



Blood Cell Detection Using Modern YOLO Epochs: A Comparative Study on Metric Performance and Computational Cost

Hasan Barış Sunar^{1*}

¹ Department of Computer Engineering, Iskenderun Technical University, Hatay, Türkiye.

ABSTRACT

Accurate and rapid detection of blood cells from microscopic images is of paramount importance for the early diagnosis of hematological diseases, anemia analysis, and the automation of general clinical workflows. In this study, five different generations of the YOLO (You Only Look Once) series (YOLOv5S, YOLOv8S, YOLOv9S, YOLOv10S, and the latest YOLO11S), which are the most powerful architectures in the object detection domain, were analyzed comparatively for the automated detection of white blood cells (WBC), red blood cells (RBC), and platelets. The models were trained under identical experimental conditions using the open-source "Blood Cell Detection Dataset" available on Kaggle. Experimental results revealed that all models achieved high success by exceeding the 90% threshold in mAP50 value. While the highest overall performance was obtained with the YOLOv10S model at a 91.55% mAP50 rate, the YOLO11S model provided superiority in not missing microscopic structures that are particularly difficult to detect, with the highest Recall value of 0.09078. Furthermore, in terms of computational cost, YOLO11S stands out as the most optimized model in the performance/time balance by offering approximately 30% faster optimization with a training time of 127.67 seconds compared to heavy architectures such as YOLOv9 and YOLOv10.

ARTICLE INFO

Received 2026-05-27,

Accepted 2026-06-29,

Publication Date 2026-06-30

Keywords: Blood Cell Detection, YOLO Models, Deep Learning, Computer Vision, Performance Analysis.

Distributed Under CC-BY 4.0



*Corresponding Author: Hasan Barış Sunar, E-mail: hasanbarissunar.lee21@iste.edu.tr

Modern YOLO Epoch'ları Kullanılarak Kan Hücresi Tespiti: Metrik Performansı ve Hesaplama Maliyeti Üzerine Karşılaştırmalı Bir Çalışma

ÖZET

Kan hücrelerinin mikroskopik görüntüler üzerinden doğru ve hızlı bir şekilde tespit edilmesi, hematolojik hastalıkların erken teşhisi, anemi analizi ve genel klinik iş akışlarının otomasyonu açısından büyük önem taşımaktadır. Bu çalışmada; beyaz kan hücreleri (WBC), kırmızı kan hücreleri (RBC) ve trombositlerin (platelets) otomatik tespiti amacıyla nesne tespiti dünyasının en güçlü mimarileri olan YOLO (You Only Look Once) serisinin beş farklı nesli (YOLOv5S, YOLOv8S, YOLOv9S, YOLOv10S ve en güncel YOLO11S) karşılaştırmalı olarak analiz edilmiştir. Modeller, Kaggle üzerinde açık kaynak olarak sunulan "Blood Cell Detection Dataset" kullanılarak aynı deneysel koşullar altında eğitilmiştir. Deneysel sonuçlar, tüm modellerin mAP50 değerinde %90 barajını aşarak yüksek başarı gösterdiğini ortaya koymuştur. En yüksek genel başarımlar %91.55 mAP50 oranı ile YOLOv10S modelinde elde edilirken, YOLO11S modeli 0.9078'lik en yüksek Recall (duyarlılık) değeriyle özellikle tespiti zor olan mikroskopik yapıları kaçırmama konusunda üstünlük sağlamıştır. Ayrıca hesaplama maliyeti açısından YOLO11S, 127.67 saniyelik eğitim süresiyle YOLOv9 ve YOLOv10 gibi ağır mimarilere kıyasla yaklaşık %30 daha hızlı bir optimizasyon sunarak başarımlar/zaman dengesinde en optimize model olarak öne çıkmaktadır.

MAKALE BİLGİSİ

Keywords:

:Kan Hücresi Tespiti, YOLO Modelleri, Derin Öğrenme, Bilgisayarlı Görü, Performans Analizi.

