

YOLOV9 İLE KAN HÜCRELERİNİN OTOMATİK TANIMLANMASI: OPTİMİZASYON ve ÖĞRENME ORANI ETKİLERİ

Zehra YÜCEL¹, Dilber ÇETİNTAŞ^{2*}

¹Necmettin Erbakan Üniversitesi, Seydişehir MYO, Bilgisayar Teknolojileri Bölümü, , Konya, Türkiye

²Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği A.B.D, Malatya, Türkiye

Geliş Tarihi/Received Date: 10.11.2023 Kabul Tarihi/Accepted Date: 30.04.2024 DOI: 10.54365/adyumbd.1388891

ÖZET

Kanda yer alan kan hücrelerinin mikroskopik incelenmesi zaman alıcı, pahalı ve hataya açık bir iştir. Bu çalışmanın amacı, kan hücresi görüntülerini kullanarak kan hücresi tiplerinin sınıflandırılması için YOLO mimarisini kullanan otomatik bir sistem geliştirmektir. Çalışmada kullanılan BCDD veri seti, 364 kan hücresi görüntüsü ve 4888 etiketli görüntüden oluşmaktadır. Açık kaynaklı BCCD veri seti, kırmızı kan hücrelerini (RBC'ler), beyaz kan hücrelerini (WBC'ler) ve trombositleri içerir. Geliştirilen senaryoda YOLOv9 mimarisi, farklı optimizasyon algoritmaları, öğrenme oranları kullanılarak hiperparametrelerin tanımlama sürecindeki etkisi gözlemlendi. Tanımlama sonuçlarını karşılaştırırken en iyi sonuca, 0,001 öğrenme oranıyla ADAMW optimizasyon algoritması kullanılarak ulaşıldı. Genel olarak kan hücresi tiplerinin sınıflandırılmasında WBC tanımlamasında 1,0'a yakın sonuç elde edildi. Daha sonra RBC tanımlaması yaklaşık olarak 0,93 doğrulukla elde edilirken trombositler 0,96 doğrulukla tanımlandı. Bu sonuçlar, önerilen sistemin kan hücresi tanımlamasının manuel sürecini otomatikleştirmeye yönelik etkili bir araç olarak kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Kan Hücresi Tespiti, Derin Öğrenme, Yolov9, Optimizasyon, Öğrenme Oranı.

AUTOMATIC IDENTIFICATION OF BLOOD CELLS WITH YOLOV9: OPTIMIZATION AND LEARNING RATE EFFECTS

ABSTRACT

Microscopic examination of blood cells in blood is time-consuming, expensive and error-prone. The aim of this study is to develop an automatic system using YOLO architecture for classification of blood cell types using blood cell images. The BCDD dataset used in the study consists of 364 blood cell images and 4888 labeled images. The open-source BCCD dataset includes red blood cells (RBCs), white blood cells (WBCs), and platelets. In the developed scenario, the YOLO v9 architecture, different optimization algorithms, and learning rates were used to observe the effect of hyperparameters in the parameter definition process. When comparing the identification results, the best result was achieved using the ADAMW optimization algorithm with a learning rate of 0.001. Overall, a result close to 1.0 was obtained in the WBC classification for blood cell types. Subsequently, the RBC identification was achieved with an accuracy of approximately 0.93, while platelets were identified with an accuracy of 0.96. These results indicate that the proposed system could be used as an effective tool for automating the manual process of blood cell identification.

Keywords: Blood Cell Detection, Deep Learning, Yolov9, Optimization, Learning Rate.

e-posta¹ : zkarhan@erbakan.edu.tr ORCID ID: <https://orcid.org/0000-0002-2863-9119>

* e-posta² : dilber.cetintas@ozal.edu.tr ORCID ID: <https://orcid.org/0000-0003-0710-2280> (Sorumlu Yazar)

1. Giriş

Yaşamsal fonksiyonların sürdürülmesinde önemli rol oynayan kan, hayati önem taşıyan canlı bir sıvıdır. Vücut ağırlığımızın yaklaşık %8' ini oluşturan kan hücresi türleri ve kandaki değerler sağlığımız açısından büyük önem taşır. Bu doğrultuda, kan değerleri ile insan sağlığı arasında doğrudan bir ilişki bulunmaktadır. Çeşitli hastalık türlerinin belirlenmesinde, hastalığın ilerlemesinin izlenmesinde ve potansiyel sağlık durumlarının analiz edilmesinde kan testleri önemlidir. Kan test sürecinde kan hücrelerinin türü ve sayısına dikkat edilmektedir. Bu analiz ile sağlık durumu hakkında bilgi edinilmektedir [1,2].

