

KONVOLÜSYONEL SİNİR AĞI KULLANILARAK SITMA HASTALIĞI SINIFLANDIRILMASI

İbrahim ÇETİNER^{1*}

¹Teknik Bilimler MYO, Burdur Mehmet Akif Üniversitesi, Burdur, Türkiye

Geliş Tarihi/Received Date: 06.12.2021 Kabul Tarihi/Accepted Date: 08.05.2022 DOI: 10.54365/adyumbd.1033135

ÖZET

Sıtma, sivrisinek ısırması sonucu oluşan bir hastalıktır. Sıtma hastalığını algılama, tanıma ve sınıflandırma gibi işlemler, Plasmodium parazitli hücrelerin mikroskopik olarak incelenmesine dayanmaktadır. Sıtma paraziti ile enfekte olmuş hücrelerin bilgisayar destekli olarak tanımlanması zorlu bir işittir. Bu zorlu işlemi kolaylaştırabilmek için son zamanlarda popüler hale gelen derin öğrenme yöntemleri ile kırmızı kan hücrelerinde sıtma parazitinin olup olmadığı tespit edilmeye çalışıldı. Bu hastalığın tanısını koyabilmek için gerçekleştirilen sınıflandırmada iki ayrı Konvolüsyonel Sinir Ağı (CNN) modeli geliştirilmiştir. Birinci modelde giriş katmanı olarak önceden eğitilmiş ResNet50V2 mimarisini temel alan derin öğrenme modeli verilmiştir. İkinci modelde ise 23 ağırlıklı katmandan oluşan yeni bir derin öğrenme modeli tasarlanmıştır. Önerilen modelleri eğitebilmek için toplam 27.558 ince kan hücresi görüntüsü kullanıldı. Önerilen modeller ile sıtma hastalığının sınıflandırılmasında %97.53 oranında doğruluk değerine ulaşılmıştır.

Anahtar Kelimeler: CNN, ResNet50V2, sıtma hastalığı, sınıflandırma

MALARIA DISEASE CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK

ABSTRACT

Malaria is a disease that is infected by mosquito bites. Detection, recognition, and classification of malaria are based on microscopic examination of parasitic cells such as Plasmodium. Computer-aided identification of the fine-grained manifestations of infected cells with malaria disease is a challenging task. In order to facilitate this difficult process, it has been tried to determine whether there is malaria in red blood cells with the deep learning methods that have become popular recently. Two different convolutional neural network (CNN) models were developed to diagnose this disease in the classification. In the first model, a deep learning model based on the pre-trained ResNet50V2 architecture is given as the input layer. In the second model, a new deep learning model consisting of 23 weighted layers was designed. A total of 27,558 thin blood cell images were used to train the proposed models. With the proposed models, an accuracy value of 97.53% was obtained in the classification of malaria.

Keywords: CNN, ResNet50V2, malaria, classification

1. Giriş

Sıtma yedi gün veya daha uzun kuluçka süresi olan, sivrisinek kaynaklı ateşli bir hastalıktır [1,2]. Bu hastalık sivrisinek ısırması sonucu parazitlerin hücreyi enfekte etmesi sonucu oluşur. Bu parazitler Plasmodium malariae, Plasmodium Ovale, Plasmodium falciparum ve Plasmodium vivax olarak adlandırılmaktadır [3]. Parazit ile enfekte olmuş kişilerde dolaşım bozukluğu, koma, çoklu organ yetmezliği gibi rahatsızlıklara ve hatta ölüme neden olabilir [4-6]. Sıtmanın erken ve etkin teşhisi onu

*¹e-posta: cetiner51@gmail.com ORCID ID: <https://orcid.org/0000-0002-1635-6461>

hem önlenabilir hem de tedavi edilebilir kılmaktadır [5]. Sıtma hastalığına karşı tedavi edici ilaçlar var olsa da hastalığın tedavi yöntemi yetersiz kalmaktadır [7]. Bu hastalığa karşı etkili bir aşı bulunması için araştırmalar yapılmaktadır [7–9]. Sıtma bulaşıcı bir hastalık olduğu için erken teşhis edilmesi ve önlenmesi hayati önem taşımaktadır.

Sıtmanın doğru ve başarılı tespiti deneyimli mikrobiyoloji uzmanları tarafından yapılabilmektedir. Bu yüzden parazitin tesbitinde standart bir yöntem ortaya konulamamıştır. Bunun yanı sıra ülkelerin gelişmişlik seviyelerine göre yeterli mikrobiyoloji uzmanı olmaması ve bunların kullanacağı araç gereçlerin yetersizliği gibi nedenlerle sıtma ile mücadelede önemli eksiklikler bulunmaktadır. Son yıllarda kan hücrelerinin mikroskopik görüntülerinden insan yorumuna dayalı sıtma enfeksiyonunu tespit etmede insanların yorgunluk, dikkat eksikliği ve bilgi eksikliği gibi sebeplerden kaynaklanan hatalardan dolayı yanlış sonuçlarda büyük artış görülmektedir. Bu problemlerin üstesinden gelmek için literatürde makine öğretimi yöntemleri ile yapılan çalışmalar görülmektedir [5]. Ancak, derin öğrenme modellerini temel alarak çalışan akıllı aygıtlar ile yapılan sıtma parazit tespit sistemleri daha standartlaşmış olmasından dolayı önemlidir. Bu sistemler mikroskopik tanıya göre daha objektif ve güvenilir hızlı sistemlerdir. Bu sistemler ile tanı daha kısa zamanda tespit edilmesinin yanında maliyet bakımından da daha ekonomiktir.

Dünyada tıbbi görüntü işlemede bilgisayar görü yöntemleri etkili ve başarılı çalışmalar sergilemişlerdir [10–12]. Daha kapsamlı, daha derin ve daha karmaşık CNN'lerin yükselişi, makine öğrenme ve bilgisayar görü alanında bir trend haline geldi. AlexNet, VGG, GoogleNet ve ResNet gibi modeller, temel CNN'den bu güne kadar önemli gelişmeler kaydetti [13–14]. Önerilen CNN yöntemleri hem öznetelik çıkarmak için kullanılabilmesi gibi hem de sigmoid ve softmax aktivasyon fonksiyonları ile sınıflandırma yapmak için de kullanılabilir. Bunlara ek olarak istenirse, CNN yönteminden elde edilen öznetelikler klasik makine öğrenme sınıflandırma algoritmaları olan Support Vector Machines (SVM), Decision Tree (DT), K-Nearest Neighbour (KNN) ve Naïve Bayes (NB) ile de sınıflandırılabilir [14–16].