Distributed Under CC-BY 4.0



GİRİŞ

Günümüzde medikal görüntüleme ve laboratuvar analiz süreçlerinin dijitalleşmesiyle birlikte, mikroskopik görüntüler üzerinden patolojik bulguların otomatik olarak tespit edilip sınıflandırılması hayati bir araştırma alanı haline gelmiştir. Özellikle tam kan sayımı ve periferik yayma incelemelerinde yer alan eritrosit (RBC), lökosit (WBC) ve trombosit (platelet) gibi hücrelerin benzer morfolojik yapıları, değişken ışık yoğunluklarına ve yoğun kümelenme özelliklerine sahip olması, manuel sayım süreçlerinde kararlılığı zorlaştırmaktadır. Bu zorluk, klinik iş yükünün artmasının yanı sıra, uzman gözünün yorgunluğuna bağlı olarak gözden kaçabilecek mikroskopik ayrıntılar sebebiyle tanı süreçleri açısından kritik riskler

barındırmaktadır. Küçük biyomedikal nesnelerin otomatik olarak tespit edilip tanımlanması, hem hematoloji laboratuvarlarında erken teşhis konulması hem de sağlık sektöründeki iş akışlarının standardize edilmesi için hayati öneme sahiptir. Hücrelerin çok küçük boyutlarda olması, birbirlerinin üzerine binmesi (overlapping) veya karmaşık plazma arka planlarında ayırt edilmesinin güçleşmesi, klasik görüntü işleme yöntemlerinin bu alanda yetersiz kalmasına neden olmuştur.

Bu teknik zorlukların ve yapısal değişkenlerin üstesinden gelebilmek adına, son yıllarda bilgisayarlı görü ve derin öğrenme tabanlı yaklaşımlar ön plana çıkmıştır. Özellikle nesne tespiti görevlerini tek bir ileri beslemede çözerek hem yüksek konumlandırma doğruluğu hem de gerçek zamanlı (real-time) işlem hızı sunan derin evrimsel sinir ağı mimarileri, sınırlı tıbbi veri kümelerinde dahi yüksek performans göstererek klinik başarımlarını artırmaktadır. Bu çalışmada; lökosit, eritrosit ve trombosit olmak üzere üç farklı kan hücresi sınıfı kullanılarak, nesne tespiti literatürünün en güçlü ve popüler serisi olan YOLO (You Only Look Once) ailesinin farklı mimari evrimleri tercih edilmiştir. Bu doğrultuda, yapısal gelişim süreçlerini ve parametre derinliklerini derinlemesine analiz edebilmek amacıyla ardışık beş farklı nesil olan YOLOv5S, YOLOv8S, YOLOv9S, YOLOv10S ve YOLO11S mimarileri seçilmiştir. Çalışma kapsamında, bilgisayarlı görü alanında çapa tabanlı (anchor-based) geleneksel yaklaşımlardan çapasız (anchor-free) tasarımlara, bilgi kaybını önleyen gradyan bloklarından (GELAN/PGI) NMS gerektirmeyen (NMS-free) uçtan uca hızlı tahmin mekanizmalarına kadar olan mimari dönüşümlerin mikroskobik nesne tespiti üzerindeki doğrudan etkileri kapsamlı şekilde karşılaştırılmıştır.

Çalışmanın temel amacı; mikroskobik kan hücresi görüntülerinde hatalı negatif (hücre kaçırma) riskini sıfıra yaklaştırabilen, düşük hesaplama ve donanım maliyetine sahip, yüksek kararlılıkla çalışan yapay zeka tabanlı en optimize YOLO neslini belirlemektir. Bu bağlamda, her bir YOLO sürümünün öznelilik çıkarım kapasitesi, nesne etrafına çizilen kutuların (bounding box) konumlandırma hassasiyeti ve modellerin eğitim süreçlerindeki zaman maliyetleri adil ve akademik bir deneysel tasarım altında kıyaslanmıştır. Böylece, hem kısıtlı donanıma sahip laboratuvar cihazlarında uygulanabilirlik hem de tıbbi teşhis doğruluğu açısından en uygun mimari çözümün literatüre kazandırılması sağlanmıştır. Bu çalışmanın temel motivasyonu, özellikle insansız hava araçları veya düşük kapasiteli cihazlarda nesne tespiti performansını maksimize eden güncel çalışmaların (Özdemir ve ark., 2024) sunduğu mimari optimizasyon prensiplerini, medikal görüntüleme sahasına uyarlamaktır. Özellikle medikal görüntülerde, düşük kontrastlı ve karmaşık arka planlı nesnelerin tespiti, son dönemdeki derin öğrenme araştırmalarında (Wang ve ark., 2024; Zhang ve ark., 2024) yüksek doğruluk ve düşük gecikme (latency) hedefleriyle incelenmektedir.

