

---

*Araştırma Makalesi / Research Article*

---

## **Sıtma Hastalığının Sınıflandırılmasında Evrimsel Sinir Ağlarının Performanslarının Karşılaştırılması**

Aykut DİKER\*

*Bandırma Onyedli Eylül Üniversitesi, Yazılım Mühendisliği Bölümü, Bandırma, Balıkesir  
(ORCID: 0000-0002-1207-8548)*

---

### **Öz**

Sıtma, Plasmodium adlı bir kan parazitinin neden olduğu ciddi bir hastalıktır. Sıtma teşhis etmenin standart yolu, parazit bulaşmış kırmızı kan hücreleri için kan bulaşmalarını mikroskop altında uzmanlar tarafından görsel olarak incelenmesidir. Bu yöntem verimsizdir ve tanı, muayeneyi yapan kişinin deneyimine ve bilgisine bağlıdır. Daha önce teşhis için sıtma kan hücrelerine makine öğrenimine dayalı otomatik görüntü tanıma teknolojileri uygulanmıştır. Bu çalışmanın amacı, sıtma hücrelerinin parazit veya enfekte olmayan olarak ayırmaktır. Ek olarak çalışmada, önceden eğitilmiş evrimsel sinir ağlarına dayalı bütünlük bir tanı sistemi önerilmiştir. Bu çalışmada sıtma hücrelerini sınıflandırmak için Ulusal Sağlık Enstitüleri'nden (NIH) elde edilen toplam 27558 imge kullanılmıştır. Deneysel çalışmalar sonucunda, sıtma hücrelerinin sınıflandırılmasında, sırasıyla AlexNet, GoogleNet, SqueezeNet, ShuffleNet ESA modelleri ile % 95.77, % 96.31, % 95.95, % 96.44 ve 0.9880, 0.9887, 0.9888, 0.9923 EAA performans değerleri elde edilmiştir. Sıtma hücrelerinin sınıflandırılmasında en iyi sonuç, %96.44 Doğruluk değeri ile ShuffleNet CNN modeli kullanılarak ulaşılmıştır.

**Anahtar kelimeler:** Sıtma, sınıflandırma, evrimsel sinir ağı.

---

## **Performances Comparison of Convolutional Neural Networks in the Classification of Malaria Disease**

---

### **Abstract**

Malaria is a serious disease caused by a blood parasite named Plasmodium. The standard way of diagnosing malaria is by visually examining blood smears for parasite-infected red blood cells under the microscope by qualified technicians. This method is inefficient and the diagnosis depends on the experience and the knowledge of the person doing the examination. The aim of this study is to separate malaria cells as parasites or non-infected. Additionally, an integrated diagnostic system based on pre-trained convolutional neural networks is proposed in the study. In this study, a total of 27558 images obtained from the National Institutes of Health (NIH) were used to classify malaria cells. As a result of experimental studies, 95.77%, 96.31%, 95.95%, 96.44% and 0.9880, 0.9887, 0.9888, 0.9923 AUC performance values were obtained in the classification of malaria cells with AlexNet, GoogleNet, SqueezeNet, ShuffleNet CNN models, respectively. The best classification result of malaria cells was achieved using the ShuffleNet CNN model with an Accuracy of 96.44%.

**Keywords:** Malaria, classification, convolutional neural network.

---

### **1. Giriş**

Sıtma, dünya nüfusunu etkileyen en yaygın, korunmasız hastalıkların başında gelmektedir. Sıtma, enfekte sivrisineklerin ısırıkları yoluyla bulaşan parazitlerden kaynaklanmaktadır. Ayrıca, özellikle tropikal bölgelerde endemik bir hastalık ve başlıca ölüm nedeni olarak sayılmaktadır. Küresel olarak, 97 ülke ve bölgede 3,2 milyar insanın sıtmaya yakalanma riski bulunmaktadır ve 1,2 milyar kişi yüksek risk altında yaşamını sürdürmektedir [1-3]. Sıtma hastalığı plazmodyumun bir türü olarak bilinmektedir. İnsanın alyuvarını tehdit eden ve bir dizi belirtiyeye neden olabilen bir tür parazitik protozoandır [1]. Sıtma

---

\*Sorumlu yazar: [aykurdiker@gmail.com](mailto:aykurdiker@gmail.com)