Bu makale kapsamında bilgisayar görü ve CNN yöntemleri bir arada kullanılarak sıtma hastalığını sınıflandırma işlemi gerçekleştirilmiştir. Önerilen derin öğrenme yöntemlerinde enfekte kırmızı kan hücreleri sıtma hastalığını doğru bir şekilde sınıflandırabilmek için girdi olarak kullanılmıştır. Girdi olarak kullanılan görüntülerde parazitlenmiş bir hücre bir yabancı cisim (parazit) içermekte iken enfekte olmamış hücreler çoğunlukla yuvarlak, tek renkli, lekesiz hücrelerdir [17]. Sıtma paraziti tespiti için 23 ağırlıklı katmandan oluşan bir CNN ve önceden eğitilmiş ResNet50V2 mimarisini temel alan bir model önerilmiştir. Önerilen modelleri sıtma hastalığını sınıflandırması için eğitebilmek amacıyla 13.779 adet kırmızı kan hücresinde çalışılmıştır. Önerilen modellerin test doğruluğunu da belirleyebilmek için eğitimde kullanılmayan 13.779 kırmızı kan görüntüsü kullanılmıştır. Toplam 27.558 kırmızı kan hücresinden oluşan bir veri seti kullanılarak geliştirilen derin öğrenme modellerinin performansları literatürde yaygın olarak kullanılan doğruluk, F1-Puanı, geri çağırma ve keskinlik performans değerlendirme ölçütleri ile belirlenmiştir.

Öne sürülen yöntemlerdeki katmanlar doğru ve güvenilir bir sonuç için önemlidir. Konvolüsyon (Convolution) katmanı çekirdek filtrelerden oluşmaktadır. Bu katmanda tanımlı olan filtreler görüntü boyunca hareket ettirilerek sıtma görüntülerine ait ayırt edici öznetelikler çıkartılmıştır. Eğitim ve test aşamasının tamamında aynı boyutta kırmızı, yeşil ve mavi renk kanallarına sahip olan görüntüler kullanılmıştır. Konvolüsyon katmanında tüm görüntülerin boyutları 64x64 olacak şekilde belirlenerek işlem hızı açısından ReLU aktivasyon fonksiyonları genel olarak tercih edilmiştir. ReLU, doğrusal transfer fonksiyonu olarak kullanılmaktadır. ReLU, negatif değerler için sıfır çıktı verirken pozitif girdileri doğrudan çıktıya aktarmaktadır. Genel olarak konvolüsyon katmanından sonra havuzlama katmanı (Pooling) gelmektedir. Havuzlama katmanının 3 farklı türü bulunmaktadır. Bunlar maksimum havuzlama (MaxPooling), ortalama havuzlama (AvgPooling) ve minimum havuzlama (MinPooling) katmanlarıdır. Konvolüsyon matrisinden çıkartılan öznetelik matrisindeki filtreler içerisinde en küçük, en büyük ya da ortalama değerleri olarak öznetelik matrisi boyutu azaltılmaktadır. Bu makale kapsamında maksimum ve ortalama havuzlama katmanları performansı iyileştirmesinden dolayı tercih edilmiştir. Havuzlama işlemlerinde öznetelik matrisinde gezinecek pencerenin boyutu pool_size olarak

tanımlanmaktadır. Genel olarak havuzlama katmanı sonrasında kullanılan toplu normalleştirme katmanı (BatchNormalization) önceki katmanlardan gelen değerleri normalleştirmektedir. Bu sayede sıtma görüntülerinin eğitim ve test grafiklerinde aşırı dalgalanmanın önüne geçilebilmektedir. Havuzlama katmanı sonrasında sıklıkla kullanılan unutmaya katmanı (Dropout) ile modelde ezberlemeyi önlemek için belirli bir değer kadar bağlantıları bırakması sağlanmaktadır. Düzleştirme (Flatten) adı verilen düzleştirme katmanında ise önceki katmandan gelen girdi olarak kullanılan öznetelik haritasını tek boyutlu bir diziyeye dönüştürmektedir. Düzleştirme katmanı sonrasında, girdi olarak verilen unutmaya katmanından gelen $8 \times 8 \times 32$ 'lik matris 2048 boyutuna dönüştürülmektedir. Tam bağlantı katmanı (Fully connected) ile önceki tüm katmanlarla bağlantı sağlanmaktadır. Genel olarak tam bağlantı katmanı ReLU ile kullanılabilirdiği gibi sınıflandırma aşamasında sigmoid aktivasyon fonksiyonu ile hedef sınıf olasılıklarının belirlenmesinde kullanılmaktadır. Sigmoid aktivasyon fonksiyonu ile kullanılan sınıflandırma katmanında sınıf sayısına göre çıkış sayısının belirlenmesi gerekmektedir. Bu aktivasyon fonksiyonu ile oluşturulan sınıflandırma katmanı ile Parazitli ve Parazitsiz olarak tanımlanan iki sınıfın belirlenmesi amaçlanmıştır. Genel olarak önerilen model bu temel şekilde çalışmaktadır.

Yukarıda ayrıntılı açıklamaları yapılan katmanlar sıfırdan ve ResNet50V2 gibi önceden eğitilmiş ağ yardımıyla iki farklı model önerilmiştir. Bu önerilen modeller ile sıtma hastalığının tanınması ve sınıflandırılması için geliştirilen bir karar destek sistemi tasarlanmıştır. Bu tasarlanan karar destek sistemide 23 ağırlıklı katmandan oluşan bir CNN ve önceden eğitilmiş ResNet50V2 mimarisini temel alan modeller ile Adamax optimizasyon yönteminde başarı oranları karşılaştırılmıştır. Sonuçlar incelendiğinde her iki önerilen modelde de Adamax optimizasyon yöntemi ile sonuçlar edilmiştir. Bu anlamda elde edilen sonuçlar literatürde performans sonuçlarını veren kriterler ile birlikte karmaşıklık matrisleri ve F1 puan değerleri verilerek ilerleyen bölümlerde detaylı analizi sunulmuştur.

