

Evrişimli Sinir Ağı (ESA) Mimarileri ile Hücre Görüntülerinden Sıtmanın Tespit Edilmesi

Yıldırım ÖZÜPAK*¹ ORCID 0000-0001-8461-8702

¹Dicle Üniversitesi, Silvan Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Diyarbakır

Geliş tarihi: 12.11.2023

Kabul tarihi: 28.03.2024

Atıf şekli/ How to cite: ÖZÜPAK, Y., (2024). Evrişimli Sinir Ağı (ESA) Mimarileri ile Hücre Görüntülerinden Sıtmanın Tespit Edilmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(1), 197-210.

Öz

Sıtma, dünyanın birçok bölgesinde yaygın olarak görülen enfekte sivrisineklerin ısırıkları yoluyla insanlara bulaşan parazitlerin neden olduğu hayatı tehdit eden bir hastalıktır. Plasmodium adlı kan paraziti bu hastalığa sebep olmaktadır. Sıtmanın erken teşhisi ve tedavisi, özellikle hastalığın yaygın olduğu gelişmekte olan ülkelerde, hastalık ve ölüm oranlarının azaltılması açısından çok önemlidir. Sıtma teşhisinde kullanılan klasik yöntem, uzmanlar tarafından kırmızı kan hücrelerinin mikroskop yardımıyla incelenmesiyle tespitidir. Bu yöntem, sadece uzmanın bilgi ve deneyimine dayandığı için verimsizdir. Günümüzde hastalığın yüksek oranda doğru bir şekilde tespiti için makine öğrenmesi yöntemleri kullanılmaktadır. Bu çalışmada, hücreyi parazitli veya parazitsiz olarak tespit için Evrişimli Sinir Ağı (ESA) mimarisi önerilmiştir. Önerilen ESA mimarisine ek olarak VGG-19, InceptionResNetV2, DenseNet121 ve EfficientNetB3 gibi önceden eğitilmiş ESA mimarilerinin performansları ile önerdiğimiz modelin performansı karşılaştırılmıştır. Önerdiğimiz ESA mimarisinde National Institute of Health (NIH) tarafından yayınlanan Sıtma Veri Kümesi kullanılarak deneyler gerçekleştirilmiştir. Mimarimiz %98,9 doğruluk ile çalışmaktadır. Çalışmanın sonuçları, Plasmodium içeren hücre görüntülerinin doğruluğunu artırmada etkili olduğunu göstermektedir.

Anahtar Kelimeler: Sıtma, ESA, Önceden eğitilmiş model, Hastalık tespiti

Detection of Malaria with Convolutional Neural Network (CNN) Architectures Using Cell Images

Abstract

This article highlights that malaria is widespread worldwide through infected mosquitoes transmitted to humans and is caused by the blood parasite Plasmodium. Early diagnosis and treatment of malaria plays an important role in reducing morbidity and mortality, especially in developing countries. The traditional method of diagnosing malaria involves examining red blood cells under a microscope, but this method can be inefficient as it relies on expert knowledge. A highlight of the paper is the use of machine learning methods in malaria diagnosis. In particular, a Convolutional Neural Network (CNN) architecture is

*Sorumlu yazar (Corresponding Author): Yıldırım ÖZÜPAK, yildirimosupak@gmail.com

proposed to detect parasitized and non-parasitized cells. Furthermore, the performance of this proposed model is compared with pre-trained CNN architectures such as VGG-19, InceptionResNetV2, DenseNet121 and EfficientNetB3. In the experiments, the Malaria Dataset published by the National Institute of Health (NIH) was used and the proposed CNN architecture achieved 98.9% accuracy. These results show that the proposed model is effective in accurately recognizing cell images containing Plasmodium. This study highlights the potential of AI-based methods in the field of malaria diagnosis.

Keywords: Malaria, CNN, Pre-trained model, Disease detection

1. GİRİŞ

Doğu Sıtma, dünya çapında hala sağlık sistemlerini tehdit eden ve özellikle gelişmekte olan ülkelerde milyonlarca insanı etkileyen bir hastalıktır. Hastalık enfekte olmuş sivrisineklerin ısırması yoluyla bulaşan Plasmodium parazitlerden kaynaklanmaktadır. Plasmodium'un en az 150 türü bilinmesine rağmen bunlardan yalnızca birkaçı insanları enfekte edebilir. Plasmodium parazitlerinin neden olduğu bu hastalık, zamanında tedavi edilmezse çocuklar başta olmak üzere birçok insanın ölümüne neden olabilmektedir [1-3]. Tüm sıtma vakalarının yaklaşık %95'i ve sıtmaya bağlı ölümlerin %96'ü Dünya Sağlık Örgütü'nün (DSÖ) 2021 yılı verilerine göre Afrika Bölgesi'nde meydana gelmektedir. Sıtmadan en çok etkilenenler ise beş yaşın altındaki çocuklardır. Sıtmanın tanısı ve tedavisi, hastalığın yayılmasını kontrol etmek ve insan hayatını kurtarmak için hayati öneme sahiptir [1,4].