Geliş Tarihi: 20.08.2020, Kabul Tarihi: 19.10.2020

hastalığının klinik belirtileri nonspesifiktir ve sıtmayla uyumlu klinik semptomların eşlik ettiği parazitemi, özellikle endemik bölgelerde mutlaka klinik sıtma anlamına gelmemektedir. Endemik bölgelerdeki hastalığı tespit etmek için, klinik sıtmanın net bir vaka tanımına ihtiyaç vardır. Endemik olmayan bölgelerde, ateşin eşlik ettiği periferik parazitemi klinik sıtmayı tanımlamak için kullanılabilirken, endemik bölgelerde bu böyle değildir çünkü bireylerin % 60'ından fazlası her zaman asemptomatik parazitemiye sahip olabilmektedir [4]. Sıtma hastalığının ciddiyetini kavramak ve hastalığı önlemek için erken tanı testi ve tedavisi hayati öneme sahiptir. Sıtma tedavisinin risk faktörü, uzmanlık ve araştırmacı bilim insanlarının eksikliği nedeniyle hala aşılmakta güçlük çekilen sorunların başında gelmektedir. Sıtma hastalığının erken tespiti, sıtmanın neden olduğu ölümü kontrol etmek için gerekli olan konuların başında gelmektedir. Bu noktada, bilgisayar destekli sistemler, Yapay zeka, açık kaynaklı araçlar, teknikler bu hastalığın tespiti ve değerlendirilmesi için uzmanlar için eşsiz bir araç haline gelmiştir [5]. Sıtma hastalığının sınıflandırılmasında ve tespitinde literatürde birçok yöntem kullanılmıştır. Bunlar; Destek Vektör Makine (DVM) [6], k- En Yakın Komşuluk algoritması (k-Ek) [7], Yapay Sinir Ağları (YSA) [8], AdaBoost algoritması [9], Otsu metodu [2], Çok Katmanlı Algılayıcı (ÇKA) [10], İstatistiksel olarak geliştirilmiş kural tabanlı sınıflandırma metodu [11], Radyal tabanlı fonksiyon sınıflandırıcı [12], İnce ayarlı Evrişimsel Sinir Ağları (ESA) modeli [13] ve literatürde birçok alanda kullanılan Derin öğrenme algoritmaları [5, 14]. Aynı zamanda son yıllarda, literatürde popüler hale gelen derin öğrenme yöntemi, sıtma hastalığının sınıflandırılmasında olduğu gibi, birçok alanda kullanılmaktadır [15,16]. Bu çalışmada, sıtma hastalığının sınıflandırılması ve teşhisi için derin bir öğrenme yaklaşımlarının bir performans karşılaştırılmasının sunulması üzerine odaklanılmıştır. Bu amaçla, önceden eğitilmiş ESA modellerinden olan AlexNet [17], GoogleNet [18], ShuffleNet [19] ve SqueezeNet [20,21] kullanılmıştır. Amaç, kan hücresi görüntülerini “Parazit” veya “Enfekte olmayan” olarak sınıflandırmaktır. Aynı zamanda, önerilen çalışmanın ana hedeflerinden biri de kandaki sıtma paraziti sınıflandırmak için yukarıda bahsedilen en uygun ESA modelini belirlemektir.

Çalışmanın diğer bölümleri şu şekilde organize edilmiştir: Bölüm 2’de çalışmaya konu olan veri seti ve kullanılan yöntemler verilmiştir. Bölüm 3’de ise elde edilen deneysel sonuçlar sunulmuştur. Bölüm 4’de ise deneysel parametreler ve ilgili çalışmalar dikkate alınarak bir tartışma sunulmuştur. Bölüm 5’de ise sonuç ifadeleri sunulmuştur.

## 2. Materyal ve Metot


Bu çalışmada toplamda 2 sınıftan oluşan sıtma hastalığının sınıflandırılması için evrişimsel sinir ağlarına dayalı bir model önerisi yapılmıştır. Önerilen modelin blok şemasına Şekil 1’de yer verilmiştir.



Şekil 1. Önerilen sistemin blok diyagramı

Şekil 1’den görüldüğü gibi alınan sıtma hücreleri ön işlem sürecinde, imgenin algılanan renginin farklı aydınlatma koşullarında aynı kalmasını sağlamak için renk sabitleme tekniği kullanılmıştır [22]. Aynı zamanda ESA modellerinin girişine verilmek üzere uygun hale getirmek için, imgeler üzerinde

yeniden boyutlandırma işlemi yapılmıştır. Veri seti, ESA modellerine verilmek üzere rasgele olarak % 80 Eğitim verisi ve % 20 Test verisi olacak şekilde ayrılmıştır. Sonrasında ise, ESA modellerinden elde edilen modellerle birlikte, kan hücreleri “Parazit” veya “Enfekte olmayan” şeklinde sınıflandırılmıştır. Şekil 2’de ön işlem öncesi ve sonrası kan hücreleri görülmektedir.



Şekil 2. (a) Ön işlem öncesi (b) Ön işlem (Renk sabitleme tekniği kullanılarak) sonrası

## 2.1. Veri Seti

Bu çalışmada kullanılan veriler, Ulusal Sağlık Enstitüleri (National Institutes of Health-NIH) tarafından sağlanan halka açık bir veri tabanından elde edilmiştir. Aynı zamanda, kırmızı kan hücrelerini saptamak ve segmentlere ayırmak için de, seviye ayarlı bir algoritma da sunulmaktadır. Kullanılan tüm imgeler Mahidol-Oxford Tropikal Tıp Araştırma Birimi’nde bir uzman tarafından manuel olarak açıklanmıştır. Veri kümesi, eşit parazit ve enfekte olmamış hücre örneklerine sahip toplam 27.558 hücre imgesi içermektedir [22]. Veri kümesine ait özellikler Tablo 1’de görülmektedir.