Sıtma hastalığını sınıflandırma için yapılan çalışmada literatüre sağlanan ana katkılar aşağıda maddeler halinde sunulmuştur.

- Sıtma hastalığı tanımlanması için iki farklı yaklaşımla bir model geliştirilmiştir. Geliştirilen modelde kullanılan eğitim ve test verileri K-Fold 5 değerine göre ayrılmıştır. Bu nedenle çalışmada K-Fold 5 değerine göre elde edilen performans değerleri sunulmuştur.
- Sıtma hastalığına sahip test görüntülerini sınıflandırabilecek yeni bir CNN modeli tasarlanmıştır.
- Kaynakların kısıtlı olduğu bölgelerdeki mikrobiyoloji uzmanlarının yükünü azaltmak için sıtma hastalığı sınıflandırma işlemini gerçekleştiren bir karar destek sistemi önerilmiştir.
- Sağlık sektöründe CNN tabanlı sınıflandırma işlemlerinin yaygınlaşması ile daha fazla sıtma hastası, daha kısa sürede tedaviye alınabilecektir.

Makalenin bundan sonraki bölümleri aşağıdaki şekilde gruplandırılmıştır. 2. Bölüm Materyal ve Metod'a bu çalışmada kullanılan veri seti detaylı anlatımı yapılmıştır ve işleme yöntemlerinden bahsedilmiştir. 3. Bölümde öne sürülen yöntemlerden olan Temel ResNet50V2 ve CNN mimarili model bahsedilerek bu modellerden elde edilen performans sonuçları karşılaştırılmıştır. 4. Bölümde sonuçlar grafiksel olarak verilerek benzer çalışmalarla karşılaştırılmıştır. 5. Bölümde ise makale sonuçlandırılmıştır.


2. Materyal ve Metod

2.1. Materyal

Bu çalışmada önerilen mimari modeller sıtma hastalığına ait halka açık kırmızı kan hücresi görüntüleri içeren bir veri seti üzerinde gerçekleştirilmiştir [18]. Bu veri seti, Malaria Screener araştırma faaliyetinden alınan ince kan hücresi görüntülerinden bölümlere ayrılmış hücrelerin bir deposunu barındırır. Ulusal Tıp Kütüphanesi'nin (NLM) bir parçası olan Lister Hill Ulusal Biyomedikal İletişim

Merkezi'ndeki (LHNCBC) arařtırmacılar, kaynakların kısıtlı olduđu bölgelerdeki mikrobiyoloji uzmanlarının yükünü azaltmak ve teşhis doğruluğunu artırmak için bir mobil uygulama geliřtirdiler. Geleneksel bir ışık mikroskopuna bađlı Android akıllı telefon. 150 Plasmodium falciparum ile enfekte olmuş ve 50 sađlıklı hastadan Giemsa lekeli ince kan hücresi görüntüsü toplandı ve Bangladeř Chittagong Tıp Koleđi Hastanesinde işlendi. Akıllı telefonun dahili kamerası, her bir mikroskopik görüř alanı için ince kan hücresi görüntüleri aldı. Görüntüler, Bangkok, Tayland'daki Mahidol-Oxford Tropikal Tıp Arařtırma Birimi'ndeki uzman bir görüntü okuyucu tarafından manuel olarak not edildi. Kimliđi kaldırılan görüntüler ve ađıklamalar NLM'de (IRB#12972) arřivlenir.

Veri seti, parazitle enfekte ve enfekte olmamıř hücrelerin eřit örneklerine sahip toplam 27.558 hücre görüntüsü içerir. Görüntülerin 13.779 tanesi enfekte ve 13.779 tanesi ise enfekte deđildir.




Şekil 1. Veri setinde bulunan sıtma hastalıđı görüntü dađılımı.

Şekil 1'de kullanılan veri setinin parazitli kırmızı kan hücresi adeti ve parazitsiz kırmızı kan hücre adeti sayısal dađılımları gösterilmiştir. Bu sayılar toplam eđitim ve test sayılarını göstermektedir. Eđitim sırasında Şekil 5'de gösterildiđi gibi tüm görüntüler ön işleme adımlarından geçmektedir. Tüm görüntüler eđitim modelleme işleminden önce ön işlemlerden geçirildi. Görüntülerin 64x64 boyutu oluşturulmuştur. Görüntü yoğunluđunu ve aydınlatma farklılıklarını belirgin hale getirilmesi için HSV renk uzayına geçilmiştir. Otsu yöntemi için görüntüler gri tonlamaya dönüřtürülmüştür. Görüntülerin ikili halleri Otsu yöntemi sonrasında kırmızı kan hücresi bölgeleri tespit edilmiştir. İlgili alanlar belirlendikten sonra Parazitli ve Parazitsiz olarak her bir görüntü etiketlenmiştir. Bu görüntülerde ön işlemlerden sonra veri dengesizliklerini giderebilmek için veri büyütme işlemleri, veri döndürme ve veri yakınlařtırma işlemleri gerçekleştirilmiştir.

2.2. ResNet50V2

ResNet mimarisi yaygın olarak kullanılan derin öğrenme mimarilerden birisidir. Bu mimarinin katman ve blok yapısına göre ResNet 50/101/152 olmak üzere farklı yapıları da bulunmaktadır[19].



