



GEMİ TESPİTİ UYGULAMASINDA YOLOV8 VE YOLOV9 ALGORİTMALARININ PERFORMANS DEĞERLENDİRMESİ

*Beyzanur TEKİNDEMİR¹, Fatih Ahmet ŞENEL¹

¹Süleyman Demirel Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Isparta

(Geliş/Received: 01.11.2024, Kabul/Accepted: 06.12.2024, Yayınlanma/Published: 31.12.2024)

ÖZ

Gemi tespiti ve sınıflandırması, deniz gözetimi ve izleme alanında kritik bir konu olup; balıkçılık yönetimi, göçmen izleme, deniz kurtarma ve deniz savaşlarına kadar geniş bir yelpazede uygulanmaktadır. Uzaktan algılama teknolojileri, geniş kapsama alanı ve düşük maliyetli erişim gibi avantajları nedeniyle gemi izleme için kullanılmaktadır. Bu çalışma, nesnelerin insan tarafından tespiti, sayımı ve takibi süreçlerinin bilgisayarlı görme ve makine öğrenmesi yöntemleri ile gerçekleştirilmesinin önemini vurgulamaktadır. Bu çalışmada, YOLO mimarileri, gemi tespiti ve sınıflandırmasının hızlı ve doğru bir şekilde yapılabilmesi için kullanılan bir teknoloji olarak ele alınmaktadır. YOLOv8 ve YOLOv9 mimarileri ile uzaktan algılama kullanılarak gemi tespiti çalışmaları gerçekleştirilmiştir. Gemi tespiti için 1658 görüntüden oluşan "Ships in Google Earth" adlı veri seti kullanılarak YOLOv8 ve YOLOv9 mimarilerinin performansını karşılaştırmaktadır. Eğitim ve doğrulama kayıpları, kesinlik, duyarlılık ve ortalama hassasiyet kriterleri açısından değerlendirilen modeller, eğitim sürecinde belirli bir başarı ve öğrenme hızı sergilemiştir. Her iki modelin de gemi tespitinde etkili çözümler sunduğu görülmüştür. Ancak, YOLOv9 modeli, özellikle başlangıçta daha hızlı yakınsama ve genel tespit performansında üstünlük sağlamıştır.

Anahtar kelimeler: Evrimsel sinir ağı, derin öğrenme, gemi tespiti, yolov8, yolov9.

PERFORMANCE EVALUATION OF YOLOV8 AND YOLOV9 ALGORITHMS IN SHIP DETECTION APPLICATION

ABSTRACT

The detection and classification of vessels represents a pivotal challenge in the domain of maritime surveillance and monitoring. Its applications encompass a diverse range of fields, including fisheries management, migrant monitoring, maritime rescue operations, and maritime warfare. The utilisation of remote sensing technologies for the tracking of ships is a consequence of the advantages they offer, including extensive coverage and low-cost accessibility. This study emphasizes the importance of human detection, counting and tracking of objects using computer vision and machine learning methods. In this study, the potential of YOLO architectures as a technology for rapid and precise ship detection and classification is explored. The YOLOv8 and YOLOv9 architectures were employed for the detection of ships utilising remote sensing techniques. This study compares the performance of the YOLOv8 and YOLOv9 architectures using a dataset, referred to as the "Ships in Google Earth" dataset, which consists of 1658 images for ship detection. The models were evaluated in terms of training and validation losses, precision, recall and average precision, and demonstrated a certain degree of success and learning speed during the training process. Both models were found to provide effective solutions for ship detection. However, the YOLOv9 model exhibited superior performance in terms of faster convergence and overall detection accuracy, particularly at the outset.

Keywords: Convolutional neural network, deep learning, ship detection, yolov8, yolov9.

1. Giriş (Introduction)

Nesnelerin insan tarafından tespiti, sayımı ve takibi gibi etmenler zaman kaybı, hata ihtimali ve maliyet gibi sorunlara yol açmaktadır. Bu süreçlerin bilgisayarlı görme ve makine öğrenmesi yöntemleri ile gerçekleştirilmesi bu olası sorunların çözümü için önem taşımaktadır [1]. Gemi tespiti, otomatik balıkçılık yönetimi, gemi trafiği hizmeti, liman yönetimi ve deniz savaşının gerçekleştirilmesinde temel bir konudur [2]. Gemi tespiti ve sınıflandırması, deniz gözetimi ve izlemesinde kritik zorluklar ortaya çıkarmaktadır. Bir yandan, balıkçılık yönetimi, yasadışı göçmen izleme ve deniz kurtarma gibi sivil alanlarda uygulamalar bulurlar. Öte yandan, gemiler deniz muharebesinde önemli hedeflerdir. Gemi tespiti ve sınıflandırması, deniz savaş alanının kontrolünü ele geçirme ve askeri operasyonların başarısını sağlamada büyük önem taşıyan zamanında deniz askeri istihbaratı elde etmeye yardımcı olmaktadır [3].

