Codella, N. C., Rotemberg, V., Helba, B., Vilaplana, V., Reiter, O., ... & Malveyh, J. (2019). Bcn20000: Dermoscopic lesions in the wild. *arXiv preprint arXiv:1908.02288*.
- [30] Zhang, Y., Qiu, Z., Yao, T., Liu, D., & Mei, T. (2018). Fully convolutional adaptation networks for semantic segmentation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 6810-6818).
- [31] Johnson, J. M., & Khoshgoftaar, T. M. (2019). Survey on deep learning with class imbalance. *Journal of Big Data*, 6(1), 1-54.
- [32] LeCun, Y., Kavukcuoglu, K., & Farabet, C. (2010, May). Convolutional networks and applications in vision. In *Proceedings of 2010 IEEE international symposium on circuits and systems* (pp. 253-256). IEEE.
- [33] Hijazi, S., Kumar, R., & Rowen, C. (2015). Using convolutional neural networks for image recognition. *Cadence Design Systems Inc.: San Jose, CA, USA*, 9.
- [34] Shi, Y. (2001, May). Particle swarm optimization: developments, applications and resources. In *Proceedings of the 2001 congress on evolutionary computation (IEEE Cat. No. 01TH8546)* (Vol. 1, pp. 81-86). IEEE.
- [35] Eberhart, R. C., & Shi, Y. (2000, July). Comparing inertia weights and constriction factors in particle swarm optimization. In *Proceedings of the 2000 congress on evolutionary computation. CEC00 (Cat. No. 00TH8512)* (Vol. 1, pp. 84-88). IEEE.
- [36] García, S., Fernández, A., Luengo, J., & Herrera, F. (2009). A study of statistical techniques and performance measures for genetics-based machine learning: accuracy and interpretability. *Soft Computing*, 13(10), 959-977.
- [37] Cai, X., Cui, Z., Zeng, J., & Tan, Y. (2009). Individual parameter selection strategy for particle swarm optimization. *Particle swarm optimization*, 978-953.
- [38] Rubinstein, R. Y., & Kroese, D. P. (2004). *The cross-entropy method: a unified approach to combinatorial optimization, Monte-Carlo simulation, and machine learning* (Vol. 133). New York: Springer.
- [39] Özbay, E., & Özbay, F. A. (2021). A CNN Framework for Classification of Melanoma and Benign Lesions on Dermoscopic Skin Images. *International Journal of Advanced Networking and Applications*, 13(2), 4874-4883.
- [40] Li, J., Cheng, J. H., Shi, J. Y., & Huang, F. (2012). Brief introduction of back propagation (BP) neural network algorithm and its improvement. In *Advances in computer science and information engineering* (pp. 553-558). Springer, Berlin, Heidelberg.
- [41] Refaeilzadeh, P., Tang, L., & Liu, H. (2009). Cross-validation. *Encyclopedia of database systems*, 5, 532-538.
- [42] Balasubramanian, K., & Ananthamoorthy, N. P. (2021). Improved adaptive neuro-fuzzy inference system based on modified glowworm swarm and differential evolution optimization algorithm for medical diagnosis. *Neural Computing and Applications*, 33(13), 7649-7660.

- [43] Xie, F., Yang, J., Liu, J., Jiang, Z., Zheng, Y., & Wang, Y. (2020). Skin lesion segmentation using high-resolution convolutional neural network. *Computer methods and programs in biomedicine*, 186, 105241.
- [44] Shahin, A. H., Kamal, A., & Elattar, M. A. (2018, December). Deep ensemble learning for skin lesion classification from dermoscopic images. In *2018 9th Cairo International Biomedical Engineering Conference (CIBEC)* (pp. 150-153). IEEE.
- [45] Khan, M. A., Javed, M. Y., Sharif, M., Saba, T., & Rehman, A. (2019, April). Multi-model deep neural network based features extraction and optimal selection approach for skin lesion classification. In *2019 international conference on computer and information sciences (ICCIS)* (pp. 1-7). IEEE.
- [46] Liu, L., Mou, L., Zhu, X. X., & Mandal, M. (2020). Automatic skin lesion classification based on mid-level feature learning. *Computerized Medical Imaging and Graphics*, 84, 101765.
- [47] Pour, M. P., & Seker, H. (2020). Transform domain representation-driven convolutional neural networks for skin lesion segmentation. *Expert Systems with Applications*, 144, 113129.
- [48] Al-Masni, M. A., Al-Antari, M. A., Choi, M. T., Han, S. M., & Kim, T. S. (2018). Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks. *Computer methods and programs in biomedicine*, 162, 221-231.
- [49] Serte, S., & Demirel, H. (2019). Gabor wavelet-based deep learning for skin lesion classification. *Computers in biology and medicine*, 113, 103423.
- [50] Dash, M., Londhe, N. D., Ghosh, S., Semwal, A., & Sonawane, R. S. (2019). PsLSNet: Automated psoriasis skin lesion segmentation using modified U-Net-based fully convolutional network. *Biomedical Signal Processing and Control*, 52, 226-237.
- [51] Li, W., Raj, A. N. J., Tjahjadi, T., & Zhuang, Z. (2021). Digital hair removal by deep learning for skin lesion segmentation. *Pattern Recognition*, 117, 107994.
- [52] Cengil, E., Çinar, A., & Yildirim, M. (2021). Hybrid Convolutional Neural Network Architectures For Skin Cancer Classification. *Avrupa Bilim Ve Teknoloji Dergisi*, (28), 694-701.
- [53] Yildirim, M., & Çinar, A. (2021). Classification Of Skin Cancer Images With Convolutional Neural Network Architectures. *Turkish Journal Of Science And Technology*, 16(2), 187-195.