Başlıca kan hücresi türleri olarak; kırmızı kan hücrelerini (RBC), beyaz kan hücrelerini (WBC) ve trombositleri sayabiliriz. RBC'ler kana kırmızı rengini veren hücrelerdir. İçeriklerindeki hemoglobin ve eritrositler sayesinde kana oksijen taşıma görevini yerine getirirler. WBC'ler ise esnek şekillere sahip çekirdekli kan hücreleridir. Lökositlerin içeriği, organizmayı bakterilere, virüslere ve diğer zararlı ajanlara karşı koruyarak hayati savunma fonksiyonlarını yerine getirmelerini sağlar. WBC'ler bağışıklık sisteminin işlevinde ve yanıtında önemli bir rol oynar. Trombositler ise trombokinaz enziminin salgılanması nedeniyle morfolojik değişikliklere uğrayan, yapışkanlık gösteren, renksiz, çekirdekli hücrelerdir. Salgıladıkları trombokinaz enzimi nedeniyle morfolojik değişiklikler ve yapışkanlık gösterirler, bu da onları kan pıhtılaşması için gerekli kılar. Örneğin, bir yaralanma durumunda trombositler pıhtılaşma ajanı görevi görerek yaranın kapanmasına ve onarılmasına yardımcı olur [2-5].

İnsan sağlığını doğrudan etkileyen kan hücresi türlerinin manuel olarak belirlenmesi önemli zorluklar doğurmaktadır. Özellikle yoğun ve zaman alıcı süreç personel için zorlu olabilir ve sonuçlar, ilgili kişilerin uzmanlığı, becerileri ve deneyimine bağlı olarak değişiklik gösterebilir [6]. Bu nedenle, hem sağlık profesyonelleri hem de kendilerini bekleyen hastalar için sonuçları hızlandırmak amacıyla bu prosedürlerin otomatikleştirilmesi önemle tavsiye edilir. Önerilen bu çözümün uygulanmasının laboratuvarlardaki iş yükünü hafifletmesi ve hastane personelinin verimliliğini artırması bekleniyor.

Kan hücresi tiplerinin sınıflandırılması, kan testi sürecinde önemli bir zorluk teşkil etmekte ve literatürde bu sorunu ele alan çok sayıda çalışmanın yapılmasına yol açmaktadır. Bu çalışmaları görüntü işleme ve makine öğrenmesi yöntemleri ile derin öğrenmeye dayalı yöntemler olarak sınıflandırabiliriz. Diğer alanlarda olduğu gibi sağlık alanında da son yıllarda derin öğrenme üzerine yapılan çalışmaların sayısı giderek artıyor. Kan hücrelerinin sınıflandırılması ve tanımlanması gibi çeşitli görevler için derin öğrenme yöntemleri kullanılmıştır [7,8]. Kan hücrelerinin sınıflandırılması tıbbi teşhiste çok önemli bir görevdir. Literatür gözden geçirildiğinde, evrimsel sinir ağları (CNN'ler) tekniği olarak yaygın bir şekilde kullanılmaktadır. CNN'lerin uygulanmasının ardından sınıflandırma aşamasında hücre tipi ayrımı için çeşitli yöntemlerden yararlanılmaktadır.


Beş farklı kan hücresi tipinin (kırmızı kan hücreleri, trombositler, nötrofiller, lenfositler ve monositler) sınıflandırılması problemi için Habibzadeh ve ark. CNN önerdi. Önerilen modelin test veri setini %92,6 doğrulukla sınıflandırdığı görülmüştür [9]. Benzer şekilde Vatathanavaro ve ark. CNN mimarisi tabanlı ResNet-50 ve VGG-16 modellerini kullanarak beş farklı sınıfa ait kan hücrelerinin sınıflandırılması sorununu ele aldı: kırmızı kan hücreleri, trombositler, nötrofiller, lenfositler ve monositler. Test veri setinde ResNet-50 %96,52 doğruluk elde ederken VGG-16 %97,57 doğruluk elde etti [10]. Beyaz kan hücrelerini dört farklı türe (nötrofiller, eozinofiller, monositler ve lenfositler) sınıflandırma görevi için Diouf ve ark. 12.500 görüntüden oluşan bir veri seti üzerinde eğitilmiş bir CNN modeli kullandılar ve test veri setinde %95,48 başarı oranı elde ettiler [11]. Beyaz kan hücresi tiplerinin sınıflandırılmasına odaklanan başka bir çalışmada Zaho ve ark. WBC tespitini ve ardından CNN ile sınıflandırmayı gerçekleştirdi. WBC için %94,6'lık bir tanıma doğruluğuna ve %91,7'lik bir sınıflandırma doğruluğuna ulaştılar [12]. Özyurt, kan hücresi türlerini ayırt etmek için özellik seçimini kullanan bir CNN modeli önerdi ve kan hücresi görüntülerinden oluşan bir veri kümesinde %97,14 genel doğruluk elde etti [13].