Uydular ve uçaklar gibi platformlara monte edilmiş sensörler tarafından kolaylaştırılan uzaktan algılama teknolojisi, kara hedeflerinin uzun mesafeli temassız görüntülenmesini sağlamaktadır [4]. Uzaktan algılama teknolojileri yüksek zamanlılık, geniş kapsama alanı, düşük maliyetli erişilebilirlik sunması ve coğrafi koşullar tarafından kısıtlarının olmaması nedenleri ile gemilerin izlenmesi için birincil yöntem olarak ortaya çıkmıştır [5]. Son yıllarda, uydu uzaktan algılama görüntüleme teknolojisinin hızla gelişmesiyle, uzaktan algılama görüntülerinden gemi hedeflerinin tespiti ve sınıflandırılması, uzaktan algılama hedef tanımının önemli bir uygulama alanı haline gelmiştir [6]. Gemi tespiti, görüntülerde gemi olup olmadığını otomatik olarak belirlemeyi, bunları hassas bir şekilde sınıflandırmayı ve yerleştirmeyi hedeflemektedir [7]. Gemi tespiti için SPOT-5, QuickBird, HRSC2016, Sentinel-1, SSDD, FGSD gibi birçok veri seti bir arada kullanılarak CNN tabanlı ve Transformer tabanlı derin öğrenme modelleri incelenmiş ve gemi tespitinin diğer gelişiminin diğer nesne tespiti çalışmalarının çok gerisinde kaldığı görülmüştür [8]. Gemi tespiti çalışmalarında karmaşık deniz ortamları, yetersiz ayırt edici özellikler, büyük ölçekli varyasyonlar, yoğun ve döndürülmüş dağılımlar, büyük en boy oranları ve pozitif ve negatif örnekler arasındaki dengesizlikler zorluklar olarak belirlenmektedir [7].

Gemi tespiti ve sınıflandırmasını tek ağda birleştiren YOLO mimarisi hızlı ve doğru sonuçların elde edilebilmesi için kullanılmaktadır [9]. Sadece Bir Kez Bak (You Only Look Once, YOLO) çerçevesine dayalı nesne dedektörleri, otomatik gemi tespitinde dikkate değer bir doğruluk göstermiştir [10]. Gemi tespiti çalışmalarında YOLO mimarisinin de sıkça kullanıldığı ve yüksek başarılar gösterdiği görülmektedir [11–14]. Gemi tespiti ve sınıflandırmasında YOLO mimarisinin etkinliği, çeşitli iyileştirmelerle daha da artırılmıştır. Örneğin, SAR-LtYOLOv8 modeli, çok ölçekli özellikleri geliştiren ve küçük nesnelerin algılanmasını optimize eden yapıları içermektedir. Bu model, özellikle karmaşık deniz ortamlarında gemi tespiti için üstün performans sergilemektedir ve HRSID ve SSDD veri kümelerinde dikkate değer bir doğruluk artışı sağlamıştır [15]. Benzer şekilde, Ship-Fire Net, gemi yangınlarının hem içeride hem de dışarıda tespiti için hafif bir yapı sunarak yüksek hızlı ve hassas bir çözüm olarak öne çıkmıştır. Bu model, YOLOv8 tabanlı olup, GhostNet ve SConv gibi yenilikçi özelliklerle donatılmıştır ve 0.9 mAP@0.5 doğruluk seviyesine ulaşmıştır [16]. Ayrıca, aktif kontur ve YOLOv8 tabanlı modeller, SAR görüntülerinde gemi hedeflerinin hassas tespiti ve sınıflandırılması için önerilmiştir. Bu modeller, hem doğruluk hem de kapsam açısından dengeli sonuçlar sunarak karmaşık deniz senaryolarında umut verici bir çözüm sunmaktadır [17].

Bu çalışmada YOLO mimarilerinden YOLOv8 ve YOLOv9 kullanılarak uzaktan algılama ile gemi tespitinin yapılması hedeflenmiştir.