Tablo 1. Veri kümesi dağılımı

Veri Seti Türü	Parazitli örneklerin sayısı	Enfekte olmayan örneklerin sayısı
Eğitim	11023	11023
Test	2756	2756

## 2.2. Evrişimsel Sinir Ağları


Evrişimsel Sinir Ağı (ESA) 2012’deki ImageNet yarışmasından bu yana görüntü işleme problemlerinde yaygın olarak kullanılmaktadır. ESA imge sınıflandırma, görüntü tanıma, nesne izleme problemlerinde sıklıkla kullanılır ve yüksek performans değerlerine sahiptir. Bir konvolüsyon katmanında, önceki katmanın özellik haritaları öğrenilebilir çekirdekler haline gelir ve çıktı özelliği haritasını oluşturmak için etkinleştirme işlevini kullanılmaktadır. Her çıktı haritası konvolüsyonları çoklu giriş haritalarıyla birleştirebilmektedir. Genel olarak ESA, Denklem 1’de olduğu gibi formüle edilir.

$$x_j^e = f \left( \sum_{i \in M_j} x_i^{e-1} * k_{ij}^e + b_j^e \right) \quad (1)$$

Burada,  $M_j$  giriş haritasının bir seçimini temsil eder. Çıktı haritası  $j$  ve harita  $k$  her ikisi de girdi haritası  $i$  üzerinde toplanır, harita  $i$ ’ye uygulanan çekirdekler çıktı haritaları  $j$  ve  $k$  için farklıdır [18,19]. ESA’nın kapsamlı matematiksel ifadelerini edinmek için referans [23] incelenebilir. Bu çalışmada kullanılan ESA modelleri ve özellikleri sonraki bölümlerde verilmiştir.

### 2.2.1. AlexNet


Derin öğrenme algoritmaları kullanılarak tasarlanan AlexNet, 2012 yılında ImageNet yarışmasını kazandığında dünya çapında tanınmıştır. Daha sonra “Derin Konvolüsyon Ağları ile ImageNet Sınıflandırması” başlıklı makalede bu ESA modeli yayınlanmıştır [23]. AlexNet mimarisi beş evrişim katmanı, havuzlama katmanı ve üç Tamamen Bağlı (Fully Connected) katmanından oluşmaktadır. AlexNet’in grafik gösterimi Şekil 3’de verilmiştir [17].



Şekil 3. AlexNet modelinin blok mimarisi

### 2.2.2. GoogleNet


GoogleNet, yapısı içindeki başlangıç modülleri nedeniyle karmaşık bir mimariye sahip bir ESA modelidir. 22 katmanı bulunmaktadır ve 2014 yılında % 5.7 hata oranı ile ImageNet yarışmasını kazanmıştır. Genellikle konvolüsyonel ve biriktirilmiş katmanları ardışık olarak yığmaktan kaçınan ilk ESA mimarilerinden biri olarak düşünülmektedir. Ayrıca, tüm katmanları yığmaktan kaçınmak ve çeşitli filtreler eklemek zaman alan hesaplamalar gerektireceğinden, daha yüksek bellek maliyetlerine sebep olacağı için bellek ve güç kullanıcıları açısından önemli bir konuma sahiptir [18]. GoogleNet’teki başlangıç modüllerinin grafik gösterimi Şekil 4’te verilmiştir.



Şekil 4. GoogleNet’teki başlangıç modüllerinin blok gösterimi

### 2.2.3. SqueezeNet

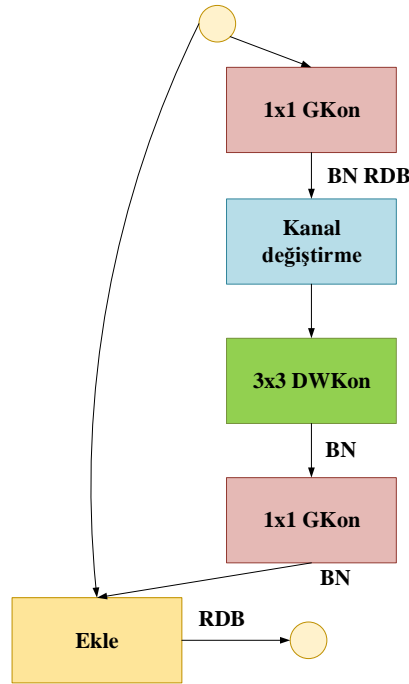
SqueezeNet ESA mimarisi Iandola ve arkadaşları tarafından 2016 yılında tanıtılmıştır. Bağımsız bir konvolüsyon tabakası (kon1), sekiz ateşleme (fire) modülü (ateşleme2–9) ve son konvolüsyon tabakası (kon10) bulunmaktadır. SqueezeNet, AlexNet’in ilk (ilk1) ve en yüksek beş doğruluğunu gerçekleştirirken veya aşarken, AlexNet’e kıyasla model boyutunda 50 kat azalma sağlar [19]. SqueezeNet’in grafik gösterimi Şekil 5’te verilmiştir.