Çeşitli çalışmaların sonuçları incelendiğinde, kan hücresi türlerinin otomatik olarak tanınmasının ve sınıflandırılmasının dikkate değer bir etkinlik gösterdiği ortaya çıkıyor. Bu sorunu çözmek için genellikle CNN tabanlı modeller kullanılır. CNN mimarisinin doğasında bulunan kendi kendine öğrenme yeteneği, başarısına büyük ölçüde katkıda bulunan çok önemli bir özellik olarak kabul edilir. Bu aşamada derin öğrenme ile tespit işleminde hangi parametrenin daha belirleyici olacağını bilmek sonuçlara daha hızlı ve doğru şekilde ulaşılmasını sağlayacaktır. Bu da sonuç olarak, eğitim işlemini ve modellerin performansını doğrudan etkiler.

Bu çalışmada, kan hücresi tiplerinin otomatik teşhisi için derin öğrenme kullanılmış olup, otomatik teşhis sistemleri için yardımcı bir sistem sunulmuştur. Otomatik teşhis amaçlanırken YOLOv9 mimarisi kullanılıp mevcut parametreleri üzerinde değişiklik gerçekleştirilerek hangi parametrelerin sınıflandırmada daha etkin olduğu gözlemlendi. Optimizasyon algoritması ADAMW ve öğrenme oranı 0,001 seçildiğinde en başarılı sonuçlara ulaşıldı.

2. Materyal ve Metot

Bu çalışmada kan hücrelerinin tespiti, halka açık Kan Hücre Sayımı Veri Seti (BCCD)[14] kullanılarak gerçekleştirilmiştir. BCCD veri seti üç farklı sınıfa ayrılan 364 görüntüden oluşur: WBC (beyaz kan hücreleri), RBC (kırmızı kan hücreleri) ve Plateletler (trombositler). Görüntülerin boyutları 640x480 pikseldir. Bu 364 görüntü ve üç sınıf için 4888 etiket (annotation) içermektedir. Bu etiketlerin 4155'i RBC, 372'si WBC ve 361'i platelet etiketine aittir [14]. Şekil 1, etiketleri (veri açıklamaları) belirtilmiş örnek bir görüntü yer almaktadır. Farklı kan hücre türlerinin tespit edilip tanımlanması için veri seti %80' i eğitim, %20 test olacak şekilde ayrılır.



Şekil 1. Etiket içeren örnek bir resim

2.1. Metot ve Parametreler


Nesne tespiti, bir görüntü içindeki nesnelerin uzamsal konumunun tanımlanmasını ve ilgili sınıf etiketlerinin belirlenmesini içerir. Kullanım alanı oldukça yaygın olmakla birlikte bilgisayarlı görüde öne çıkan bir araştırma alanıdır. Donanım yeteneklerindeki ilerlemelerle birlikte derin öğrenme algoritmalarının kullanımında ve yeni tekniklerin geliştirilmesinde artış yaşanmıştır.

Son yıllarda özellikle nesne tespiti alanında önemli bir popülerlik kazanan YOLO algoritması dikkat çeken tekniklerden biridir. YOLO, tüm görüntünün tek geçişte işlenmesi yaklaşımını yansıtan "Yalnızca Bir Kez Bak" anlamına gelir. YOLO, uçtan uca evrişimli sinir ağı mimarisini kullanarak nesne tespitini bir regresyon problemi olarak formüle eder. Bu yaklaşım, bir görüntüdeki birden fazla nesnenin etkili ve eş zamanlı tespitini sağlar [15].

YOLO'nun performansı, COCO veri seti üzerinde kapsamlı bir şekilde değerlendirilerek bölge bazlı nesne algılama algoritmalarına kıyasla üstünlüğünü ortaya koymuştur [16]. Ayrıca YOLO, hem görüntüleri hem de bunlara karşılık gelen sınıfları kodlayan tek bir ağ uygulaması sayesinde yüksek verimlilik elde eder. Algoritmanın dikkat çekici hızı, özellikle gerçek zamanlı uygulamalarda yaygın olarak benimsenmesine katkıda bulunmaktadır.

YOLO'nun temel çalışma prensibi, giriş görüntüsünün tek adımda bir sinir ağı üzerinden geçirilmesini ve aynı zamanda görüntü üzerinde bir ızgara (segmentasyon) oluşturulmasını içerir. İlgilenilen bir nesne bir ızgara içinde mevcutsa ve orta noktası bu bölgenin içindeyse, algoritma nesnenin genişliğini, yüksekliğini ve karşılık gelen sınıf etiketini belirler. Bazı durumlarda ilgilenilen nesne birden fazla ızgaraya yayılabilir. Bu sorunu çözmek için, gereksiz sınırlayıcı kutuların oluşturulmasını önlemek amacıyla bir güven değeri kullanılır. Daha sonra nesneyi kapsayan en yüksek güven değerine sahip sınırlayıcı kutuyu çizmek için "Maksimum Olmayan Bastırma" algoritması kullanılır [17].