Bu çalışmanın ikinci bölümünde kullanılan yöntemler ve veri seti hakkında bilgi verilmiştir. Üçüncü bölümde deneysel çalışmalardan elde edilen sonuçlar ve dördüncü bölümde ise sonuçların bir değerlendirilmesi yapılmıştır.

2. Materyal ve Metot (Material and Method)

2.1. YOLO algoritması (YOLO algorithm)


YOLO, 2015 yılında Joseph Redmon ve arkadaşları tarafından 'You Only Look Once: Unified, Real-Time Object Detection' başlıklı bir makale yayımlanmasıyla bilgisayarlı görüş topluluğuna tanıtılmış ve nesne tespiti için birleşik bir model olan YOLO tam görüntüler üzerinde doğrudan eğitilebilir ve model

oluşturulması basit olarak belirtilmiştir [18]. YOLO, nesne algılama görevini hesaplama karmaşıklığını azaltan tek bir regresyon problemi olarak ele almaktadır. Temel fikir, tüm görüntüyü ağa giriş olarak kullanmak ve doğrudan çıkış katmanında sınırlayıcı kutu koordinatlarını ve sınıf olasılıklarını döndürmektir [19]. Sonraki yıllarda YOLOv1'den YOLOv9'a kadar birçok YOLO sürümü geliştirilmiştir. Şekil 1'de YOLO mimarisinin zamanla geliştirilen versiyonları verilmektedir.



Şekil 1. YOLO Tarihsel Gelişim Çizelgesi (YOLO Historical Development Chart) [20]

Temel olarak YOLO mimarileri 3 ana bölümden oluşmaktadır. Bunlar; omurga (Backbone), boyun (Neck) ve baş (Head) bölümleridir. Omurga bölümünde girdi olarak verilen resimlerin öz niteliklerinin çıkarılması işlemleri gerçekleştirilir. Boyun bölümde çıkarılan öz niteliklerin birleştirilme ve seçilme işlemleri gerçekleştirilirken baş bölümünde ise tahminleme yapılır. Şekil 2'de YOLO mimarisinin bölümleri görsel olarak verilmiştir.



Şekil 2. YOLO Mimarisinin Bölümleri (Parts of YOLO Architecture) [21]

2016 yılında YOLO9000 olarak da bilinen YOLOv2 tanıtılmış ve bu modelde, "batch normalization" kullanılarak eğitim süresi kısaltılmış ve model doğruluğu artmıştır. Ayrıca daha fazla nesne sınıfını algılayabilen bir ağ yapısı olan Darknet-19 geliştirilmiştir. YOLOv2, çeşitli veri kümelerinden öğrenebilen "kapsamlı eğitim" (joint training) tekniğini kullanarak, nesne sınıflandırma performansını artırmıştır [22]. 2018 yılında Darknet-53 olarak bilinen yeni bir ağ yapısı kullanılmış ve çoklu ölçeklerde tespit yapılabilmesi sağlanmıştır ve önceki versiyonlara göre daha gelişmiş bir mimariye sahip olduğu, özellikle daha küçük nesnelerin tespitinde performansının iyileştirildiği öne sürülmüştür [23]. 2020 yılında CSPDarknet53 mimarisini kullanarak geliştirilen YOLOv4, mozaik veri arttırma, CIOU kaybı ve SAM bloğu gibi yenilikçi tekniklerle önceki versiyonlara göre hem daha yüksek doğruluk hem de daha iyi hız sağlayarak gerçek zamanlı nesne tespiti için güçlü bir model olarak sunulmuştur [24]. Aynı yıl Ultralytics tarafından geliştirilen ve PyTorch tabanlı bir model olan YOLOv5, eğitim sürecini basitleştiren, geniş bir kullanıcı kitlesine ulaşan, hızlı ve hafif bir model olarak tanıtılmıştır [25]. 2022 yılında YOLOv6 PyTorch tabanlı ve hız ile doğruluk açısından YOLOv5'e alternatif olarak geliştirilmiştir [26]. Aynı yıl YOLOv7 nesne tespitinde yüksek doğruluğa sahip bir model olarak ve özellikle gerçek zamanlı uygulamalar için optimize edilerek geliştirilmiştir [27]. Önceki YOLO modellerine göre mimari, hız, doğruluk ve kullanım kolaylığı açısından çeşitli geliştirmeler

içeren YOLOv8 modeli tanıtılmıştır [28]. Yakın bir zamanda YOLOv9 derin bir sinir ağına dayalı bir nesne algılama algoritması olarak geliştirilmiştir [29].