Geleneksel sıtma tanı yöntemleri, mikroskopik inceleme ve laboratuvar testleri gibi emek yoğun ve maliyetli süreçleri içermektedir. Sıtma hastalığının klinik belirtileri genellikle belirsizdir, bu nedenle hastalığın ciddiyetini anlamak ve önlemek için erken tanı testleri ve tedavi önem arz etmektedir. Sıtma tedavisindeki zorluklar, uzmanlık eksikliği ve sınırlı sayıda araştırmacı bilim insanının bulunması gibi faktörlere dayanmaktadır [5,6]. Sıtma hastalığının erken teşhisi, hastalığın neden olduğu ölümleri kontrol etmek adına kritik bir öneme sahiptir. Bu bağlamda, bilgisayar destekli sistemler, yapay zeka, açık kaynaklı araçlar ve teknikler, sıtmanın tespiti ve değerlendirilmesi için uzmanlar arasında önemli bir yardımcı araç haline gelmiştir. Bu ilerlemeler, sıtma hastalığıyla mücadelede daha etkili ve erişilebilir çözümlerin geliştirilmesine katkı sağlayabilir. [7]. Özellikle son

yıllarda Derin Öğrenme (DL) ve Makine Öğrenme (ML) teknikleri, sıtma tanısı alanında büyük bir potansiyel sunmaktadır. Bu teknolojiler, büyük veri kümelerini işleme, karmaşık desenleri tanıma ve hızlı bir şekilde tanı koyma yetenekleri sayesinde sıtma tanısı için büyük imkân sağlamaktadırlar [8,9]. Tespit ve teşhis araçları doktorlara değerli bir ikinci görüş sunmakta ve tarama sürecinde onlara yardımcı olmaktadır [10]. Tıbbi görüntüleme Bilgisayar Destekli Tespit (CAD) ve teşhis, son on yılda büyük ilgi gören bir araştırma alanı olmuştur. Bu sistemler, büyük veri kümesinde Plasmodium parazitlerini tanımak amacıyla eğitildikleri için insan hatalarını en aza indirebilirler ve sonuçları daha hızlı bir şekilde üretebilirler [11].

Patologlar, teşhis süresini azaltan otomatik bir teşhis yönteminden ikinci bir görüş alabilirler. Tıbbi veriler makine öğrenimi yöntemleri kullanılarak analiz edilebilir. ML yöntemleri, sıtma semptomları açısından nüfusu izlemek için kullanılabilir. Bir katmanlama sistemindeki doğrusal olmayan işlem birimi seviyelerini içeren DL modelleri, ham verilerdeki yapıları ortaya çıkarmak için kullanılabilir. Öğrenme söz konusu olduğunda, dinamik ve doğrusal olmayan karar verme süreçleri, düşük seviyeli bileşenlerden sofistike özelliklerin kullanılmasını gerektirir [12].

Tıbbi görüntüleme alanında CAD için literatürde çeşitli Yapay Zekâ (AI) yöntemleri önerilmiştir. Yapay Zekâ atılımları, örnekleri insan gözünden daha hızlı ve doğru bir şekilde analiz etmeyi mümkün kılmıştır. ML ve DL teknikleri tıbbi görüntü kategorizasyonunda yaygın olarak kullanılmaktadır. Tıbbi cihazlar DL yöntemlerini benimsemeye başlamıştır [13,14]. Kan hücrelerindeki sıtma parazitleri mikroskop görüntüleri ve benzer DL yöntemleri kullanılarak tespit edilmektedir. Bu görüntüler tipik olarak ince

veya kalın kan yaymalarının görüntü grafikleri kullanılarak oluşturulur. Sonuç olarak, kırmızı kan hücrelerinin yoğun tabakası nedeniyle geniş noktaların parazitlerle istila edilme olasılığı daha yüksektir. Bu nedenle, kalın yayma teknikleri kan hücrelerindeki sıtma parazitlerini daha doğru bir şekilde tespit edebilir. Çok ince oldukları için yaymalarda ince bir kan tabakası görülebilir. Doktorlar bu yöntemleri genellikle sıtmanın çeşitli evrelerini ayırt etmek için kullanırlar. Her iki yöntem de yaymaların kalitesine ve kanseri doğru bir şekilde teşhis etmek için insan becerisinin seviyesine dayanır. Ancak DL tabanlı algoritmalar, hem ince hem de kalın yaymaların sıtmayı tanımlamak için verimli bir şekilde kullanılabileceğini göstermiştir [15,16]. CNN'in her katmanı için bir görüntüye belirli bir aktivasyon fonksiyonu uygulanır. Bir görüntünün lekeler, kenarlar ve renkler gibi temel özellikleri CNN'in ilk katmanından çıkarılır ve derin iç katmanlar tarafından üst düzey özelliklere dönüştürülür [17]. DL modellerini klinik karar verme sürecine dahil etmek için dünya çapında birçok araştırma projesi sunulmuştur. Son yıllarda, DL algoritmalarının sağlık sektöründe uygulanmasında bir genişleme olmuştur. Sıtma teşhisi için CNN kullanan ilk çalışmalardan biri Liang ve arkadaşlarına aittir [18]. İnce kan yayma görüntü hücrelerini elde etmek için geleneksel optik mikroskop lamları kullanılmış, ardından benzersiz bir CNN modeli kullanılarak sınıflandırılmıştır. Daha "geleneksel" transfer modellerinden daha iyi performans göstermişlerdir (%97,37 doğruluk). Quan ve diğerleri tarafından geliştirilen CNN tabanlı model, yoğun ve artık ağlardan gelen ilkeleri ve dikkati yönlendirme mekanizmalarını içermektedir. Önerilen yöntem bir Dikkatli Yoğun Dairesel Ağ (ACDN) idi. Sonuçlar önceki çalışmalarla karşılaştırılmıştır. DenseNet121 ve DPN92 sırasıyla %90,94 ve %87,88 sonuç veririrken, bu algoritma %97,47'lik üstün bir performans elde etmiştir. Hassasiyet ve yakınsama ACDN modelinin güçlü noktalarıdır [19]. Rajaraman ve arkadaşları, sınıflandırma için özellik çıkarıcı olarak önceden eğitilmiş CNN tabanlı DL algoritmalarını kullanmışlardır. Algoritmalar ne kadar iyi çalıştıklarını görmek için test edilmiştir. Altı farklı mimariye kadar bu modeller temel alınmış ve özel modeller olarak kullanılmıştır. Kesinlik %91 ila %95 arasında doğru

çıktı. ResNet ve VGG16 rakiplerinden daha iyi performans gösterdi. Zaten eğitilmiş olan CNN'leri kullanmanın özellikleri keşfetmek için harika bir yol olduğuna inanıyorlar [20].