YOLO algoritmasının birden fazla versiyonu mevcut olup Şubat 2024'te yayınlanan YOLO' nun en son sürümü YOLOv9 kullanılmıştır [18]. Programlanabilir Gradyan Bilgisi (PGI), bilgi darboğazı sorunuyla mücadele etmek için YOLOv9'da tanıtılan yeni bir kavramdır ve derin ağ katmanlarında temel verilerin korunmasını sağlar. Bu, güvenilir gradyanların oluşturulmasına olanak tanıyarak doğru model güncellemelerini kolaylaştırır ve genel algılama performansını iyileştirir [18,19]. Şekil 2, yayınlanan makalede yer alan PGI ya ilişkin ağ mimarileri ve yöntemlerini gösteren yapı yer almaktadır [18].



Şekil 2. PGI ve İlgili Ağ Mimarileri. (a) Path Aggregation Network (PAN) [20], (b) Reversible Columns (RevCol) [21], (c) Geleneksel Derin Denetim ve (d) önerilen Programmable Gradient Information (PGI). [18]

Eğitim sırasında ayarlanabilen hiperparametrelerden eğitim işlemini etkiler ve değerleri eğitim süreci başlamadan önce ayarlanabilmektedir. YOLOv9 ağının tasarlanması ve eğitilmesinde hiperparametreler iki gruba ayrılabilir. İlk grup, katman sayısı, filtreler ve giriş görüntülerinin boyutu dahil olmak üzere ağ mimarisi hiperparametrelerinden oluşur. İkinci grup, toplu iş boyutu, öğrenme oranı ve optimizasyon algoritması gibi eğitim hiperparametrelerini içerir [18].

YOLOv9'in yaklaşık otuz hiperparametresi vardır ve bunları farklı eğitim ayarlarına göre ayarlamak, nesne tanımanın doğruluğunu ve öğrenme oranını optimize etmek için kullanılabilir. Hiperparametreler sonucu önemli ölçüde etkileyebileceğinden, belirli bir görev için doğru olanları seçmek önemlidir [22].

Bu çalışmada YOLOv9 ağının iki eğitim hiper parametresine odaklanıldı: optimizasyon algoritması ve öğrenme oranı. Bu iki parametre eğitim sürecinde kritik bir rol oynar ve modelin

yakınsama oranını, kararlılığını ve nihai doğruluğunu etkiler. Optimizasyon algoritması, eğitim sırasında model parametrelerinin nasıl güncelleneceğini belirlerken öğrenme oranı, güncelleme işleminin adım boyutunu kontrol eder. Farklı optimizasyon algoritmalarının ve öğrenme oranlarının sonuç üzerindeki etkilerini karşılaştırarak, bunların YOLOv9 ağının performansı üzerindeki etkilerini araştırmak hedeflendi. YOLO mimarilerinde sıklıkla SGD (Stochastic Gradient Descent), ADAM (Adaptive Moment Estimation), ADAMW (Adam with Weight Decay) optimizasyon algoritmaları tercih edildiği için bu algoritmalar kullanıldı [23-25].

2.2. Performans Metrikleri

Performans değerlendirmesini yapabilmek için karmaşıklık matrisi kullanıldı. Bu matriste satırlar gerçek sınıfları sütunlar tahmin edilen sınıflandırmaları belirtmektedir. Değerlendirme metriklerini ölçebilmek için tp (doğru pozitif), tn (doğru negatif), fp (yanlış pozitif), fn (yanlış negatif) değerleri kullanılır.

Kesinlik (Precision; P): Tahmin edilenler arasında pozitif olarak belirlenen verilerin toplam pozitif sayısına oranı olarak tanımlanmaktadır. Kesinlik değerinin hesaplanması denklem 1'de verilmiştir.

$$Kesinlik = \frac{tp}{tp+fn} \quad (1)$$

Duyarlılık (Recall; R): Pozitif olarak tahmin edilmesi gereken verilerden gerçekte pozitif olarak tahmin edilen veri sayısı ile ilgili bilgi vermektedir. Duyarlılık değerinin hesaplanması denklem 2' de belirtilmiştir.

$$Duyarlılık = \frac{tp}{tp+fp} \quad (2)$$

F1-Skor: Kesinlik ve duyarlılık hesaplarının harmonik ortalaması ile hesaplanmaktadır. 0-1 arasında değerler almakta olup, 1 en iyi sonuca ulaşıldığını belirtmektedir. F1 skor değerinin hesaplanması denklem 3' te verilmiştir.