2.2.YOLOv8 algoritması (YOLOv8 algorithm)

Ultralytics, Ocak 2023'te tanıtılan YOLOv8 [28], kullanıcılara kapsamlı bir dizi geliştirme ve çok yönlü yetenekler sunarak YOLO serisinde önemli bir gelişme göstermiştir [30]. Mimari, kayıp fonksiyonları ve segmentasyon yeteneklerindeki ilerlemeleriyle YOLOv8, çok çeşitli uygulamalar için güçlü bir araç olarak öne çıkmaktadır [20]. YOLOv8 tarafından önerilen C2f (Cross Stage Partial) modülü, derin öğrenme ağları içindeki gradyan akışını önemli ölçüde iyileştirerek, modelin öğrenme yeteneğini artırmakta ve dolayısıyla daha hızlı bir NMS (Non-Maximum Suppression) sürecine zemin hazırlamaktadır. Bu modül, katmanlar arası geçişlerdeki bilgi kaybını minimize ederken, katmanların iş birliğini güçlendirir ve öğrenim sürecinde daha verimli bir gradyan akışı sağlar. Gradyan akışının optimize edilmesi, modelin daha kısa sürede daha yüksek performans göstermesine olanak tanır, çünkü bu durum ağırlıkların güncellenmesi sırasında daha etkili bir geri yayılım sağlar. Böylece, C2f modülü, tespit süreçlerinde zaman tasarrufu sağlarken aynı zamanda algoritmanın genel verimliliğini artırmaktadır [31].

2.3.YOLOv9 algoritması (YOLOv9 algorithm)

Omurga ağının birincil işlevi, giriş görüntüsünden özellikler çıkarmaktır. Bu, özellik haritasını iki ayrı bölüme ayıran omurga olarak CSPDarknet53 kullanılarak elde edilir. Bir bölüm derin evrimsel katmanlardan geçerken, diğeri hafif evrimsel katmanlardan geçer ve daha sonra bu iki bölüm özellik gösterimini geliştirmek için yeniden birleştirilir. Gradyan kaybolması sorununu azaltmak için artık bir yapı benimsenir. Özellik birleştirme ağı, özellik birleştirmeyi başarmak için Mekansal Piramit Havuzlama (SPP) modülleri ve Yol Toplama Ağı (PAN) modülleri kullanarak farklı ölçeklerdeki özellik haritalarını entegre etmekle görevlendirilmektedir. Bununla birlikte, YOLOv9 modeli, önceki nesil YOLO modellerinden birçok kavramı bünyesinde barındırmaktadır. Örneğin, YOLOv5'ten elde edilen CSP Bloğu, YOLOv6'dan alınan RepVGGBlock ve YOLOv7'den entegre edilen ELAN bloğu, YOLOv9'un RepNCSPELAN4 modülünde bir araya getirilmiştir. Bu entegre yapı, modelin öğrenme kapasitesini artırarak daha karmaşık nesne tespiti görevlerinde daha yüksek doğruluk oranları elde edilmesini sağlamaktadır [32].

2.4. Veri Seti (Data set)

Bu çalışmada, veri seti olarak Kaggle üzerinde orijinal olarak barındırılan ve daha sonra Roboflow tarafından kullanıma sunulan "Ships in Google Earth" veri seti kullanılmıştır. Veri seti, toplamda 1658 görüntüden oluşmaktadır. Bu görüntülerin tamamı uydu çekimi olup gemileri kuş bakışı görecektir. Ayrıca veri seti farklı hava şartlarını, farklı ışık şiddetlerini (gece-gündüz) ve farklı tip, uzunluktaki gemi resimlerinden meydana gelmektedir. Veri seti, modelin eğitimi, doğrulaması ve testi için üç farklı kümeye ayrılmıştır. Eğitim seti, toplam görüntülerin %86'sını oluşturan 1420 görüntüden oluşurken, doğrulama seti %10'luk bir payla 159 görüntüye sahiptir. Test seti ise toplamda %5'lik bir payla 79 görüntü içermektedir. Görüntüler, Google Earth'ten çıkarılmış ve çözünürlüğü genellikle 30 ila 50 cm arasında olan görüntülerden oluşur. Görüntüler, genellikle boş okyanus arka planına karşı farklı boyutlarda gemi/tekne içerir, ancak bazı görüntüler, gemilerin sahil şeridine yakın ya da birden fazla teknenin küme halinde olduğu durumlarla da yakalanmıştır.