Mikroskobik görüntüler kullanılarak farklı sınıflardaki sıtma parazitlerinin tespiti ve sınıflandırılması için yapay zeka tabanlı yaklaşımlar üzerine incelemeler yapılmıştır [21]. Tasarlanan ViT modeli ile %93,97 doğrulama doğruluğu ve %90,03 test doğruluğu ile iyi performans elde edilmiştir. Performansın daha iyi değerlendirilmesi için farklı derin öğrenme ağları ile karşılaştırılmıştır [22]. Derin öğrenme kullanılarak sıtma hastalığının tespiti ve analizi için derin öğrenmeli evrişimli sinir ağları modeli kullanılarak %95,23 doğruluk oranına sahip sonuçlar elde edilmiştir. Bu modelde rastgele seçilen 16 görüntüden 15'inin doğru tahmin edildiği ifade edilmiştir [23]. Nesne algılama modelleri kullanılarak sıtmanın sınıflandırılması üzerine yapılan bir çalışmada ölçeklendirilmiş YOLOv4 %83'lük doğruluk oranıyla ilk sırada yer alırken, onu %78,5'lik doğruluk oranıyla YOLOv5 takip etmiştir [24]. Derin öğrenme algoritmalarına dayalı sıtma paraziti tespiti (CNNs) tekniği üzerine çalışmalar yapılmıştır [25].

Bu çalışma, geleneksel sıtma tanı yöntemlerinin ötesine geçerek, derin öğrenme ve makine öğrenme model mimarilerinin performansını değerlendirmeyi amaçlamaktadır. Bu teknolojilerin klinik uygulamalarda nasıl kullanılacağı ve sıtma tanısının doğruluğunu artırabileceği konusunda derinlemesine bir inceleme sunulmuştur. Veri setinin eğitilmesi sonucunda aldığımız sonuçlar doğrultusunda hücre görüntüsünün tahminini yapan bir uygulama geliştirilmiştir. Sonuç olarak, sıtma tanısı alanında önemli bir dönüşümün başlangıcını işaret edebilir ve hastalığın erken teşhis edilmesi ve kontrol altına alınmasına büyük katkılar sağlayabilir. Bu makalenin amacı, giriş görüntülerinden gerçek zamanlı sıtma tespitinde etkili ve doğru bir şekilde yararlı olabilecek evrişimli sinir ağı (CNN) gibi derin öğrenme mimarisinin nasıl kullanılacağına göstermek ve bir yazılım uygulaması ile uzmanlara teşhis konusunda yardımcı olmaktır.

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 sonuç ifadelerine yer verilmiştir.

2. YÖNTEM

Bu çalışmada, 2 sınıfa ayrılan sıtma hastalığının sınıflandırılması için evrşimli sinir ağlarına dayalı bir model önerilmiştir. Önerilen modelin blok şeması Şekil 1’de gösterilmiştir.




Şekil 1. Önerilen sistemin blok diyagramı

Önerilen yöntemin doğrulanması amacıyla kullanılan görüntüler, Amerika Birleşik Devletleri'nde Ulusal Sağlık Enstitüleri (NIH) tarafından sağlanan açık erişimli bir veri kümesinden temin edilmiştir. Bu veri kümesi, toplamda 27.558 hücre görüntüsü içermekte olup, parazitli ve parazitsiz hücrelerin eşit örneklerini içermektedir [13]. Tüm görseller, Mahidol-Oxford Tropikal Tıp Araştırma Birimi'nde bir uzman tarafından açıklanmıştır. Veri kümesini eğitim için


%80 ve her bir sınıfa ait test örnekleri için %20 olmak üzere rastgele bölünmüştür. Ayrıca (rastgele seçilen) eğitim veri kümesini eğitim ve doğrulama amaçları için sırasıyla %90 ve %20'lük gruplara ayrılmıştır. Çizelge 1'de eğitim, doğrulama ve test için her bir sınıfa ait görüntülerin dağılımı gösterilmektedir. Veri setinden rastgele alınmış parazitli hücre örnekleri Şekil 2’de parazitsiz hücre örnek görüntüleri Şekil 3’de verilmiştir.

Şekil 1. Önerilen sistemin blok diyagramı

Dataset type	Number of parasitised sample	Number of unparasitised sample	Total
Training Data	8818	8818	17636
Validation Data	2205	2205	4410
Test Data	2756	2756	5512
Total Data			27558



Şekil 2. Parazitli hücre örnekleri




Şekil 3. Parazitsiz hücre örnekleri

2.1. Evrişimsel Sinir Ağları

Evrişimli Sinir Ağları (CNN), bilgisayarlı görüş ve desen tanıma alanlarında kullanılan derin öğrenme modellerinden biridir. Temelde, görsel veriler üzerinde etkili bir şekilde çalışabilen özel bir sinir ağı mimarisidir. CNN'ler, bir görüntüyü küçük,

örtüşen bölgelere bölen ve bu bölgelerdeki özellikleri öğrenen bir dizi evrişim katmanından oluşur. Bu özellikler, girdi görüntülerdeki belirli desenleri temsil eder. Evrişim ve havuzlama katmanları, özellik haritalarını oluşturur ve boyutunu azaltır. Bu sayede, ağ, öğrenme sürecinde daha az parametre kullanarak daha karmaşık özellikleri öğrenebilir. CNN'ler genellikle nesne tanıma, yüz tanıma ve diğer görsel görevlerde başarıyla kullanılır. Şekil 4'te evrişimli sinir ağı mimarisi verilmiştir.



Şekil 4. Evrişimli Sinir Ağı Mimarisi


2.1.1. VGG19

Visual Geometry Group (VGG) tarafından geliştirilen VGG19, derin öğrenme alanındaki evrişimli sinir ağı (CNN) modelleri arasında önemli bir konuma sahiptir. Bu model, 2014 yılında düzenlenen ImageNet Large Scale Visual Recognition Challenge'da etkileyici bir performans sergileyerek geniş çapta tanınmıştır.