$$F1\ Skor = \frac{2tp}{2tp+fp+fn} \quad (3)$$

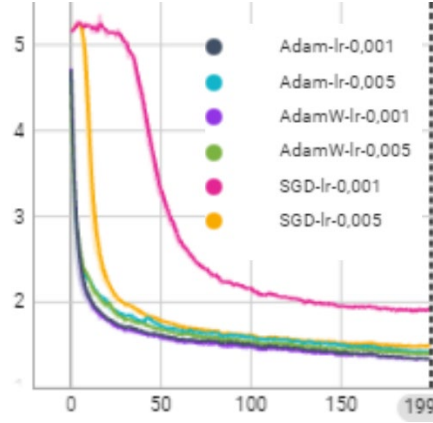
Ortalama Kesinlik Ölçütü (Mean Average Precision; mAP): Nesne tespit modellerinde algoritmaları daha kapsamlı değerlendirmek için kullanılan önemli bir metriktir. Farklı her nesne sınıfı için ayrı ayrı AP değeri hesaplanarak bu değerlerin ortalaması alınarak mAP değeri hesaplanmaktadır.

3. Sonuçlar

Bu çalışmada, Kan Hücreleri Sayımı Veri Kümesinden (BCCD) üç ayrı kategoriye ayrılan görüntülerin analizini gerçekleştirildi. Nesne algılama görevi için YOLOv9 modeli kullanıldı ve eğitim sırasında SGD (Stochastic Gradient Descent), ADAM, ADAMW optimizasyon algoritmaları ve 0,001, 0,005 öğrenme oranları kullanıldı. Farklı optimizasyon ve öğrenme oranı kombinasyonları için, yatay eksen boyunca dönem sayısı ve dikey eksen boyunca kayıp değerinden oluşan sonuç verileri kaydedildi. Literatürdeki çalışmalarla en çok tercih edilen öğrenme oranları ile algoritmalar tercih edildi.


Şekil 3'te sunulan bulgularımız, en düşük kayıp değerine 0,001 öğrenme oranıyla ADAMW optimizasyon algoritması kullanılarak ulaşıldığını gösterdi. Bu sonuçlar, YOLOv9'in hiperparametre optimizasyonunun, nesne algılama görevlerinde doğruluğun artırılmasında faydalı olabileceğini

göstermektedir. Kayıp eğrisi incelendiğinde burada SGD optimizasyon algoritmasının 0,001 öğrenme oranındaki öğrenme işleminde diğer algoritmaların gerisinde kalmaktadır. Fakat bununla birlikte SGD algoritmasının 0,005 öğrenme oranı ile eğitim işleminde diğer algoritmalara yakın sonuçlar vermektedir. Buradan optimizasyon algoritması kadar öğrenme oranının da performansı etkilediği görülür.