Şekil 5. SqueezeNet modelinin blok gösterimi

### 2.2.4. ShuffleNet

ShuffleNet modeli artık bir yapıdır ve darboğaz yapısını içermektedir. ShuffleNet, diğer ESA mimarilerine kıyasla daha düşük karmaşıklığa ve daha az parametreye sahiptir. Bunun yanında, sadece darboğaz özellik haritasında uygulanan derinlikli konvolüsyon için, düşük güçlü mobil cihazlar için uygundur [24]. ShuffleNet mimarisi Şekil 6'da gösterilmektedir.



Şekil 6. ShuffleNet modelinin blok gösterimi

### 2.3. Performans Ölçütleri

Bu çalışmada modellerin performanslarını ölçmek için karmaşıklık matrisinden türetilen Duyarlılık (Duy), Özgüllük (Özg) ve Doğruluk (Doğ) gibi ve Alıcı işlem karakteristik (AİK) gibi çeşitli performans ölçütleri kullanılmıştır. Bir karmaşıklık matrisi temel olarak Gerçek pozitif (GP), Yanlış pozitif (YP), Gerçek negatif (GN) ve Yanlış negatif (YN) olan dört endeksten oluşmaktadır. GP ve GN, karmaşıklık matrisinin diyagonal ekseninde bulunur, gerçekten tahmin edilen parazit ve enfekte olmamış örneklerin sayılarını temsil etmektedir. YP ve YN endeksleri ise, parazit ve enfekte olmamış örnekler için yanlış teşhis edilen örnek sayısına karşılık gelmektedir [25–27]. Performans metriklerinin matematiksel ifadeleri Denklem (2)-(4)'de sırasıyla verilmiştir.

$$Duy = \frac{(GP)}{(GP + GN)} \quad (2)$$

$$Özg = \frac{(GN)}{(GN + GP)} \quad (3)$$

$$Doğ = \frac{(GP + GN)}{(GP + YP + GN + YN)} \quad (4)$$

Alıcı işlem karakteristiği (AİK) eğrisi, sınıflandırma işlemi için yaygın olarak kullanılan metriklerden birisidir. AİK eğrisinin çiziminde Yanlış pozitif oranlar (YPO) ve Gerçek pozitif oranlar (GPR) sırasıyla x eksenini ve y eksenini üzerinde temsil edilmektedirler. Bu Eğrinin altındaki alan (EAA) modellerin performanslarını değerlendirmek için hesaplanmaktadır. Bu EAA değeri mükemmel bir sınıflandırmayı temsil ettiğinden, EAA için 1'e ulaşmak amaçlanmaktadır [26, 28].

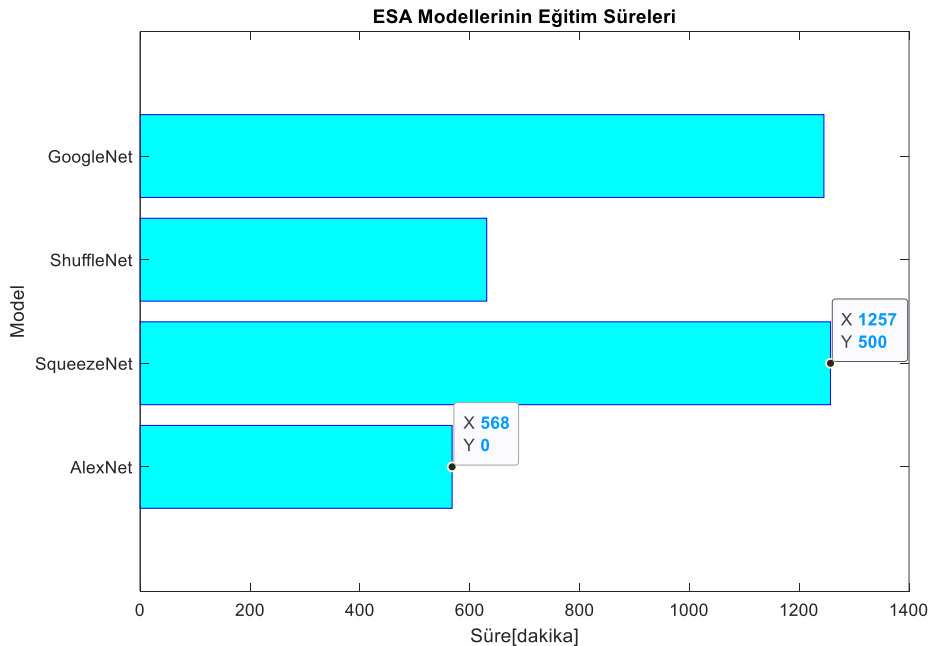
### 3. Bulgular

Tüm deneyler, iş istasyonu üzerinde 2,60 GHz'de Intel © Core CPU, 16 GB RAM ve 2 GB RAM NVIDIA GTX960M grafik kartı ile gerçekleştirilmiştir. Simülasyon platformu olarak ise MATLAB (2019a) kullanılmıştır. Ayrıca, sıtma hücrelerinin ESA modelleri ile yapılan eğitim ve test süresince kullanılan parametreler Tablo 2'de verilmiştir.