VGG19, toplamda 19 katmandan oluşan derin bir mimariye sahiptir. Mimarinin temel özellikleri, ardışık evrişim katmanları ve ardından gelen havuzlama katmanlarından oluşan tekrarlanan bir yapıdır. Özellikle 3x3 filtre boyutlarına sahip evrişim katmanları, küçük boyutlu filtrelerin ardışık kullanımı sayesinde daha karmaşık özellikleri öğrenme yeteneğini artırır. VGG19 modeli, tam bağlantılı katmanlarla sonlanan bir yapıya sahiptir ki bu katmanlar, öğrenilen özellikleri sınıflandırma görevlerinde kullanır. Ayrıca, VGG19'da genellikle ReLU aktivasyon fonksiyonları tercih edilmiştir. Bu model, derin öğrenme topluluğunda başlangıçta kullanılan ve referans alınan modellerden biri olmuştur. Ancak, büyük parametre sayısı ve hesaplama yoğunluğu nedeniyle günümüzde daha

hafif ve ölçeklenebilir modellerin popülerliği artmış olsa da, VGG19 derin öğrenme mimarilerinin

evriminde kritik bir rol oynamıştır [26]. Şekil 5'te VGG19 mimarisinin görseli verilmiştir.



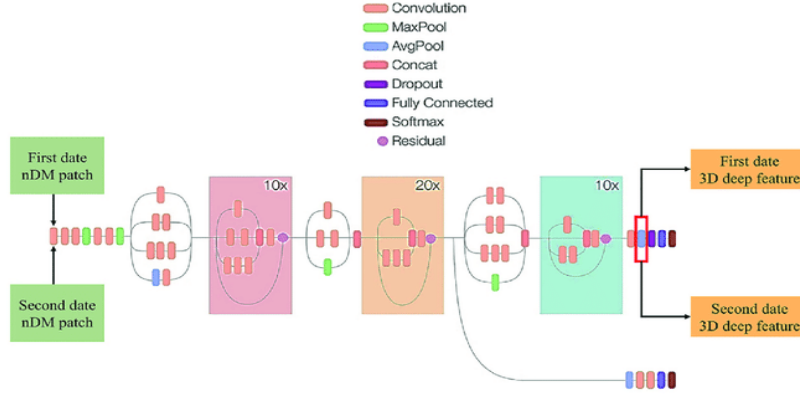
Şekil 5. VGG19 mimarisi

VGG19, toplamda 19 katmandan oluşan derin bir mimariye sahiptir. Mimarinin temel özellikleri, ardışık evrişim katmanları ve ardından gelen havuzlama katmanlarından oluşan tekrarlanan bir yapıdır. Özellikle 3x3 filtre boyutlarına sahip evrişim katmanları, küçük boyutlu filtrelerin ardışık kullanımı sayesinde daha karmaşık özellikleri öğrenme yeteneğini artırır. VGG19 modeli, tam bağlantılı katmanlarla sonlanan bir yapıya sahiptir ki bu katmanlar, öğrenilen özellikleri sınıflandırma görevlerinde kullanır. Ayrıca, VGG19'da genellikle ReLU aktivasyon fonksiyonları tercih edilmiştir. Bu model, derin öğrenme topluluğunda başlangıçta kullanılan ve referans alınan modellerden biri olmuştur. Ancak, büyük parametre sayısı ve hesaplama yoğunluğu nedeniyle günümüzde daha hafif ve ölçeklenebilir modellerin popülerliği artmış olsa da, VGG19 derin öğrenme mimarilerinin evriminde kritik bir rol oynamıştır [26]. Şekil 5'te VGG19 mimarisinin görseli verilmiştir.

2.1.2. InceptionResNetV2

InceptionResNetV2, bilgisayarlı görüş ve derin öğrenme alanında kullanılan gelişmiş bir sinir ağı

modelidir. Google tarafından geliştirilen bu mimari, Inception ve ResNet mimarilerini başarıyla birleştirerek daha etkili ve derin öğrenme yetenekleri sunar. Inception, çok çeşitli paralel evrişim yapılarını içeren bir mimariye sahiptir, bu da farklı ölçeklerdeki özellikleri daha etkili bir şekilde çıkarabilmesini sağlar. ResNet, ağı derinliğini artırmak ve eğitim sırasında kaybolan bilgiyi geri iletmek amacıyla residual blokları kullanır. InceptionResNetV2, bu iki yaklaşımı birleştirir ve hem yatay hem de dikey olarak zengin bir bağlantı ağı kurar. Ayrıca, toplu normalizasyon, ReLU aktivasyon fonksiyonları gibi tekniklerle ağı eğitimi daha stabil hale getirir. InceptionResNetV2, ImageNet veri kümesinde ve diğer görevlerde olağanüstü performans sergileyerek, karmaşık görsel tanıma ve sınıflandırma görevlerinde etkili bir şekilde kullanılacak bir model olarak kabul edilmektedir. Bu model, özellikle derin öğrenme topluluğunda, büyük ve çeşitli veri setlerinde başarılı sonuçlar elde etmek amacıyla tercih edilmektedir [27]. Şekil 6'da InceptionResNetV2 mimarisi sunulmuştur.