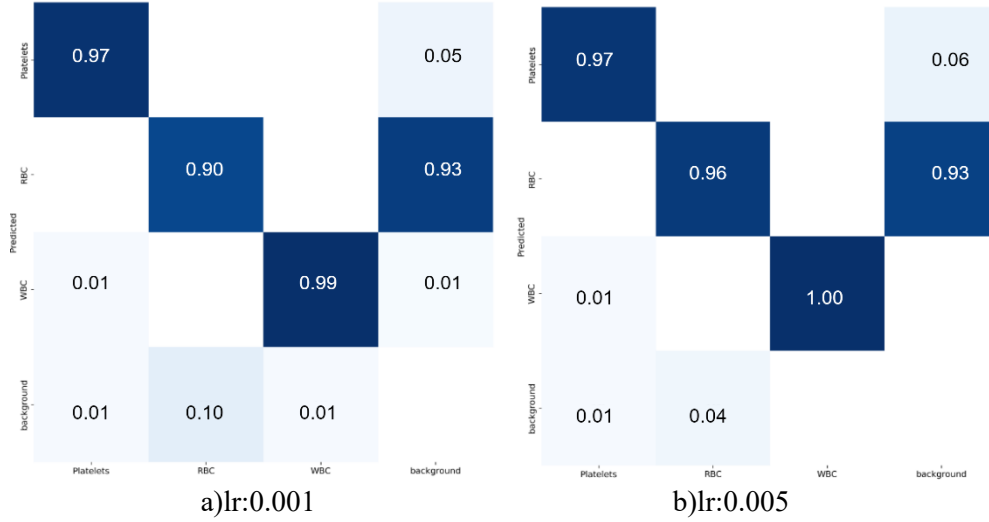
Şekil 3. YOLOv9 Kayıp Eğrisi

Bu çalışma değerlendirme aşamasında eğitilen ağın performansını değerlendirmek için model test verilerine uygulanmıştır. Sonuçlar daha sonra üç etiketli kan hücre tipi için karmaşıklık matrisi oluşturmak için kullanıldı. Farklı öğrenme oranlarının tespit performansı üzerindeki etkisini araştırmak için ADAM optimizasyon algoritmasıyla birlikte 0,001 ve 0,005 olmak üzere iki farklı öğrenme oranı kullanıldı. Şekil 4'te sunulan karmaşıklık matrisi, öğrenme oranının trombositlerin ve WBC'lerin tespit doğruluğu üzerinde nispeten minimum etkiye sahip olduğunu ortaya koymaktadır. Ancak RBC kan grubunun tespitinin, 0,001 öğrenme oranı kullanıldığında daha doğru olduğu görüldü.




Şekil 4. ADAM algoritmasının öğrenme oranlarıyla ilişkili karmaşıklık matrisi. a) lr:0.001 b) lr:0.005

YOLOv9 modelinin kan hücresi tespiti için performans değerlendirmesi, farklı öğrenme oranları ve SGD optimizasyon algoritması kullanımının sonuçlarına dayalı bir karmaşıklık matrisi oluşturularak daha ayrıntılı analiz edildi. Şekil 5'deki sonuçlar incelendiğinde; WBC ve RBC türlerinin tespit doğruluğunun öğrenme oranı seçiminden etkilendiğini, trombosit tespitinin ise etkilenmediği görülür.



Şekil 5. SGD algoritmasının öğrenme oranlarıyla ilişkili karmaşıklık matrisi. a)lr:0.001 b)lr:0.005

ADAMW optimizasyon algoritmasının sonuçlarına dayalı karmaşıklık matrisi analiz edildiğinde trombositlerin ve RBC türlerinin tespit doğruluğunun öğrenme oranı seçiminden etkilendiğini, WBC tespitinin ise etkilenmediği Şekil 6'da görülür.



Şekil 6. ADAMW algoritmasının öğrenme oranlarıyla ilişkili karmaşıklık matrisi. a)lr:0.001 b)lr:0.005


Spesifik olarak, 0,001'lik bir öğrenme oranı, RBC'ler için tespit doğruluğunun arttığını gösterirken, 0,005'lik bir öğrenme oranında SGD ve ADAM için trombosit tespiti daha yüksek doğrulukla sonuçlanırken ADAMW algoritmasında tam tersi söz konusudur. Algoritmanın WBC'leri tespit etme performansı farklı öğrenme oranlarında nispeten tutarlıydı.

Sonuçlar, optimum tespit performansını elde etmek için eğitim sırasında hiperparametrelerin ayarlanmasının önemini vurgulamaktadır. Bu bulgular, kan hücresi tespiti için nesne tanıma algoritmalarının performansını geliştirmeyi ve iyileştirmeyi amaçlayan araştırmacılar ve uygulayıcılar için değerli bilgiler sağlar.

Bu çalışmanın temel amacı, Kan Hücreleri Sayımı Veri Setinde (BCCD) nesne tespitinin doğruluğunu artırmak için en uygun optimizasyon algoritması ve öğrenme oranı kombinasyonunu bulmaktır. Değerlendirme: duyarlılık, kesinlik, mAP@0.5, mAP@0.5:0.95 değerleri ölçülerek gerçekleştirildi. Sonuçlar, farklı optimizasyon algoritmalarının ve öğrenme oranlarının performansını özetleyen değerler Çizelge 1'de sunuldu.

Çizelge 1. YOLOv9 ile hücre tipi tespitinde optimizasyon ve öğrenme oranlarının performans sonuçları

Optimizasyon Alg.	Öğrenme Oranı	Duyarlılık	Kesinlik	mAP@0.5	mAP@0.5:0.95	F1-Skor
SGD	0,001	0.837	0.903	0.901	0.586	0.868
SGD	0,005	0.834	0.901	0.913	0.652	0.866
ADAM	0,001	0.838	0.903	0.919	0.659	0.869
ADAM	0,005	0.848	0.901	0.916	0.661	0.874
ADAMW	0,001	0.853	0.914	0.927	0.665	0.882
ADAMW	0,005	0.842	0.911	0.92	0.659	0.875



Şekil 7. Aynı test görüntülerindeki farklı optimizasyon ve öğrenme oranlarına ilişkin tahmin görüntüleri a) SGD-lr:0,001 b) ADAM-lr:0,001 c) ADAMW-lr:0,001 d) SGD-lr:0,005 e) ADAM-lr:0,005 e) ADAMW-lr:0,005