**Tablo 2.** ESA modellerinde kullanılan eğitim parametreleri

Parametre	Değer
Mini topluluk boyutu	32
Maksimum dönem	100
Başlangıç öğrenme oranı	1e-4
Optimize yöntemi	sgdm
Momentum	0.90

Sıtma hücrelerinin sınıflandırılması için yapılan deneysel çalışmada, ESA modellerinin başarımları incelenmiştir. ESA modellerini eğitimi testi için veri seti Tablo 1'de belirtildiği gibi % 80 Eğitim ve % 20 test için ayrılmıştır. Mini topluluk boyutu 32 olarak ayarlandığından döngü başına 688 imge kullanılmış ve maksimum dönem sayısı 100 olarak ayarlandığı için eğitim işlemi toplamda 68800 iterasyonda tamamlanmıştır. Şekil 7'de ESA modellerinin sıtma hücrelerinin eğitimi için harcadıkları süreler için grafik verilmiştir. Grafikten de görüleceği üzere AlexNet modeli eğitim için 568 dakika ile en az sürede eğitimi tamamlayan ESA modeli olurken, eğitimi 1257 dakika ile en geç tamamlayan ESA modeli SqueezeNet olduğu grafikten görülmektedir.




**Şekil 7.** ESA modellerinin eğitim için harcadıkları süreler

ESA modellerinin performans sonuçları incelendiğinde en düşük sınıflandırma oranına %95.77 ile AlexNet'in sahip olduğunu, en etkili sınıflandırma doğruluğunu %96.44 ile ShuffleNet modelinin sağladığı görülmüştür. Modellerin sınıflandırma performansında doğruluk değerlerinin yüksek orana sahip olduğu, buna karşılık duyarlılık ve özgüllük oranlarının ise daha düşük olduğu görülmüştür. Buna nedenin, modellere ait olan Şekil 8'de karmaşıklık matrisinin Gerçek Negatif değerinin düşüklüğü olduğu, ayrıca özellik seçimi yöntemi kullanılmadığı için olduğu düşünülmektedir.

**Tablo 3.** ESA modelleri performans sonuçları

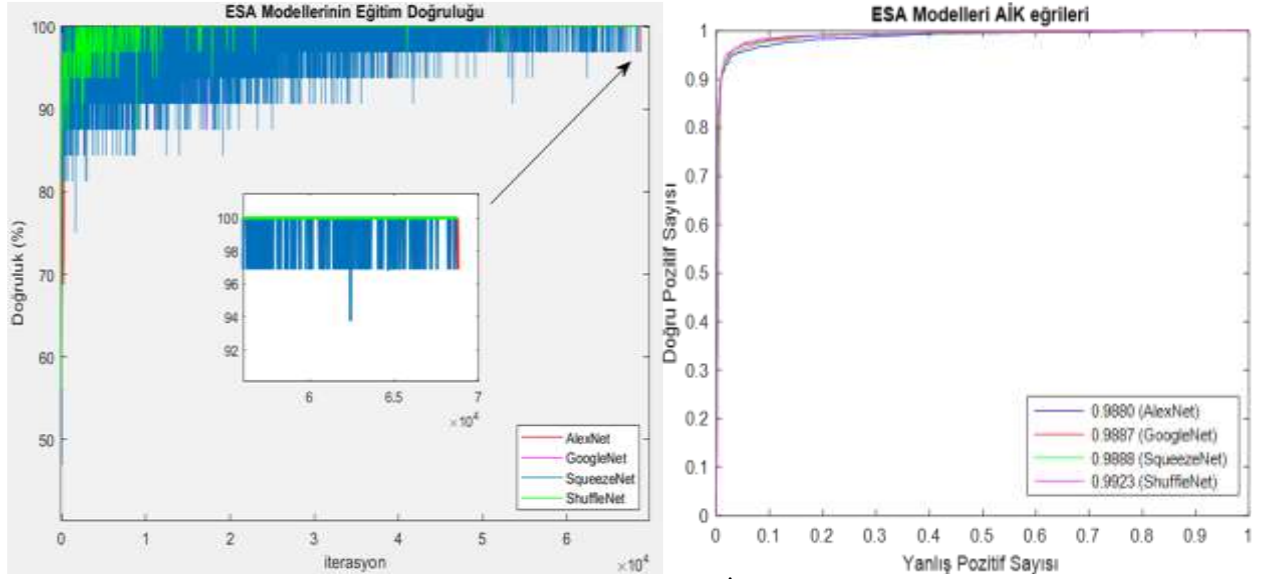
Modeller	Doğruluk	Duyarlılık	Özgüllük
AlexNet	%95.77	%49.10	%50.89
GoogleNet	%96.31	%50	%49.93
SqueezeNet	%95.95	%49.72	%50.27
ShuffleNet	%96.44	%49.52	%50.47