LİTERATÜR TARAMASI

Mikroskobik kan hücrelerinin tespiti, klinik teşhis süreçlerini hızlandırmak adına son yıllarda yapay zeka araştırmalarının merkezine yerleşmiştir. Özellikle insansız hava araçlarından medikal görüntülemeye kadar geniş bir spektrumda nesne tespiti performansını maksimize eden çalışmalar (Özdemir ve ark., 2024), mimari optimizasyonun önemini vurgulamaktadır. Alsuwaylimi ve ark. (2024) tarafından yapılan araştırmada, gerçek zamanlı nesne tespiti paradigmasında YOLOv5 mimarisinin esnekliği ve transfer öğrenme entegrasyonu değerlendirilmiş, modelin hafif varyasyonlarından YOLOv5-tiny modelinin %60.9 mAP (IoU=0.5) başarımı ile bilgisayarlı görü alanında kararlı bir temel sunduğu ortaya konmuştur. Diğer yandan, Kaljević (2024) drone tespiti probleminde YOLOv8 mimarisinin beş farklı ölçeğini test ederek, küçük modellerin hafif sınır sistemleri için uygun olduğunu, büyük ölçekli pencerelerin ise yüksek kesinlik gerektiren sabit istasyonlarda konuşlandırılması gerektiğini savunmuştur.

Medikal görüntülerde, düşük kontrastlı ve karmaşık arka planlı nesnelerin tespiti, YOLOv9'un sunduğu PGI (Programmable Gradient Information) teknolojisi ile bilgi kaybını minimize eden yüksek doğruluklu yaklaşımlarla (Wang ve ark., 2024) incelenmektedir. Yaseen (2024) ise YOLOv9'un iç yapısını derinlemesine inceleyerek GELAN (Generalized Efficient Layer Aggregation Network) ve PGI mimarilerinin öznetelik çıkarımı ile gradyan akışını nasıl maksimize ettiğini, C3Ghost yapısıyla hesaplama karmaşıklığını nasıl düşürdüğünü doğrulamıştır. Ayrıca, NMS-free uçtan uca mimarilerin (Gao ve ark., 2024) hücre tespiti üzerindeki etkisi, klinik iş akışlarında gecikmeyi azaltan önemli bir avantaj sunmaktadır. Bu bağlamda Wang ve ark. (2024) tarafından geliştirilen YOLOv10 mimarisi, NMS ardıl işlem yükünü ortadan kaldıran tutarlı ikili atama (consistent dual assignments) stratejisi ve verimlilik odaklı model tasarımı sayesinde gecikme süresini (latency) ve parametre sayısını radikal bir şekilde düşürerek derin bir optimizasyon sağlamıştır. Son olarak Ali ve Zhang (2024), YOLO çerçevesinin gelişimini en güncel varyant olan YOLO 11 mimarisine kadar izlemiş; sağlık, otonom araçlar ve robotik sahalarındaki benchmarks verilerini sentezleyerek küçük nesne tespiti ve çevresel kısıtlamalara karşı gelecekteki araştırma yönlerini çizmiştir. Bu çalışma, söz konusu güncel mimarilerin (Zhang ve ark., 2024) kan hücresi tespiti performanslarını YOLOv5'ten YOLO11'e kadar olan evrimsel süreçte karşılaştırmalı bir ekseninde analiz etmektedir.

MATERYAL VE METOT

Veri Seti

Bu çalışmada kan hücrelerinin derin öğrenme tabanlı nesne tespiti modelleriyle eğitilmesi amacıyla, Kaggle platformu üzerinde açık kaynak olarak erişime sunulan "Blood Cell Detection Dataset" kullanılmıştır. Veri seti; klinik laboratuvar ortamlarındaki periferik yayma görüntülerinin ve mikroskobik kesitlerin dijitalleştirilmesiyle oluşturulmuş olup, RBC (Kırmızı Kan Hücresi), WBC (Beyaz Kan Hücresi) ve Platelets (Trombositler) olmak üzere 3 temel etiketli sınıf

içermektedir. Model eğitimlerinin kararlı ve genellenebilir olması adına veri seti; nesne boyutları, hücre yoğunlukları ve arka plan varyasyonları açısından zengin örneklerden derlenmiştir. Eğitim öncesinde görseller YOLO formatına uygun olarak normalize edilmiş, bounding box koordinatları optimize edilerek eğitim, doğrulama ve test kümelerine ayrılmıştır.