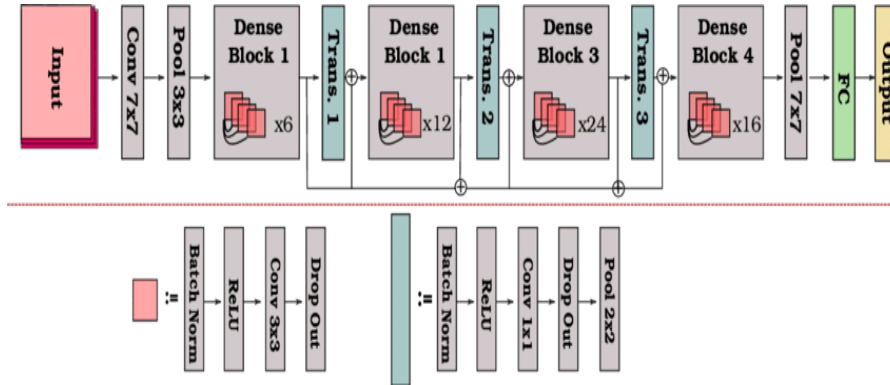
Şekil 6. InceptionResNetV2 mimarisini

2.1.3 DenseNet121

DenseNet121, yoğun blokların kullanıldığı ve bilgisayarlı görüş alanındaki derin öğrenme görevlerinde etkili bir performans sergileyen bir sinir ağı modelidir. Bu model, yoğun bağlantılar ile

öne çıkan bir mimariye sahiptir, yani her katman önceki katmanlarla direkt olarak bağlantılıdır. Bu bağlantılar, ağır öğrenme kapasitesini artırır ve ağır daha etkili bir şekilde bilgi paylaşmasına olanak tanır. DenseNet121, toplamda 121 katmandan oluşan bir derin ağ yapısına sahiptir. Yoğun

bağlantıların yanı sıra, her yoğun blok içinde evrişim katmanları ve havuzlama katmanları gibi temel bileşenler de bulunmaktadır. Bu, ağır girişten çıkışa kadar sürekli ve yoğun bir bilgi akışını sağlar. Model, ImageNet veri kümesi üzerinde yapılan sınıflandırma görevlerinde ve diğer çeşitli görsel tanıma görevlerinde başarılı bir şekilde kullanılmıştır. DenseNet121, bilgisayarlı görüş alanında derin öğrenme modellerinin geliştirilmesinde önemli bir ilerleme olarak değerlendirilmekte ve yoğun bağlantıların getirdiği avantajlarıyla öne çıkmaktadır [19]. Bu mimari Şekil 7’de sunulmuştur.

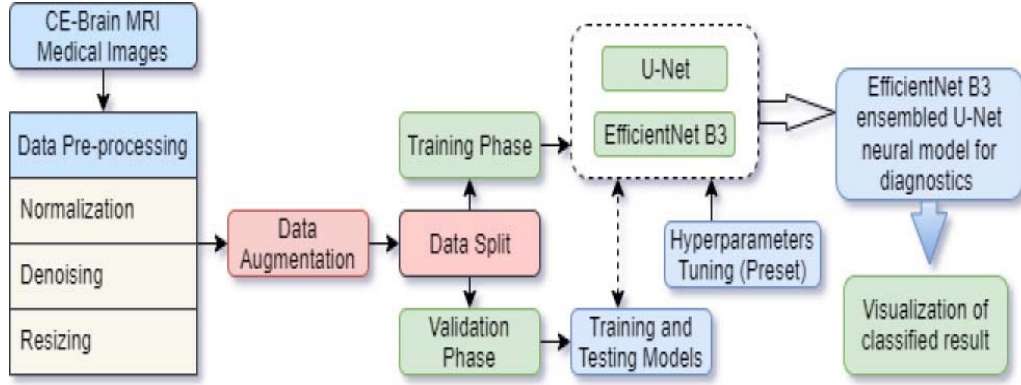


Şekil 7. DenseNet121 mimarisine ait görsel

2.1.4. EfficientNetB3

EfficientNetB3, derin öğrenme alanındaki bilgisayarlı görüş görevleri için tasarlanmış yüksek performanslı bir sinir ağı modelidir. EfficientNet serisi, özellikle model boyutu, derinlik ve genişlik

gibi faktörleri dengeli bir şekilde optimize eden bir ölçekleme stratejisi kullanarak etkili ve ölçeklenebilir modeller sunmayı amaçlamaktadır. EfficientNetB3, bu stratejiyi izleyen ve önceki EfficientNet modellerinden daha büyük bir boyuta sahip olan bir versiyondur.



Şekil 8. EfficientNetB3 mimarisi

Model, evrişim katmanları, mobil öğrenme blokları ve genişleyen bloklar gibi özel bileşenleri içerir. Bu, ağı daha fazla öğrenme kapasitesi kazanmasını ve görsel özellikleri daha etkili bir şekilde çıkarmasını sağlar. EfficientNetB3, ImageNet veri kümesinde ve diğer görsel tanıma görevlerinde yüksek doğruluk oranları elde etmiştir. Bu model, derin öğrenme modellerinin büyüklük ve performans dengesini optimize etme çabalarında önemli bir adım olarak kabul edilmektedir [28]. EfficientNetB3 mimarisi Şekil 8’de verilmiştir.

2.1.5 Önerilen Model


Veri ön işleme, özellik çıkarma ve sınıflandırma, önerilen yöntemin üç aşamasıdır. Bu adımlar Şekil 6’da şematik olarak gösterilmiştir. Veri ön işleme, görüntü kalitesini iyileştirmek için etkili bir stratejidir. Görüntüler, kamera açısı ve mikroskop konumu da dahil olmak üzere çeşitli gürültü kaynakları tarafından kirletilebilir. Görüntüler, görüntü gürültüsünü azaltmak için çeşitli yöntemler kullanılarak temizlenmiştir. Sıtmanın tespiti için enfekte ve enfekte olmayan görüntüleri verimli bir şekilde sınıflandırmak için önerdiğimiz CNN modeli kullanılmıştır. İlk olarak, $50 \times 50 \times 3$ boyutlu giriş görüntülerini işlemek için 2×2 filtre boyutlarına sahip 4 konvolüsyonel katmanı, ardından 2×2 boyutunda 4 maksimum havuzlama katmanı kullanılmıştır. Aktivasyon fonksiyonu olarak ReLU tercih edilmiştir. Son olarak veriyi düzleştirmek için 1 flatten katmanı, 2 Dropout ve 2 Dense katmanı kullanılmıştır. Çıkış katmanı için Sigmoid aktivasyon fonksiyonu uygulanmıştır.