Şekil 8'de ESA modellerine ait karmaşıklık matrisleri verilmiştir. Karmaşıklık matrisleri irdelendiğinde ESA modellerinin sıtma hücrelerinde parazit ve enfekte olmayan hücreleri ayırt etme yeteneklerinin birbirine yakın olduğu görülmüştür. Bu bağlamda, karmaşıklık matrislerinde çapraz parametreler olan GP ve GN değerlerinin, YP ve YN parametrelerine göre daha çok örneği tespit ettikleri sonucu görülmüştür.



**Şekil 8.** ESA modellerinin karmaşıklık matrisleri

Şekil 9’da gösterilen ESA modellerinin sıtma hücrelerinin eğitim doğrulukları grafiği ve AİK eğrileri verilmiştir. Eğitim doğrulukları göz önüne alındığında, AlexNet modelinin yaklaşık 25000. iterasyondan sonra GoogleNet modelinin 27000. iterasyonda sonra, ShuffleNet modelinin 12000. iterasyonda sonra, SqueezeNet modelinin 25000. iterasyondan sonra elde edilen doğruluk değerlerinde kararlı hale geldikleri gözlemlenmiştir. AİK eğrileri örnek sayısından bağımsız olarak modellerin sınıf olarak başarımını görselleştiren ve ölçen metotlardan biridir. Ayrıca Şekil 9’da verilen, ESA modellerinin eğitim doğrulukları grafiğinde modellerin iterasyon son sayıları olan 60000-68800 aralığında aynı seviyeye geldiği grafik üzerinde yapılan yakınlaştırma işlemi neticesinde saptanmıştır. ESA modellerin AİK eğrileri de Şekil 9’da verilmiştir. Buradan hareketle, sıtma hücrelerinin sınıflandırma işlemi, en iyi doğruluk oranı ile ShuffleNet tarafından yapılmıştır ve EAA değeri 0.9923 olarak elde edilmiştir.



Şekil 9. ESA modellerinin Eğitim Doğrulukları, AİK eğrileri ve EAA değerleri

#### 4. Tartışma

Çalışmanın bu bölümünde, sıtma hücrelerinin sınıflandırılmasında yapılan çalışmalara yer verilmiştir. Bu bağlamda, bu çalışmalara ait, veri setindeki örnek sayıları, kullanılan veri seti, sınıf sayıları, sınıflandırma başarı oranları göz önüne alınarak bir Tablo 4’de sunulmuştur.

Tablo 4. ESA modelleri performans sonuçları

Metotlar	Veri seti ve kayıt sayısı	Sınıf sayısı	Sınıflandırıcı başarı oranları
Karar Ağacı, Naive Bayes ,Minimum uzaklık, YSA [29].	CDC (Halk Sağlığı Konusunda Parazitlerin Laboratuvar Tanımı) -165 kayıt	2	% 88
VGG19-DVM [30]	Tagore Tıp Koleji & Hastane ve MAMIC veritabanı-2550 kayıt	2	% 93.1
LeNet-5 [31]	PEIR-VM- 2703 kayıt	2	% 95
AlexNet, ResNet, VGG-16 ve DenseNet [21]	Ulusal Sağlık Enstitüleri-27.558 kayıt	2	Genel doğruluk % 96.60
<b>Bu çalışma Derin Evrimsel Sinir Ağları (ShuffleNet)</b>	<b>Ulusal Sağlık Enstitüleri-27.558 kayıt</b>	<b>2</b>	<b>% 96.44</b>



Tablo 4’de seçilen çalışmalar veri setleri açısından incelendiğinde, deneysel çalışmalarda özel veri setlerinin kullanıldığı ve veri setlerinde yer alan sınıf sayıları dikkate alındığında ise en az iki sınıfa sahip problemler üzerinde çalışmaların yapıldığı görülmektedir. Bu bağlamda, yapılan çalışmada sıtma hücrelerinin sınıflandırmasında ShuffleNet ESA modelinin %96.44 doğruluk oranı elde ettiği görülmektedir. Referans [29]’de toplam 165 enfekte sıtma hücrelerinin mikroskopik kan görüntüleri kullanılarak Karar ağacı sınıflandırıcısı ile saptanması üzerine bir çalışma yapılmıştır. Çalışmada Karar ağacı sınıflandırıcısına ek olarak, Naive Bayes, Minimum uzaklık, YSA metotları da kullanılmıştır. Bir diğer çalışma [30]’da ise enfekte olmuş falciparum sıtma hücrelerini transfer öğrenme yaklaşımı kullanarak tanımlamak için yeni bir derin sinir ağı modeli tanıtılmıştır. Önerilen bu transfer öğrenme yaklaşımı, mevcut VGG ağı ile SVM’nin birleştirilmesiyle elde edilmektedir. Bu yaklaşım ve toplam 2550 kayıt ile %93.1 doğruluk oranı elde edilmiştir.