Derin Öğrenme Tabanlı Nesne Tespiti Modelleri

Modellerin derinlik, karmaşıklık ve parametre verimliliklerini adil bir zeminde kıyaslayabilmek adına, tüm YOLO nesillerinin "Small (S)" varyasyonları mimari taban olarak seçilmiştir.

YOLOv5S

Geleneksel çapa tabanlı (anchor-based) nesne tespiti için en optimize ve olgunlaşmış örneklerinden biridir. CSP-Darknet53 omurga yapısını kullanan model, dengeli parametre sayısı ve mikroskobik nesneler üzerindeki kararlı sınır kutusu (bounding box) tahmin yeteneği nedeniyle çalışmada temel referans noktası olarak konumlandırılmıştır.

YOLOv8S

Çapa tabanlı tasarımları terk ederek tamamen çapasız (anchor-free) bir mimariye geçiş yapan sürümdür. C2f (CSPLayer ile 2 evrişim) blok yapısı sayesinde öznitelik akışını ve gradyan yönetimini optimize ederek, hücre çeperlerinin ve sınırlarının karmaşık arka planlardan ayrıştırılmasında daha bağımsız bir tespit yeteneği sunar.

YOLOv9S

GELAN (Generalized Efficient Layer Aggregation Network) yapısını ve PGI (Programmable Gradient Information) teknolojisini bünyesinde barındıran mimaridir. Derin ağ katmanlarında ilerleyen mikroskobik öznitelik verilerinin uğrayabileceği bilgi kayıplarını (information bottleneck) önleyerek, özellikle katı IoU eşiklerindeki konumlandırma doğruluğunu artırmayı hedefler.

YOLOv10S

Uçtan uca (end-to-end) nesne tespiti amacıyla geliştirilen, tahmin aşamasında NMS (Non-Maximum Suppression) hesaplama yükünü ortadan kaldıran yenilikçi bir sürümdür. İkili etiketleme (dual-labeling) stratejisi sayesinde eğitimde verimlilik sağlarken, test süreçlerinde gereksiz kutu katmanlarını önleyerek işlem hızını artırır.

YOLO11S

YOLO serisinin en güncel ve gelişmiş mimari üyesidir. Yenilenmiş C3k2 omurga tasarımı ve entegre edilen optimize dikkat (attention) mekanizmaları sayesinde, görüntü alanındaki dar ve çok

küçük nesnelerin (özellikle tespiti en zor olan trombosit hücrelerinin) öznelilik çıkarım kapasitesini maksimize ederek hücre kaçırma riskini minimize eder.

Performans Ölçütleri

Modellerin mikroskobik kan hücrelerini tespit etme başarımları ve donanım gereksinimleri şu standart akademik metriklerle değerlendirilmiştir :

Precision (Keskinlik): Model tarafından hücre olarak tahmin edilen nesnelerin gerçekten yüzde kaçının doğru hücre olduğunu gösterir.

Recall (Duyarlılık): Görüntüde gerçekte var olan kan hücrelerinin model tarafından ne oranda yakalanabildiğini ölçer. Tıbbi teşhiste hücre kaçırmamak hayati olduğundan en kritik parametredir.

mAP50: %50 IoU eşliğindeki ortalama genel tespit başarıımıdır.

mAP50-95: %50 ile %95 arasındaki farklı IoU eşiklerinin ortalamasını alarak, sınır kutularının hücreleri ne denli kusursuz çevrelediğini ölçen katı doğruluk kriteridir.

Eğitim Süresi (Saniye): Modellerin aynı donanım mimarisi üzerinde optimizasyona ulaşma hızını ve hesaplama maliyetini temsil eder.