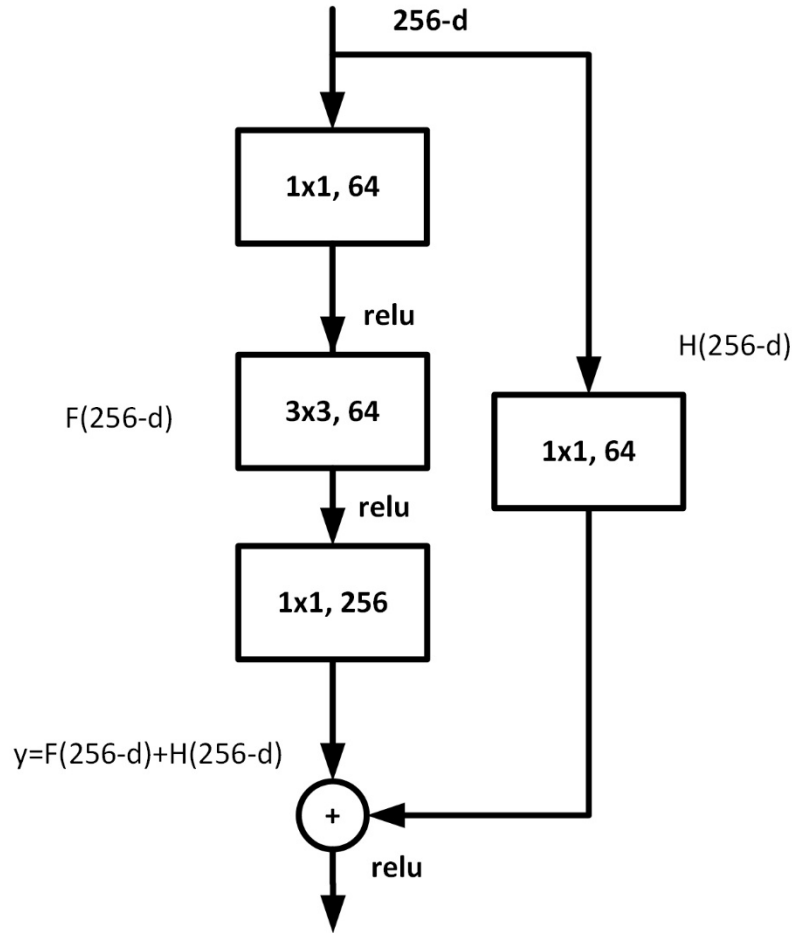
Şekil 2. Kısa yol bağlantılı darboğaz yapı bloğu

Mimari içerisinde kullanılan yapılardan birisi de darboğaz yapı bloğudur. Darboğaz yapı bloğunda katmanları atlayan kısa yol bağlantıları ($256 - d$) bulunmaktadır [19]. Darboğaz yapı bloğunda kısa yol bağlantıları blok olarak konvolüsyonel katmanların atlama temelini dayanmaktadır. Darboğaz yapı bloğu konvolüsyon, aktivasyon katmanlarına ek olarak bir kısa yoldan oluşur. Darboğaz yapı bloğu genel olarak Şekil 2'de gösterilmiştir. Şekil 2'deki yapı bloğu Denklem (1)'de sunulmuştur.

$$y = F(256 - d) + (256 - d) \quad (1)$$

Derin sinir ağları katman sayısına göre ifade edilmektedir. Katman sayısı arttıkça derinlik artmaktadır. Daha derin sinir ağlarının eğitilmesi daha zordur. Daha derin olan ağların eğitimini kolaylaştırmak için ResNets mimarisi ile artık bir öğrenme çerçevesi sunulmuştur. Katmanları, referanssız fonksiyonları öğrenmek yerine, katman girdilerine referansla öğrenen artık fonksiyonlar yerleştirilerek yeniden formüle edilmiştir. Bu artık ağların optimize edilmesinin daha kolay olduğunu ve önemli ölçüde artırılmış derinliklerin kazanılabileceğini gösteren kapsamlı bir ampirik(deneysel) kanıtlar sunmuşlardır[19]. ImageNet veri kümesinde, önceden eğitilmiş konvolüsyon sinir ağlarından özellikle VGG ağlarından 8 kat daha derin, ancak daha düşük karmaşıklığa sahip 152 katmana kadar derinliğe sahip artık ağları kullanabilir.

Derin artık ağlar (ResNets) bir çok yığılmış “Artık Birim”den oluşur.



Şekil 3. Darboğaz yapı bloğu.

Şekil 3'deki akış diyagramında 256-d değeri x_l değeridir. Her birim aşağıdaki Denklem (2) ile genel biçimde ifade edilebilir:

$$\begin{aligned} y_l &= h(x_l) + F(x_l, W_l), \\ x_{l+1} &= f(y_l), \end{aligned} \quad (2)$$

burada x_l ve x_{l+1} , l 'inci birimin girdisi ve çıktısıdır ve F bir artık fonksiyondur. $h(x_l) = x_l$ bir kimlik eşleşmesi ve f bir ReLU fonksiyonudur.

ResNets'in ana fikri, $h(x_l) = x_l$ kimlik eşleşmesi kullanılarak, $h(x_l)$ ile ilgili olarak toplam artık fonksiyonu F'yi öğrenmektir. Burada bir kısa yol atlama bağlantısı eklenerek gerçekleştirilir [19].

Önceden eğitilmiş mimari olarak ResNet50, 50 katmanlı artık bir ağıdır. Bu ağ artıkları öğrenmeyi amaçlar. Katmanın girdisinden öğrenilen özelliklerin çıkarılmasına "artık" olarak ifade edilir [5]. Çeşitli derinliklerdeki ResNet verimliliği ve doğruluğu artırmak için darboğaz özelliklerini kullanılabilir [17].

2.3. Hiperparametre Ayarı

Bu çalışmada kullanılan 2 modelin öğrenilmesini etkileyen parametreler kümesi hiperparametre olarak adlandırılır. Hiperparametrede görüntü boyutu, epoch sayısı, batch sayısı, optimizasyon yöntemi, öğrenme oranı ve düzeyici parametreleridir. Eğitim ve test işlemlerinin görüntü boyutu 64x64 ve 3 kanallıdır. Modeller eğitilirken adım sayısı 50, öğrenme oranı $1e-4$, bölüm sayısı 32 olarak ayarlanmıştır. Optimizasyonda Adamax yöntemi kullanılmıştır. Gecikme durakları öğrenme oranı adım

sayısına bölünerek belirlenmiştir. Burada kullanılan parametreler ile ulaşılan sonuçlar 3. Bölümde verilmiştir.