## 5. Sonuç

Bu çalışmada, sıtma hücrelerinin sınıflandırılması için çeşitli derin öğrenme tabanlı sınıflandırma yaklaşımlarının performans karşılaştırılması sunulmuştur. Bu makalede sunulan tüm sınıflandırma algoritmaları, genel doğruluk ve EAA açısından minimum performans sırasıyla % 95.77 ve 0.9880 olmak üzere nispeten iyi performans göstermiştir. Ayrıca, bu algoritmaların hesaplama (bellek ve zaman) açısından çok süre alması ve daha çok bellek miktarına ihtiyaç duydukları gözlemlenmiştir. Sıtma hücre imgelerini parazit ve enfekte olmamış olarak sınıflandırmak için ESA tabanlı mimarilerin uygulanmasının etkili sonuçlar verdiği gözlemlenmiştir. Transfer öğrenme tabanlı ESA yaklaşımlarının performansı, ESA tabanlı sınıflandırma modellerinin özelliklerin çıkarılmasında iyi olduğu gerçeğini açıkça göstermektedir. Sonuç olarak, sıtma hücrelerinin sınıflandırılmasında, sırasıyla AlexNet, GoogleNet, SqueezeNet, ShuffleNet ESA modelleri ile % 95.77, % 96.31, % 95.95, % 96.44 ve 0.9880, 0.9887, 0.9888, 0.9923 EAA performans değerleri elde edilmiştir. ESA modelleri performans değerleri olarak Tablo 3’den anlaşılacağı üzere en iyi sınıflandırma sonucu, ShuffleNet ESA modeli ile edilmiştir. İleriki çalışmalarda ise, sıtma hücrelerinin sınıflandırılması çalışmaları daha derinlemesine irdelenecektir. Bu kapsamda, literatür çalışmaları derinlemesine incelenip, yeni bir ESA modeli sunulması amaçlanmaktadır.

## Yazarların Katkısı

Çalışmanın tasarlanmasında, uygulamanın yapılması ve yorumlanması %100 yazarın kendisine aittir.

## Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

## Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada, araştırma ve yayın etiğine uyulmuştur.

## Kaynaklar

- [1] Liang Z., Fulfilment P., The OF, For R, Degree THE, Master OF, Arts OF, 2017. Automatic Image Recognition of Rapid Malaria Emergency Diagnosis: A Deep Neural Network Approach Automatic Image Recognition of Rapid Malaria Emergency Diagnosis : a Deep Neural Network Approach. .
- [2] Sunarko B., Djuniadi Bottema M., Iksan N., Hudaya K.A.N., Hanif M.S. 2020. Red blood cell classification on thin blood smear images for malaria diagnosis. J Phys Conf Ser., doi: 10.1088/1742-6596/1444/1/012036.
- [3] Saritha D.S.J. 2019. Classifying Malaria Cell Images Dataset using Machine Learning Algorithms. Int J Res Appl Sci Eng Technol, 7 (4): 2409-2412.
- [4] Afrane Y.A., Zhou G., Githeko A.K., Yan G. 2014. Clinical malaria case definition and malaria attributable fraction in the highlands of western Kenya. doi: 10.1186/1475-2875-13-405.