Önerilen yönteme dair detaylı bilgiler, Şekil 9’da açıkça sunulmuştur. Şekil 9’un incelenmesi sonucunda, toplam parametre sayısının 620.441 olduğu görülmektedir. Bu parametrelerin tamamının başarıyla eğitildiği belirtilmiştir. Ayrıca, önerilen modelin şematik gösterimi, Keras Visualization özelliği kullanılarak Şekil 10’da görselleştirilmiştir. Önerilen yöntemin blok diyagramı ise Şekil 11’de detaylı bir şekilde sunulmuştur.


Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 50, 50, 16)	208
max_pooling2d (MaxPooling2D)	(None, 25, 25, 16)	0
conv2d_1 (Conv2D)	(None, 25, 25, 32)	2080
max_pooling2d_1 (MaxPooling2D)	(None, 12, 12, 32)	0
conv2d_2 (Conv2D)	(None, 12, 12, 64)	8256
max_pooling2d_2 (MaxPooling2D)	(None, 6, 6, 64)	0
conv2d_3 (Conv2D)	(None, 6, 6, 128)	32896
max_pooling2d_3 (MaxPooling2D)	(None, 3, 3, 128)	0
flatten (Flatten)	(None, 1152)	0
dropout (Dropout)	(None, 1152)	0
dense (Dense)	(None, 500)	576500
dropout_1 (Dropout)	(None, 500)	0
dense_1 (Dense)	(None, 1)	501

Total params: 620,441
Trainable params: 620,441
Non-trainable params: 0

Şekil 9. Önerilen yöntemin detayları



Şekil 10. Önerdiğimiz modelin şematik gösterimi



Şekil 11. Önerdiğimiz modelin blok diyagramı

Sınıflandırma performansını değerlendirmek amacıyla önerilen yöntem, karışıklık matrisi ve bu matristen türetilen çeşitli sınıflandırma değerlendirme ölçütlerini kullanmaktadır. Bu ölçütler arasında doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru (F1-score) bulunmaktadır. Karışıklık matrisi, Gerçek Pozitif (True Positive-TP), Gerçek Negatif (True Negative-TN), Yanlış Negatif (False Negative-FN) ve Yanlış Pozitif (False Positive-FP) değerlerini içermektedir. Çalışmada, TP, sınıflandırıcının belirli bir parazitli hücre sınıfını doğru bir şekilde tahmin ettiği durumu ifade ederken, TN,

sınıflandırıcının bir hücre görüntüsünün belirli bir parazitli hücre sınıfına ait olmadığını doğru bir şekilde teşhis ettiği durumu yansıtmaktadır. FP, sınıflandırıcının negatif bir örneği yanlış bir şekilde pozitif olarak tahmin ettiği durumu ifade ederken, FN, sınıflandırıcının pozitif bir örneği yanlış bir şekilde negatif olarak tahmin ettiği durumu ifade etmektedir. Şekil 12, karışıklık matrisini görsel olarak temsil etmektedir.

		Actual Values	
		Positive(1)	Negative(0)
Predicted Values	Positive(1)	TP	FP
	Negative(0)	FN	TN

Şekil 12. Confusion matrix

Her hücre türüne göre doğru bir şekilde sınıflandırılan test örneklerinin sayısının, toplam test örnekleri sayısına oranı accuracy olarak adlandırılır ve Eşitlik (1)'deki gibi hesaplanır.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

Her hücre türü için doğru bir şekilde sınıflandırılan pozitif örneklerin, gerçek pozitif örneklerin sayısına oranı recall olarak adlandırılır ve Eşitlik (2)'deki formülle hesaplanır.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2)$$

Her bir hücre türü tarafından doğru bir şekilde sınıflandırılan pozitif örneklerin sayısı ile pozitif olarak sınıflandırılan toplam örneklerin sayısı, precision (kesinlik) tarafından belirlenir ve Eşitlik (3)'deki formülle hesaplanır.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

F1-skoru, kesinlik ve duyarlılık oranlarının harmonik ortalamasını ifade eder. F1-skoru, 0 ile 1

arasında bir değer alır; her bir hücre sınıflandırma modelinin daha iyi performansı, daha yüksek bir F1-skora karşılık gelir ve Eşitlik (4)'teki formülle hesaplanır.

$$F1 - \text{skor} = 2x \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

3. ARAŞTIRMA BULGULARI


Bu bölümde önceki bölümde sunulan materyaller ve metotlar kullanılarak elde edilen sonuçlar sunulmuştur. Çalışma, insan kırmızı kan hücresi görüntülerinin Plasmodium paraziti tarafından parazitlenmiş veya parazitlenmemiş olarak sınıflandırılmasını içeriyor. Kan hücresinin parazitlenmiş ya da parazitlenmemiş olduğunu tespit etmek için CNN mimarileri kullanılmıştır. Bu çalışmada önceden eğitilmiş CNN mimarilerinden VGG-19, InceptionResNetV2, DenseNet121, EfficientNetB3 ve önerdiğimiz CNN modeli ile deneyler gerçekleştirilmiştir. Yapılan deneyler sonucunda her bir model için Confusion matrisleri verilmiştir.

		Confusion Matrix	
		Unparasitised	Parasitised
True label	Unparasitised	2571	155
	Parasitised	52	2734


Şekil 13. DenseNet121 Confusion Matrix

		Confusion Matrix	
		Unparasitised	Parasitised
True label	Unparasitised	2646	80
	Parasitised	72	2713


Şekil 14. EfficientNetB3 Confusion Matrix



Şekil 15. InceptionResNetV2 Confusion Matrix



Şekil 17. Proposed Model Confusion Matrix



Şekil 16. VGG19 Confusion Matrix


Önerilen görüntü sınıflandırma yönteminin performansı, doğruluk, kesinlik, duyarlılık ve F1-skor açısından önceden eğitilmiş CNN tabanlı yöntemlerle karşılaştırılmıştır, Çizelge 2'de bu karşılaştırma sunulmuştur. Modellerin confusion matrisine dayalı olarak elde edilen doğruluk, kesinlik, duyarlılık ve F1-skor değerleri Çizelge 2'de detaylı bir şekilde belirtilmiştir.