2.4. Performans Değerlendirme Ölçümleri

Sınıflandırma görevi gerçekleştirildikten sonra başarısının değerlendirilmesi gerekir. Sınıflandırma görevinin performansı değişik ölçütler ile ölçümlenebilir. Bu çalışmada deneysel çalışmalar, Tensorflow-GPU kullanılarak Keras kütüphaneleri ile birlikte cuda_11.5.r1 1.5 versiyonunda gerçekleştirilmiştir. Önerilen yöntem karmaşıklık matrisinden türetilen doğruluk (Accuracy), kesinlik (Precision), F-puanı (F-Score), geri çağırma (Recall) performans değerlendirme metrikleri kullanılarak değerlendirilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

Denklem 2 ve sonrasında TP doğru sınıflandırılabilen kırmızı kan hücresi örnek sayısını tanımlarken, FP yanlış sınıflandırma yapılan kırmızı kan hücresi örnek sayısını tanımlamaktadır. TN ise diğer sınıftan doğru sınıflandırılan kırmızı kan hücresi örnek sayısını tanımlamaktadır. FN ise gözlem altındaki diğer sınıftan yanlış sınıflandırılan kırmızı kan hücresi örnek sayısını temsil etmektedir. Denklem 3'te pozitif olarak sınıflandırılıp doğru tahmin edilen kırmızı kan hücresi sınıfının toplam pozitif kırmızı kan hücresi sayısına oranına geri çağırma denilmektedir. Geri çağırma formülü modelin bulunduğu doğru sınıfları tespit etmektedir. Geri çağırmanın yüksek olması doğru sınıflandırılan kırmızı kan hücresi sayısının bir o kadar fazla olduğunu göstermektedir. Geri çağırma denkleminde yanlış bulunan kırmızı kan hücresi sınıfı ile ilgilenilmemektedir. Ancak modeldeki tüm pozitif kırmızı kan hücresi doğru sınıflandırıp sınıflandırmadığının anlaşılabilmesi için geri çağırma sonuçlarının elde edilmesi gerekmektedir.

$$\text{Geri Çağırma} = \frac{TP}{TP + FN} \quad (4)$$

Kesinlik ise TP ve pozitif olarak tahmin edilen toplam kırmızı kan hücresi sayısının oranı olarak tanımlanmaktadır. Negatif kırmızı kan hücresi bazıları pozitif olarak sınıflandırma durumunda bunun tespit edilebilmesi için kesinlik denkleminde sonuç elde edilmesi gerekmektedir. Denklem 4'te kesinlik formülü verilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (5)$$

F1 puanı ise kesinlik ve geri çağırma denklemlerinden elde edilen sonuçlarının ağırlıklı harmonik ortalamasıdır. Kesinlik ve geri çağırma arasındaki dengeyi ölçebilmek için Denklem 5'da sunulan denklem kullanılmaktadır. F1 puanı bir değerine yakınsa az sayıda düşük hatalı pozitif ve negatif sayısına sahip bir model oluşturduğunu anlamına gelmektedir.

$$F1 = 2x \frac{\text{Kesinlik} \times \text{Geri çağırma}}{\text{Kesinlik} + \text{Geri çağırma}} \quad (6)$$

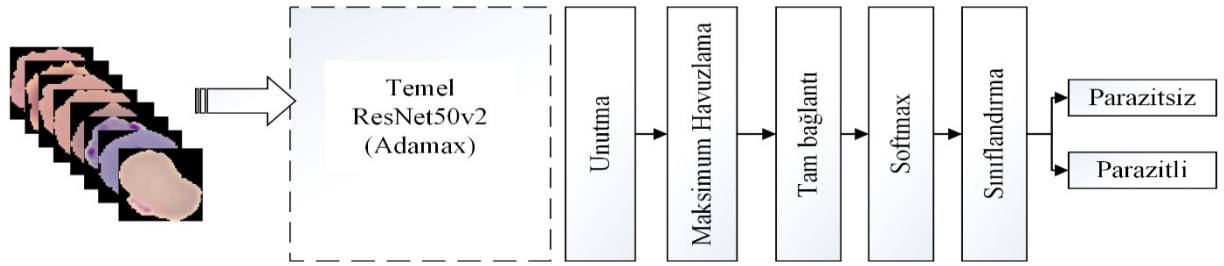
Belirtilen performans ölçüm değerlerinin tamamı bu çalışmada önerilen yöntemlerin performanslarını doğru değerlendirebilmek için kullanılmıştır. Kullanılan performans ölçümlerinin yanında doğruluk ve kayıp sonuçları grafiksel anlamda ikili çizimler ile verilmiştir. Bunlara ek olarak modellerden elde edilen karmaşıklık matrisi her bir model başlığı altında sunulmuştur. Önerilen Temel ResNet50V2 ve CNN yöntemleri ile 2 farklı model ile farklı eğitim ve test işlemleri gerçekleştirilmiştir. Denklem 3-6 arasındaki denklemlere göre her bir modelden elde edilen sonuçlar verilmiştir.

3. Önerilen Yöntemler

Bu bölüm içerisinde önerilen modellerle ulaşılan sonuçlar sunulmuştur. Bu bölümün sonunda kullanılan ve önerilen modellerin kendi içlerinde yapılan kıyaslama sonuçları verilmiştir. Bunlara ek olarak güncel literatürde Malaria Cells veri setini kullanan benzer olmayan çalışmalar ile sonuçların karşılaştırılması verilmektedir.

3.1. Temel ResNet50V2 Modeli ile Performans Sonuçları

Sıtma hastalığını tam zamanında doğru ve hızlı tanımlayabilmek için önceden eğitilmiş ResNet50V2 mimarisini temel alan 5 ağırlık katmanlı modeli Şekil 4’de gösterilmiştir. Geliştirilen model Adamax optimizasyon algoritması ile test edilmiştir. Önerilen Temel ResNet50V2 modeli, 1 adet Unutma, 1 adet Maksimum Havuzlama, 1 adet Tam bağlantı ve Sınıflandırma katmanında Softmax aktivasyon fonksiyonu kullanılmıştır. Oluşturulan sınıflandırıcı model ile Parazitli ve Parazitsiz olarak 2 kategoride sınıflandırılmıştır.