- [5] Suriya M., Chandran V., Sumithra M.G. 2019. Enhanced deep convolutional neural network for malarial parasite classification. *Int J Comput Appl*, 0 (0): 1-10.
- [6] Bairagi V.K., Charpe K.C. 2016. Comparison of texture features used for classification of life stages of malaria parasite. *Int J Biomed Imaging*. doi: 10.1155/2016/7214156.
- [7] Malihi L., Asl K.A., Behbahani A. 2015. Improvement in Classification Accuracy Rate Using Multiple Classifier Fusion Towards Computer Vision Detection of Malaria Parasite (*Plasmodium vivax*). *Jundishapur J Heal Sci*. doi: 10.5812/jjhs.25114v2.
- [8] Das S., Sony P., Jyothi R.L. 2018. Automated Identification & Classification of Malarial Parasites in Thin Blood Smear Images. *International Research Journal of Engineering and Technology*, 5 (5): 4214-4218.
- [9] Saiprasath G., Nsren Babu R., ArunPriyan J., Vinayakumar R., Sowmya V., Soman kp.; center for computational Engineering and networking, Amrita School of Engineering I., 2019. Performance Comparison of Machine Learning Algorithms for Malaria Detection Using. *Ijar*, 6 (1):86-90.
- [10] Nugroho H.A., Akbar S.A., Murhandarwati E.E.H. 2016. Feature extraction and classification for detection malaria parasites in thin blood smear. In: *ICITACEE 2015 - 2nd Int. Conf. Inf. Technol. Comput. Electr. Eng. Green Technol. Strength. Inf. Technol. Electr. Comput. Eng. Implementation, Proc. IEEE*, 197-201.
- [11] Bbosa F., Wesonga R., Jehopio P. 2016. Clinical malaria diagnosis: rule-based classification statistical prototype. *Springerplus*, doi: 10.1186/s40064-016-2628-0.
- [12] Adebayo A.A., Oguntuyib T., Olabode O., Olumoyed M.Y., Nwaiwu J.C. 2019. Malaria Parasite Classification based on Severity level: A Comparative Evaluation of Sigmoid and Radial Basis Function. *Int J Sci Eng Res*, 10 (7): 1770-1778.
- [13] Krishnan S., Antani S., Jaeger S., 2017. Visualizing Deep Learning Activations for Improved Malaria Cell Classification. *First Work Med Informatics Healthc (MIH 2017)*, PMLR, 40-47.
- [14] Razzak M.I. 2015. Malarial Parasite Classification using Recurrent Neural Network. *Int J Image Process*, 9: 69-79.
- [15] Budak Ü., Cömert Z., Rashid Z.N., Şengür A., Çıbuk M. 2019. Computer-aided diagnosis system combining FCN and Bi-LSTM model for efficient breast cancer detection from histopathological images. *Appl Soft Comput J*, 85: 105765.
- [16] Budak Ü., Cömert Z., Çıbuk M., Şengür A. 2020. DCCMED-Net: Densely connected and concatenated multi Encoder-Decoder CNNs for retinal vessel extraction from fundus images. *Med Hypotheses*. doi: 10.1016/j.mehy.2019.109426.
- [17] Diker A., Avci E. 2019. Feature extraction of ECG signal by using deep feature. *7th Int Symp Digit Forensics Secur ISDFS 2019*. doi: 10.1109/ISDFS.2019.8757522.
- [18] Özyurt F. 2019. Efficient deep feature selection for remote sensing image recognition with fused deep learning architectures. *J Supercomput*. doi: 10.1007/s11227-019-03106-y.
- [19] Zhang X., Zhou X., Lin M., Sun J. 2018. ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognit*, 6848-6856.
- [20] Ucar F., Korkmaz D. 2020. COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Med Hypotheses*, 140 (April): 109761.
- [21] Narayanan B.N., Ali R.A., Hardie R.C. 2019. Performance analysis of machine learning and deep learning architectures for malaria detection on cell images. In: *SPIE-Applications Mach. Learn.* s: 29.
- [22] Cömert Z. 2019. Otitis media için evrimsel sinir ağlarına dayalı entegre bir tanı sistemi. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 8 (4): 1498-1511.
- [23] Krizhevsky A., Sutskever I., Hinton G.E. 2012. ImageNet classification with deep convolutional neural networks. *Adv Neural Inf Process Syst*, 2: 1097-1105.
- [24] Guan C.Z. 2019. Realtime multi-person 2D pose estimation using ShuffleNet. *14th Int Conf Comput Sci Educ ICCSE 2019, (Iccse)*: 17-21.
- [25] Diker A., Cömert Z., Avci E., Velappan S. 2018. Intelligent system based on Genetic Algorithm and support vector machine for detection of myocardial infarction from ECG signals. In: *2018 26th Signal Process. Commun. Appl. Conf.* s: 1-4.
- [26] Diker A., Comert Z., Avci E., Togacar M., Ergen B. 2019. A Novel Application based on

- Spectrogram and Convolutional Neural Network for ECG Classification. 1st Int Informatics Softw Eng Conf Innov Technol Digit Transform IISEC 2019-Proc. doi: 10.1109/UBMYK48245.2019.8965506.
- [27] Diker A., Avcı E., Cömert Z., Avcı D., Kaçar E., Serhatlioğlu İ. 2018. Classification of ECG signal by using machine learning methods. In: 2018 26th Signal Process. Commun. Appl. Conf. s: 1-4.
- [28] Diker A., Cömert Z., Avcı E. 2017. A Diagnostic Model for Identification of Myocardial Infarction from Electrocardiography Signals. Bitlis Eren Univ J Sci Technol, 7 (3): 132-139.
- [29] Muneer S., Khanzada T.J., Jatoi S., Naz B. 2018. Detection of Noisy Blood Images Indicating Prodromal Diseases. International Journal of Latest Trends in Engineering and Technology, 12 (6): 1-6.
- [30] Vijayalakshmi A., Rajesh Kanna B. 2019. Deep learning approach to detect malaria from microscopic images. Multimed Tools Appl. doi: 10.1007/s11042-019-7162-y.
- [31] Pan W.D., Yuhang D., Dongsheng W. 2012. Classification of Malaria-Infected Cells Using Deep Convolutional Neural Networks. Intech, i(tourism): 13.