Eğitilen YOLOv9 modelinin kan hücrelerinin farklı tiplerini tespit etme performansını değerlendirmek amacıyla test verilerine uygulandı. Sonuçlar tespit doğruluğu ve mAP değeri açısından analiz edilmiş olup, karşılık gelen tespit görüntüsü ve mAP değeri Şekil 7'de gösterilmektedir. Şekil 7'de, kan hücre tiplerinin tespitinin doğruluğunun görüntüler arasında farklılık gösterdiği ve belirli kan hücre tiplerinin daha yüksek mAP değeri ile tespit edildiği görülmektedir. İlk olarak WBC tespitinin öğrenme oranının 0,001 (lr:0,001) olduğunda ADAM ve ADAMW algoritmasının daha yüksek doğrulukla (0,9) tespit ettiği görülür. Fakat öğrenme oranı 0,005 (lr:0,005) olduğunda bütün optimizasyon algoritmalarının aynı mAP değeri ile tespit ettiği görülür. Bununla birlikte bazı RBC tespitinin öğrenme oranından bağımsız şekilde ADAMW algoritması tarafından tespit edildiği görülürken SGD ya da ADAM algoritmasının tespit edmediği görülür.

Bu çalışmada kan hücrelerinin görüntülerindeki kan türlerini tespit etmek için YOLOv9 derin öğrenme algoritması kullanıldı. YOLOv9 algoritmasında farklı optimizasyon algoritmalarının ve öğrenme oranlarının etkinliği deneylerle araştırıldı. Öğrenme oranı 0,001 ve ADAMW optimizasyon algoritmasının F1-Skor değeri için en iyi performansı ürettiği gözlemlenmiştir. Bir sonraki en başarılı durum ADAMW optimizasyonu ve 0,005 öğrenme oranı hiperparametreleriyle oluşmuştur. Kan hücre türlerinin sınıflandırılmasında en önemli optimizasyon algoritması ADAMW olmuştur. Elde edilen sonuçlar doğrultusunda optimizasyona ek olarak kullanılan öğrenme oranı da sonuçlar üzerinde oldukça etkili rol oynamıştır.

Boyut ve renk farklılığı olan WBC'lerin arka plandan ayrıştırılmasında daha başarılı olunurken yakın görsel değerlere sahip RBC'ler ve Trombositlerde karışıklık yaşanmış olup bu hücrelerin başarı oranlarını düşürmüştür. YOLO'nun son versiyonu olan YOLOv9 mimarisinin temel parametrelerinin değişimi ile sonuçlarının iyileştirilebileceği gösterilmiş olup daha sonra yapılacak çalışmalar için rehber niteliğindedir. Otomatik hücre türünün tespiti için önerilen bu sistem ilerleyen zamanlarda mikroskop altında farklı boyama seçenekleriyle daha iyi sonuçlara ulaştırılabilir.

Eğitilen model, test veri seti kullanılarak değerlendirildi ve sonuçlar, farklı kan hücre tipleri için tespit doğruluğunda farklılıklar olduğunu, bazı kan hücre tiplerinin ise hiç tespit edilmediğini gösterdi. Tespit doğruluğundaki tutarsızlıklar, aydınlatma koşullarındaki değişiklikler, kan hücrelerinin farklı açıları ve görüntü arka planının karmaşıklığı gibi faktörlere bağlanabilir. Bu doğrultuda, tüm kan türlerinin tespitinin doğruluğunu artırmak için daha fazla iyileştirme yapılması ihtiyacını vurgulamaktadır.

Bu çalışmanın sonuçları gözden geçirildiğinde, tıbbi görüntü analizi uygulamalarında kan hücrelerinin farklı türlerinin tespitinin doğruluğunu ve etkinliğini artırmak için değerli bilgiler sağladığı açıkça ortaya çıkıyor. Çeşitli optimizasyon algoritmalarının performansı ve öğrenme oranları, YOLOv9 kullanılarak otomatik kan grubu tanımlama bağlamında karşılaştırıldı. Bu bulgular, bu alanda çalışan diğer araştırmacılara değerli bilgiler sunarak, farklı algoritmalar arasındaki performansı değerlendirmelerine ve karşılaştırmalarına olanak sağlayabilir. Ayrıca otomatik kan hücresi türlerini belirlenmesine yardımcı sistem olarak kullanılması bu alanda zaman ve iş gücü tasarrufu da sağlayabilir. Bu çalışmaya ilave uygulamalar ve geliştirmeler yapılarak çeşitli alanlarda kullanılabilir. Bu çalışmanın hasta ve sağlık personeli açısından genel kapsamı göz önüne alındığında geniş bir kitleye fayda sağlama potansiyeli taşıdığı ve bu konuda ilerlemesinin sağlık alanında ilerlemelere katkı sağlayabileceği değerlendirilmektedir.