Şekil 4. Önerilen Temel ResNet50V2’li model

| Tahmin | Gerçek | | sütunToplam |
|-------------|----------------|----------------|----------------|
| | Parazitli | Parazitsiz | |
| Parazitli | 3195 38.64% | 728 8.81% | 3923 81.44% |
| Parazitsiz | 899 10.87% | 3446 41.68% | 4345 79.31% |
| sütunToplam | 4094 78.04% | 4174 82.56% | 8268 80.32% |
| | 21.96% | 17.44% | 19.68% |

Şekil 5. Önerilen ResNet50V2 yönteminin karmaşıklık matrisi

Şekil 4’de verilen modelin doğruluk ve kayıp karmaşıklık matrisi oluşturulmuştur. Oluşturulan bu matrisler Şekil 5’de gösterilmektedir. Diğer modellerin aksine önerilen Temel ResNet50V2’li CNN

modelinde Çizelge 2’de verilen K-Fold5 değerlerinden en iyi doğruluk değerine ulaşılan Kfold1 performans sonuçları seçilmiştir.

Bu karmaşıklık matrisindeki performans sonuçları daha ayrıntılı olarak Çizelge 1’de taplo halinde verilmiştir. Çizelge 1’deki sonuçlarda sadece doğruluk oranı değil, önerilen ResNet50V2 modelinin performansını değerlendirebilmek için kesinlik, geri çağırma, F1 puanı ve doğruluk ölçüm sonuçları içermektedir.

Çizelge 1. Önerilen ResNet50V2 modeli ile transfer öğrenme performans sonuçları

| Optimizasyon Yöntemi | Sınıf | Kesinlik | Geri Çağırma | F1 Puanı | Doğruluk |
|----------------------|------------|----------|--------------|----------|----------|
| Adamax | Parazitli | 0.81 | 0.78 | 0.80 | 0.80 |
| Adamax | Parazitsiz | 0.79 | 0.83 | 0.81 | |

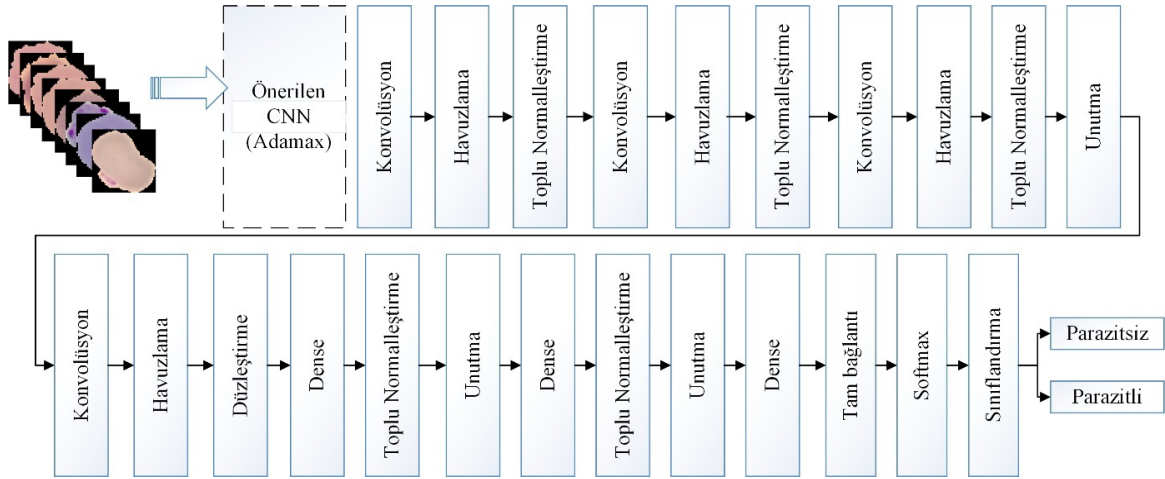
Temel RestNetV2 ile Adamax optimizasyon yönteminde elde edilen K-Fold5 ile elde edilen performans sonuçları Çizelge 2’de verilmiştir. Bu K-Fold5 değerlerinden Kfold1 değerlerinin diğerlerine göre daha yüksek olduğu görülmüştür.

Çizelge 2. Temel RestNet50V2 kfold değerlerine göre performans sonuçları

| Optimizasyon Yöntemi | Kfold | Doğruluk | Kayıp |
|----------------------|----------|--------------|-------------|
| Adamax | 1 | 79.28 | 0.72 |
| Adamax | 2 | 66.72 | 1.50 |
| Adamax | 3 | 57.94 | 2.49 |
| Adamax | 4 | 62.00 | 2.11 |
| Adamax | 5 | 64.41 | 1.72 |
| | Ortalama | 66.07 | 1.70 |


3.1. Önerilen CNN Modeli ve Performans Sonuçları

Şekil 7’de önerilen CNN modeli verilmiştir. Önerilen modelde 32 adet 3x3 filtreden oluşan ReLU aktivasyon fonksiyonuna sahip padding değeri aynı olan dört adet Konvolüsyon katmanı kullanılmıştır. Her Konvolüsyon katmanı sonrası 1x1 boyutunda 1 adet Havuzlama ve Toplu Normalleştirme katmanı kullanılmıştır. Bu şekilde 4 adet Evrişim-Havuzlama-TopluNormalleştirme bloğu kullanılmıştır. 3 adet Unutma katmanı kullanılarak ezberlemenin önüne geçilmeye çalışılmıştır. Bir adet Düzleştirme, 3 adet ReLU aktivasyon fonksiyonlu Dense katmanı, Düzleştirme katmanından sonra 2 adet toplu normalleştirme, 2 adet Unutma, 1 adet Tam bağlantı, 1 adet softmax aktivasyon fonksiyonlu sınıflandırma katmanı kullanılmıştır.



Şekil 6. Önerilen CNN Modeli

Şekil 6'de önerilen modelin doğruluk ve kayıp karmaşıklık matrisi Şekil 7'de verilmiştir. Bu önerilen CNN modelinde Çizelge 4'de verilen K-Fold5 değerlerinden en iyi doğruluk değerine ulaşılan Kfold1 performans sonuçları seçilmiştir.



Şekil 7. Önerilen CNN yönteminin karmaşıklık matrisi

Şekil 9'daki karmaşıklık matrisin Kesinlik, Geri Çağırma, F1-Puanı ve Doğruluk değerleri Çizelge 3'de verilmiştir.