Çizelge 2. Model sonuçlarının karşılaştırılması


Yöntem	Doğruluk (%)	Kesinlik (%)	Geri çağırma (%)	F-Score (%)	Parametre sayısı
VGG19	96,28	96,79	95,73	96,26	26.449.730
InceptionResNetV2	89,76	82,38	96,65	88,95	15.241.025
DenseNet121	96,23	94,31	98,0	96,12	7.304.514
EfficientNetB3	97,23	97,70	97,33	97,20	11.183.665
Proposed Model	98,9	97,98	98,9	98,9	620.441

Tüm yöntemlerde her bir hücre türü için hesaplanan değerlendirme ölçütlerinin ortalama değerleri alınarak karşılaştırmalar yapılmıştır. Önerilen yöntem, %98,9 doğruluk, %97,98 kesinlik, %98,77 duyarlılık ve %98,9 F1-skor değeri ile en üstün sınıflandırma performansını sergilemektedir. Önerilen yönteme en yakın sonuçlar %97,23 doğruluk, %97,70 kesinlik, %97,33 duyarlılık ve %97,20 F1-skoru ile EfficientNetB3 modelinden elde edilmiştir. Veri seti için en düşük performans %89,76 doğruluk, %82,38 kesinlik, %96,65 duyarlılık ve %88,95 F1-skoru ile InceptionResNetV2 modelinden kaydedilmiştir. Çizelge 2'deki tüm veriler göz önüne alındığında, önerilen yöntem düşük eğitilebilir parametre sayısı


ve üstün sınıflandırma sonuçlarıyla dikkat çekmektedir. Diğer derin öğrenme tabanlı yöntemlerle karşılaştırıldığında, önerilen yöntem yalnızca daha iyi bir sınıflandırma doğruluğu sağlamakla kalmayıp aynı zamanda daha iyi bir hesaplama verimliliği sunmaktadır. Eğitim-doğrulama doğruluğu, Şekil 18'de, ve eğitim-doğrulama kaybı 50 epoch için Şekil 19'da grafikleştirilmiştir. Epoch değeri arttıkça, eğitim ve doğrulama setlerindeki doğruluk değerleri artmaktadır. Aynı zamanda, eğitim ve doğrulama kayıp eğrileri, epoch değeri arttıkça düşüş göstermektedir. Şekil 20'de, rastgele seçilen bir hücrenin parazitli veya parazitsiz olma tahminini gösteren bir ekran görüntüsü yer almaktadır.



Şekil 18. Training-validation accuracy curve



Şekil 19. Training-validation loss curve verilmiştir.



Şekil 20. Rastgele seçilmiş hücrelerin parazit durumunun tahmin edilmesi

4. SONUÇLAR

Bu araştırmada, sıtma hücrelerinin sınıflandırılması için farklı derin öğrenme tabanlı sınıflandırma yöntemlerinin performansları karşılaştırılmıştır. Önerilen CNN modeli, VGG-19,

InceptionResNetV2, DenseNet121 ve EfficientNetB3 gibi önceden eğitilmiş mimarilerle kıyaslanmıştır. CNN tabanlı mimarilerin sıtma hücre görüntülerini parazitli ve parazitsiz olarak sınıflandırmak için etkili sonuçlar verdiği gözlemlenmiştir. Bu çalışmanın performansını

değerlendirmek için literatürde sıklıkla kullanılan, Ulusal Sağlık Enstitüleri tarafından açık erişim izni olan bir veri seti kullanılmıştır. Bulgular, önerilen modelin kabul edilebilir bir güven düzeyinde doğru ve hızlı bir tespit sağlayabildiği sonucuna varmıştır. Performans değerleri, Çizelge 2'den anlaşılacağı üzere, önerilen CNN modelinin en iyi sınıflandırma sonuçlarını elde ettiğini göstermektedir. Bu sonuçlar, önerilen yöntemin sıtma teşhisi için yüksek verimlilikle doğru sonuçlar verdiği ve klinik uygulamalarda uzmanlar için alternatif bir yöntem olarak kullanılabilmesi düşüncesini desteklemektedir. En iyi performans gösteren model, daha basit ve daha hızlı sıtma tespitini kolaylaştırmak amacıyla masaüstü tabanlı bir uygulama geliştirmek için kullanılmıştır. Bu çalışmadan elde edilen sonuçların, tedavinin güvenilirliğini artırma ve tıbbi uzmanlık eksikliğini çözüme konularında fayda sağlayabileceğine inanılmaktadır.