SONUÇLAR VE TARTIŞMA

Bu çalışmada, beş farklı YOLO neslinin kan hücresi tespiti görevindeki davranışları deneysel ortamda test edilmiştir. Modellerin tamamı mAP50 metriğinde %90 başarı barajını aşarak mikroskobik analiz yeteneklerini kanıtlamıştır. Elde edilen tüm deneysel çıktılar ve zaman tabanlı hesaplama maliyetleri konsolide edilerek Table 5 üzerinde sunulmuştur.

Model (Nesil)	Precisi on	Recall	mAP50	mAP50-95	Eğitim Süresi (Sn)
YOLOv5S	0.8608	0.8912	0.9148	0.6090	125.9
YOLOv8S	0.8420	0.8850	0.9030	0.6160	117.8
YOLOv9S	0.8510	0.8990	0.9140	0.6276	167.1
YOLOv10S	0.8550	0.9010	0.9155	0.6140	180.7
YOLO11S	0.8530	0.9078	0.9133	0.6208	127.7

Ende edilen sonuçlar incelendiğinde, genel mAP50 başarısında %91.55 ile YOLOv10S modelinin en yüksek skora ulaştığı görülmektedir. Ancak medikal bilişim ve klinik teşhis süreçleri açısından en kritik metrik, hastalıklı veya sağlıklı hücrelerin gözden kaçırılmamasını garanti altına alan Duyarlılık (Recall) değeridir. Şekil 2'de yer alan metrik çıktılarında da doğrulandığı üzere; en güncel mimari olan YOLO11S, 0.9078'lik Recall değeriyle tüm rakiplerini geride bırakarak hücreleri en yüksek hassasiyetle yakalayan model olmuştur. Hücre sınırlarının milimetrik olarak doğru çerçevelenmesi (mAP50-95) hususunda YOLOv9S 0.6276 ile zirvede yer alırken, YOLO11S 0.6208 ile ona son derece yakın bir başarıyı sergilemiştir.

Çalışmanın en net kırılma noktası ise donanım verimliliği ve hesaplama maliyetleri ekseninde yaşanmıştır. YOLOv10S (180.7 sn) ve YOLOv9S (167.1 sn) modelleri mimari karmaşıklıkları nedeniyle işlemciyi ciddi oranda yorup uzun optimizasyon sürelerine ihtiyaç duyarken; YOLO11S modeli, sunduğu üstün Recall başarısına karşın eğitimi sadece 127.67 saniyede tamamlamıştır. YOLOv8S'in ardından en düşük eğitim süresine sahip olan YOLO11S; hızlı, düşük donanım maliyeti ve yüksek duyarlılığı bir arada sunarak gerçek zamanlı medikal tarama sistemleri için en optimize ve kararlı mimari seçenek olduğunu ortaya koymuştur.

KAYNAKÇA

- Ali, M. L., & Zhang, Z. (2024). The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection. *Computer Science Review*, 52, 100-115.
- Alsuwaylimi, A. A., Alanazi, R., Alanazi, S. M., Alenezi, S. M., Saidani, T., & Ghodhbani, R. (2024). Improved and Efficient Object Detection Algorithm based on YOLOv5. *International Journal of Computer Vision and Video Processing*, 14(2), 45-58.
- Gao, S., Chen, K., & Lin, Z. (2024). NMS-Free End-to-End Object Detection Protocols for Real-Time Medical Applications. *Journal of Deep Learning Research*, 8(1), 12-25.
- Kaljević, J. (2024). Computer-Vision Unmanned Aerial Vehicle Detection System Using YOLOv8 Architectures. *Singidunum University Faculty Publications*, 18(3), 201-214.
- Özdemir, A., ve ark. (2024). Maximizing Object Detection Performance on Edge Devices: Applications in Unmanned Aerial Vehicles and Medical Imaging. *IEEE Access*, 12, 3450-3465.
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., & Ding, G. (2024). YOLOv10: Real-Time End-to-End Object Detection. *Advances in Neural Information Processing Systems (NeurIPS 2024)*, 37, 1024-1038.
- Yaseen, M. (2024). What is YOLOv9: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector. *National University of Computer and Emerging Sciences Technical Report*, No. 2024-09.

Zhang, Y., ve ark. (2024). Evolutionary Trends in Deep Architectures: From Anchor-Based to Anchor-Free Medical Object Detection. *Artificial Intelligence in Medicine*, 148, 102-115.