Çizelge 3. Önerilen CNN modelinin performans sonuçları

| Optimizasyon Yöntemi | Sınıf | Kesinlik | Geri Çağırma | F1-Puanı | Doğruluk |
|----------------------|------------|----------|--------------|----------|----------|
| Adamax | Parazitli | 0.98 | 0.91 | 0.94 | 0.95 |
| Adamax | Parazitsiz | 0.92 | 0.98 | 0.95 | |

Öne sürülen CNN modelin Adamax optimizasyon yönteminde elde edilen K-Fold5 performans sonuçları Çizelge 4’de verilmiştir. Bu K-Fold5 değerlerinden Kfold1 değerlerinin diğerlerine göre daha yüksek olduğu görülmüştür.


Çizelge 4. Önerilen CNN modelinin kfold değerlerine göre performans sonuçları

| Optimizasyon Yöntemi | Kfold | Doğruluk | Kayıp |
|----------------------|----------|--------------|-------------|
| Adamax | 1 | 97.53 | 0.35 |
| Adamax | 2 | 97.15 | 0.80 |
| Adamax | 3 | 97.24 | 0.99 |
| Adamax | 4 | 97.40 | 0.26 |
| Adamax | 5 | 96.98 | 0.36 |
| | Ortalama | 97.26 | 0.55 |

4. Tartışma


Parazitli ve Parazitsiz hücrelerin eşit örneklerine sahip 27.558 kırmızı kan hücre görüntüsü Adamax optimizasyon yöntemi ile test edilmiştir. Bu görüntülerde önerilen Temel ResNet50V2 mimarili modelde Parazitli hücrelerde 728 ve Parazitsiz hücrelerde 899 hata oluşmuştur. Önerilen CNN modelinde ise Parazitli hücrelerde 85 ve Parazitsiz hücrelerde 367 hata oluşmuştur.

Önerilen CNN ve Temel ResNet50V2’li CNN modelleri kullanılan optimizasyon yöntemlerinden olan Adamax optimizasyon yönteminde elde edilen eğitim performans sonuçları Şekil 8’de verilmiştir. Şekil 8 incelendiğinde her iki model sonuçlarının birbirinden farklı olduğu belirlenmiştir.



Şekil 8. Önerilen CNN model ve Temel ResNet50V2’li CNN model a)Eğitim Doğruluk grafikleri, b)Eğitim Kayıp grafikleri

Önerilen CNN ve Temel ResNet50V2’li CNN modelleri kullanılan optimizasyon yöntemlerinden olan Adamax optimizasyon yönteminde elde edilen test performans sonuçları Şekil 9’de verilmiştir. Test sonuçları incelendiğinde her iki model sonuçlarının birbirinden farklı olduğu görülmektedir.



Şekil 9. Önerilen CNN model ve Temel ResNet50V2’li CNN model a) Test Doğruluk grafikleri, b) Test Kayıp grafikleri

Şekil 4 ve Şekil 6’da tasarlanmış modellerin Şekil 8 ve Şekil 9’da eğitim, test işlemlerine göre elde edilen sonuçların doğruluk ve kayıp grafikleri verilmiştir. Bunların yanında eğitimde kullanılmayan test verilerinin performans sonuçlarını daha detaylı bir şekilde inceleyebilmek için karmaşıklık matrisleri oluşturulmuştur.

İki farklı model aynı parametreler kullanılarak Malaria Cells adlı halka açık bir veri setinde değerlendirildiğinde önerilen 23 ağırlık katmanlı CNN modelin Temel ResNet50V2 mimarili modelden daha iyi bir sonuç verdiği gözlenmiştir.

Önerilen CNN modelin toplam parametre sayısı 268,673,890 olarak belirlenmiştir. Belirlenen bu parametre sayılarının 268,672,098 adeti eğitilebilir iken, 1,792 parametre adeti ise ağırlık değerleri güncellenmeyen parametredir. Parazitli sınıfta önerilen CNN model Parazitsiz hücrelere göre daha iyi sonuç vermiştir. K-fold5 değeri kullanılarak uygulamalarda aynı sonuç alınmıştır. Böylece önerilen modellerin değişmeyen kararlı bir sonuç vermesi sağlanmıştır.

Önerilen CNN modelle elde edilen test sonuçları benzer veri setleri kullanan çalışmalar ile karşılaştırılmıştır. Bu karşılaştırma sonuçları Çizelge 5’te verilmiştir. Verilen uygulama sonuçları incelendiğinde diğer benzer çalışmalar kadar başarılı bir model önerildiği görülmektedir.

Çizelge 5. Benzer çalışma sonuçları ile karşılaştırılması.

| Sınıf | Model /Yöntem | Kesinlik (%) | Geri Çağırma (%) | F1 puanı (%) | Doğruluk (%) |
|------------|-----------------------------------|--------------|------------------|--------------|--------------|
| Parazitli | Abubakar vd. [3] / SVM | 0.94 | 0.95 | 0.94 | 0.94 |
| | Irmak [7] /CNN | 0.95 | 0.95 | 0.95 | 0.95 |
| | Montalbo vd. [13] /EfficientNetB0 | 0.94 | 0.95 | 0.94 | 0.94 |
| | Rameen vd.[20] /SVM | 0.85 | 0.78 | 0.81 | 0.95 |
| | Maqsood vd. [9] / ResNet50 | 0.95 | 0.92 | 0.96 | 0.95 |
| | Temel ResNet50V2 | 0.81 | 0.78 | 0.80 | 0.80 |
| | Önerilen CNN | 0.98 | 0.91 | 0.94 | 0.95 |
| Parazitsiz | Abubakar vd. [3] /SVM | 0.94 | 0.95 | 0.94 | 0.94 |
| | Irmak E. [7] /CNN | 0.95 | 0.95 | 0.95 | 0.95 |
| | Montalbo vd. [13] /EfficientNetB0 | 0.94 | 0.95 | 0.94 | 0.94 |
| | Rameen et al.[20] SVM | 0.85 | 0.78 | 0.81 | 0.95 |
| | Maqsood vd. [9] /ResNet50 | 0.95 | 0.92 | 0.96 | 0.95 |

| | | | | | |
|--|------------------|------|------|------|------|
| | Temel ResNet50V2 | 0.79 | 0.83 | 0.81 | 0.80 |
| | Önerilen CNN | 0.92 | 0.98 | 0.95 | 0.95 |