5. KAYNAKLAR

1. Mahajan, H., Rashid, A., Junnarkar, A., 2022. Integration of Healthcare 4.0 and Blockchain Into Secure Cloud-Based Electronic Health Records Systems. *Appl Nanoscience*, 13, 2329-2342
2. Mbanefo, A., Kumar, N., 2020. Evaluation of Malaria Diagnostic Methods as a Key for Successful Control and Elimination Programs. *Trop Med Infect Disease*, 5(2), 102
3. Nema, S., Rahi, M., Sharma, A., Bharti, P.K., 2022. Strengthening Malaria Microscopy Using Artificial Intelligence-Based Approaches in India. *Lancet Reg Health-Southeast Asia*, 3(5), 100054
4. W.H. Organization, 2021. Malaria Microscopy Quality Assurance Manual-Version 2. World Health Organization, 140.
5. Alhayani, A., Bilal, S.A., Hamid, N., 2022. Optimized Video Internet of Things Using Elliptic Curve Cryptography Based Encryption And Decryption. *Comput Electr Eng.*, 101, 108022.
6. Alhayani, B., Kwekha-Rashid, A.S., Mahajan, H.B., 2022. Standards For The Industry 4.0 Enabled Communication Systems Using Artificial Intelligence: Perspective of Smart Healthcare System. *Appl Nanoscience*, 13, 1807-1817.
7. Daid, R., Kumar, Y., Gupta, A., Kaur, I., 2021. An Effective Mechanism for Early Chronic Illness Detection Using Multilayer Convolution Deep Learning Predictive Modelling. In 2021 International Conference on Technological Advancements and Innovations (ICTAI), IEEE, 649-652.
8. Bansal, K., Bathla, R.K., Kumar, Y., 2022. Deep Transfer Learning Techniques with Hybrid Optimization in Early Prediction and Diagnosis of Different Types of Oral Cancer. *Soft Comput* 26(21), 11153-11184.
9. Beck, H.P., 2022. Digital Microscopy and Artificial Intelligence Could Profoundly Contribute to Malaria Diagnosis in Elimination Settings. *Front Artif Intell*, 17(5), 510483.
10. Kumar, Y., Koul, A., Mahajan, S., 2022. A Deep Learning Approaches and Fastai Text Classification to Predict 25 Medical Diseases from Medical Speech Utterances, Transcription and Intent. *Soft Comput*, 26(17), 8253-8272.
11. Narayanan, B.N., Ali, R., Hardie, R.C., 2019. Performance Analysis of Machine Learning and Deep Learning Architectures for Malaria Detection on Cell Images. In: Zelinski ME, Taha TM, Howe J, Awwal AAS, Iftekharruddin KM (Eds) Applications of Machine Learning. SPIE, Bellingham, 11139, 240-249.
12. Alsunbuli, B.N., Ismail, W., Mahyuddin, N.M., 2021. Convolutional Neural Network and Kalman Filter-Based Accurate CSI Prediction for Hybrid Beamforming under A Minimized Blockage Effect in Millimeter-Wave Network. *Appl Nanosci*, 13, 1539-1560.
13. Aslan, E., Özüpak, Y., 2024. Classification of Blood Cells with Convolutional Neural Network Model. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 13(1), 314-326.
14. Malihi, L., Ansari-Asl, K., Behbahani, A., 2013. Malaria Parasite Detection in Giemsa-Stained Blood Cell Images, 8th Iranian Conference on Machine Vision And Image Processing (MVIP), Zanjan, 360-365.
15. Memeu A., Daniel, M., 2014. A Rapid Malaria Diagnostic Method Based on Automatic Detection and Classification of Plasmodium

- Parasites in Stained thin Blood Smear Images. University of Nairobi, 44(1), 69-78.
16. Prasad, K., Winter, J., Bhat, U.M., Acharya, R.V., Prabhu, G.K., 2012. Image Analysis Approach for Development of A Decision Support System for Detection of Malaria Parasites ,n Thin Blood Smear Images. J Digit Imaging, 25(4), 542-549.
 17. Kumarasamy, S.K., Ong, S.H., Tan, K., 2011. Robust Contour Reconstruction of Red Blood Cells and Parasites in the Automated Identification of the Stages of Malarial Infection. Mach Vis Appl., 22(3), 461-469.
 18. Liang, Z., Fulfilmenti, P., 2017. Automatic Image Recognition of Rapid Malaria Emergency Diagnosis: A Deep Neural Network Approach. The Degree Master of Arts.
 19. Quan, Q., Wang, J., Liu, L., 2020. An Effective Convolutional Neural Network for Classifying Red Blood Cells in Malaria Diseases. Interdiscip Sci Comput Life Sci., 12, 217-225.
 20. Rajaraman, S., Antani, S., Pootschi, M., Silamut, K., Hossain, M., 2018. Pre-Trained Convolutional Networks as Feature Extractors Toward Improved Malaria Parasite Detection in Thin Blood Smear Images. Peer J., 6(4), 4578.
 21. Kakkar, B., Goyal, M., Johri, P., 2023. Artificial Intelligence-Based Approaches for Detection and Classification of Different Classes of Malaria Parasites Using Microscopic Images: A Systematic Review. Arch Computat Methods Eng, 30, 4781-4800.
 22. Neha, S., Radim, B., Malay, D., 2022. A Vision Transformer Based Approach for Analysis of Plasmodium Vivax Life Cycle for Malaria Prediction Using Thin Blood Smear Microscopic Images. Computer Methods and Programs in Biomedicine, 224, 106996.
 23. Gourisaria, M.K., Das, S., Sharma, R., Rautaray, S.S., Pandey, M., 2020. A Deep Learning Model for Malaria Disease Detection and Analysis Using Deep Convolutional Neural Networks. International Journal on Emerging Technologies, 11(2), 699-704.
 24. Krishnadas, P., Chadaga, K., Sampathila, N., Rao, S., Swathi, S.K., Prabhu, S., 2022. Classification Of Malaria Using Object Detection Models. Informatics, 9(4), 76-86.
 25. Muqdad, A., Abdullahi, A.I., 2022. Malaria Parasite Detection Using Deep Learning Algorithms Based on (Cnns) Technique. Computers and Electrical Engineering, 103, 108316.
 26. Yufeng, Z., Clifford, Y., Alex, M., 2018. Breast Cancer Screening Using Convolutional Neural Network and Follow-Up Digital Mammography. Proc. SPIE 10669, Computational Imaging III. 1066905.
 27. Hamid, M., Farhad, S., 2020. An Object Based Framework for Building Change Analysis Using 2D and 3D Information of High Resolution Satellite Images. Advances in Space Research, 66(6), 1386-1404.
 28. Dudeja, T., Dubey, S.K., Bhatt, A.K., 2023. Ensembled EfficientNetB3 Architecture for Multi-Class Classification of Tumours in MRI Images, 395-414.