Çıkar Çatışması Beyanı

Makale yazarları herhangi bir kurum, kuruluş, kişi ile kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] Alberts, B. (2017). Molecular biology of the cell. Garland science.
- [2] Alomari, Y. M., Sheikh Abdullah, S. N. H., Zaharatul Azma, R., & Omar, K. (2014). Automatic detection and quantification of WBCs and RBCs using iterative structured circle detection algorithm. Computational and mathematical methods in medicine, 2014.
- [3] Faggio C, Sureda A, Morabito S, Sanches-Silva A, Mocan A, Nabavi SF, Nabavi SM. Flavonoids and platelet aggregation: A brief review. European journal of pharmacology. 2017 Jul 15;807:91-101.
- [4] Farag MR, Alagawany M. Erythrocytes as a biological model for screening of xenobiotics toxicity. Chemico-biological interactions. 2018 Jan 5;279:73-83.
- [5] Rezaatofghi SH, Soltanian-Zadeh H. Automatic recognition of five types of white blood cells in peripheral blood. Computerized Medical Imaging and Graphics. 2011 Jun 1;35(4):333-43.
- [6] Acharjee, S., Chakrabarty, S., Alam, M. I., Dey, N., Santhi, V., & Ashour, A. S. (2016, March). A semiautomated approach using GUI for the detection of red blood cells. In 2016 International conference on electrical, electronics, and optimization techniques (ICEEOT) (pp. 525-529). IEEE.
- [7] Arslan, Özkan, and Mustafa Karhan. "Effect of Hilbert-Huang transform on classification of PCG signals using machine learning." Journal of King Saud University-Computer and Information Sciences (2022).
- [8] Yaman, O., & Tuncer, T. (2022). Exemplar pyramid deep feature extraction based cervical cancer image classification model using pap-smear images. Biomedical Signal Processing and Control, 73, 103428.
- [9] Habibzadeh, Mehdi, Adam Krzyżak, and Thomas Fevens. "White blood cell differential counts using convolutional neural networks for low resolution images." International Conference on Artificial Intelligence and Soft Computing. Springer, Berlin, Heidelberg, 2013.
- [10] Vatathanavaro, Supawit, Suchat Tungjitnob, and Kitsuchart Pasupa. "White blood cell classification: a comparison between VGG-16 and ResNet-50 models." proceeding of the 6th joint symposium on computational intelligence (JSCI6). Vol. 12. 2018.
- [11] Diouf, Daouda, et al. "Convolutional Neural Network and decision support in medical imaging: case study of the recognition of blood cell subtypes." arXiv preprint arXiv:1911.08010 (2019).
- [12] Zhao, Jianwei, et al. "Automatic detection and classification of leukocytes using convolutional neural networks." Medical & biological engineering & computing 55.8 (2017): 1287-1301.
- [13] Özyurt, Fatih. "A fused CNN model for WBC detection with MRMR feature selection and extreme learning machine." Soft Computing 24.11 (2020): 8163-8172.
- [14] BCCD Veri seti. https://github.com/Shenggan/BCCD_Dataset (Erişim tarihi: Şubat 2024).
- [15] Redmon, Joseph, et al. "You only look once: Unified, real-time object detection." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [16] Lin, Tsung-Yi, et al. "Microsoft coco: Common objects in context." European conference on computer vision. Springer, Cham, 2014.
- [17] Shinde, Shubham, Ashwin Kothari, and Vikram Gupta. "YOLO based human action recognition and localization." Procedia computer science 133 (2018): 831-838.
- [18] Wang CY, Yeh IH, Liao HY. YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. arXiv preprint arXiv:2402.13616. 2024 Feb 21.
- [19] YOLOv9. <https://docs.ultralytics.com/tr/models/yolov9/> (Erişim Tarihi, Mart,2024).
- [20] Liu S, Qi L, Qin H, Shi J, Jia J. Path aggregation network for instance segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition 2018 (pp. 8759-8768).
- [21] Cai Y, Zhou Y, Han Q, Sun J, Kong X, Li J, Zhang X. Reversible column networks. arXiv preprint arXiv:2212.11696. 2022 Dec 22.

- [22] Lin, Tsung-Yi, et al. "Microsoft coco: Common objects in context." European conference on computer vision. Springer, Cham, 2014.
- [23] Bottou L. Large-scale machine learning with stochastic gradient descent. In Proceedings of COMPSTAT'2010: 19th International Conference on Computational Statistics Paris France, August 22-27, 2010 Keynote, Invited and Contributed Papers 2010 (pp. 177-186). Physica-Verlag HD.
- [24] Kingma DP, Ba J. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980. 2014 Dec 22.
- [25] Loshchilov I, Hutter F. Decoupled weight decay regularization. arXiv preprint arXiv:1711.05101. 2017 Nov 14.