Çizelge 6. Devamı

5. Sonuçlar

Sıtma hastalığının başarılı bir şekilde sınıflandırılması bu hastalığın tedavisinde önemli aşamalardan biri olabilir. Bu çalışmada, 27.558 kırmızı kan hücresinden sıtma parazitlerini etkin bir şekilde sınıflandırılması için en gelişmiş algoritmaları kullanan kapsamlı bir araştırma sunduk. Bu görüntülerden yararlı belirleyici öznelikleri çıkarmak için önceden eğitilmiş mevcut mimarileri test ederek kendi CNN modelimizi oluşturduk. Öne sürülen CNN model ile belirli bir kan numunesinin parazitli olup olmadığını bilmek için her bir numune ön işlemlerden geçirilerek sınıflandırılması gerçekleştirildi. Kırmızı kan hücresi görüntülerinden sıtma hastalığının doğru bir şekilde sınıflandırılması için yeni bir konvolüsyon sinir ağı modeli sunuldu. Sıtma hastalığı sınıflandırılması için kamuya açık kırmızı kan hücreli büyük bir veri seti kullanılarak yeni bir CNN modeli önerildi. Önerilen CNN modeli ile sıtma hastalığının sınıflandırılması sonucunda %97.53 gibi yüksek bir doğrulukla sağlandı. Bu çalışma ile sıtma hastalığı daha kısa sürede sınıflandırılması yapılarak doktorların hastayı daha kısa sürede tedaviye alabilecektir.

Kaynaklar

- [1] Rajaraman S., Jaeger S., Antani SK. Performance evaluation of deep neural ensembles toward malaria parasite detection in thin-blood smear images. *PeerJ* 2019; 7: e6977.
- [2] Vijayalakshmi A., Rajesh Kanna B. Deep learning approach to detect malaria from microscopic images. *Multimed Tools Appl* 2020; 79(21–22): 15297–317. Doi: 10.1007/s11042-019-7162-y.
- [3] Abubakar A., Ajuji M., Yahya IU. DeepFMD: Computational Analysis for Malaria Detection in Blood-Smear Images Using Deep-Learning Features. *Appl Syst Innov* 2021; 4(4): 82. Doi: 10.3390/asi4040082.
- [4] Tangpukdee N., Duangdee C., Wilairatana P., Krudsood S. Malaria Diagnosis: A Brief Review. *Korean J Parasitol* 2009; 47(2): 93. Doi: 10.3347/kjp.2009.47.2.93.
- [5] Singla N., Srivastava V. Deep learning enabled multi-wavelength spatial coherence microscope for the classification of malaria-infected stages with limited labelled data size. *Opt Laser Technol* 2020; 130(September 2019): 106335. Doi: 10.1016/j.optlastec.2020.106335.
- [6] Rajaraman S., Antani SK., Poostchi M., Silamut K., Hossain MA., Maude RJ., Jaeger S., Thoma GR. Pre-trained convolutional neural networks as feature extractors toward improved malaria parasite detection in thin blood smear images. *PeerJ* 2018; 6: e4568.
- [7] Irmak E. A Novel Implementation of Deep-Learning Approach on Malaria Parasite Detection from Thin Blood Cell Images. *Electrica* 2021; 21(2): 216–24. Doi: 10.5152/electrica.2020.21004.
- [8] Gopakumar GP., Swetha M., Sai Siva G., Sai Subrahmanyam GRK. Convolutional neural network-based malaria diagnosis from focus stack of blood smear images acquired using custom-built slide scanner. *J Biophotonics* 2018; 11(3): e201700003. Doi: 10.1002/jbio.201700003.
- [9] Maqsood A., Farid MS., Khan MH., Grzegorzec M. Deep Malaria Parasite Detection in Thin Blood Smear Microscopic Images. *Appl Sci* 2021; 11(5): 2284. Doi: 10.3390/app11052284.
- [10] da Costa AZ., Figueroa HEH., Fracarolli JA. Computer vision based detection of external defects on tomatoes using deep learning. *Biosyst Eng* 2020; 190: 131–44. Doi: <https://doi.org/10.1016/j.biosystemseng.2019.12.003>.
- [11] Zhang Z., Liu H., Meng Z., Chen J. Deep learning-based automatic recognition network of agricultural machinery images. *Comput Electron Agric* 2019; 166: 104978. Doi: <https://doi.org/10.1016/j.compag.2019.104978>.
- [12] Çetiner H. Yaprak Hastalıklarının Sınıflandırılabilmesi İçin Önceden Eğitilmiş Ağ Tabanlı Sinir

- Ağı Geliştirimi. *Adıyaman Üniversitesi Mühendislik Bilim Derg* 2021; 15: 442–56. Doi: 10.54365/adyumbd.988049.
- [13] Montalbo FJP., Alon AS. Empirical Analysis of a Fine-Tuned Deep Convolutional Model in Classifying and Detecting Malaria Parasites from Blood Smears. *KSII Trans Internet Inf Syst* 2021; 15(1): 147–65. Doi: 10.3837/tiis.2021.01.009.
- [14] Çetiner İ., Var AA., Çetiner H. Classification of KNOT defect types. *2014 22nd Signal Processing and Communications Applications Conference (SIU)*. IEEE; 2014. p. 1086–9.
- [15] Çetiner H. Classification of Apple Leaf Diseases Using The Proposed Convolution Neural Network Approach. *J Eng Sci Des* 2021; 9(4): 1130–40. Doi: 10.21923/jesd.980629.
- [16] Cetiner I., Var AA., Cetiner H. Classification of knot defect types using wavelets and KNN. *Elektron Ir Elektrotehnika* 2016; 22(6): 67–72.
- [17] Rahman A., Zunair H., Reme TR., Rahman MS., Mahdy MRC. A comparative analysis of deep learning architectures on high variation malaria parasite classification dataset. *Tissue Cell* 2021; 69(September 2020): 101473. Doi: 10.1016/j.tice.2020.101473.
- [18] Jaeger S. Malaria cell images dataset, National Institute of Health (NIH) 2020.
- [19] He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE; 2016. p. 770–8.
- [20] Rameen I., Shahadat A., Mehreen M., Razzaq S., Asghar MA., Khan MJ. Leveraging Supervised Machine Learning Techniques for Identification of Malaria Cells using Blood Smears. *2021 International Conference on Digital Futures and Transformative Technologies (ICoDT2)*. IEEE; 2021. p. 1–6.