Veri ön işleme sürecinde, görüntüler öncelikle otomatik yönlendirme (Auto-Orient) uygulanarak düzgün bir hale getirilmiştir. Ardından, görüntüler, modelin işlemesi için daha uygun bir hale getirmek amacıyla 640x640 piksel olacak şekilde yeniden boyutlandırılmıştır (Resize: Stretch to 640x640).

Veri artırma (augmentation) sürecinde ise, her eğitim örneği için 3 çıktı oluşturulmuştur. Bu süreçte, görüntüler yatay olarak çevrilmiştir (Flip: Horizontal) ve hem saat yönünde hem de saat yönünün tersine 90 derece döndürülmüştür (90° Rotate: Clockwise, Counter-Clockwise). Her gemi, YOLOv5 dahil olmak üzere model eğitimine uygun bir şekilde sınırlayıcı kutu (bounding box) ile etiketlenmiştir [33].

3. Araştırma Bulguları (Research Findings)

Yapılan çalışmada her iki YOLO mimarisi de 25 iterasyon çalıştırılmıştır. Her iki model içinde batch_size değeri 16 olarak seçilmiştir. 25 iterasyon sonrasında modelin eğitimdeki başarısında değişiklik azaldığı için eğitim süreci tamamlanmıştır. Eğitimin başarısı kesinlik, duyarlılık ve ortalama hassasiyet (mAP) metriklerine göre karşılaştırılmıştır. Denklem 1, 2 ve 3'te sırasıyla kesinlik, duyarlılık ve ortalama hassasiyet formülleri verilmiştir.

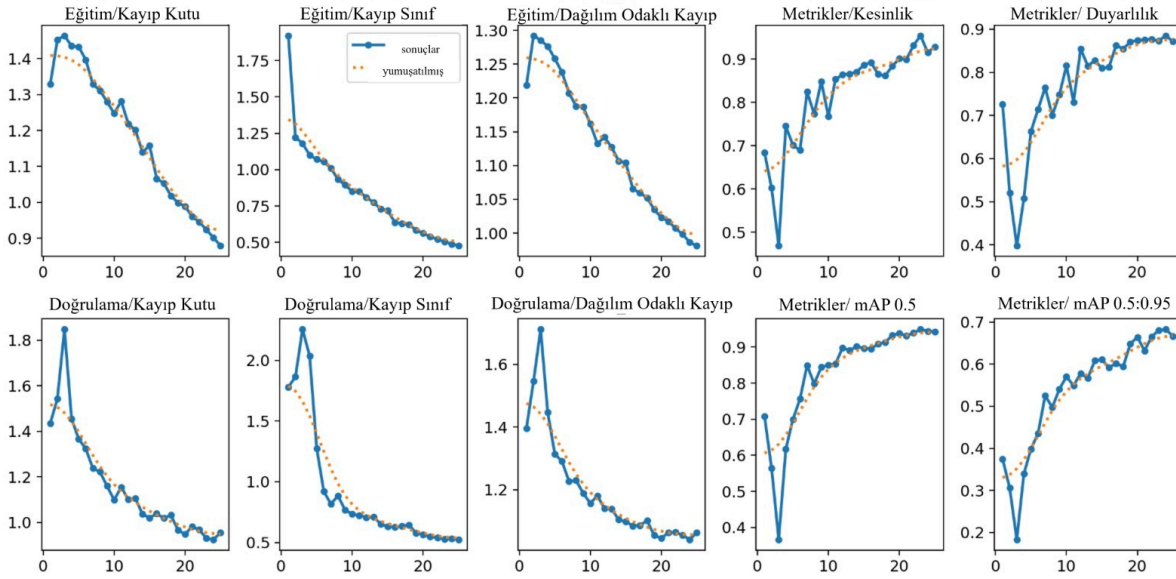
$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (1)$$

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


$$\text{Ortalama Hassasiyet} = \frac{\sum_1^c AP(c)}{c} \quad (3)$$

Burada TP doğru pozitif, FP yanlış pozitif, FN yanlış negatif sınıflandırılmış örnek sayılarını ifade etmektedir. AP her bir sınıf için ortalama kesinlik değerini ifade ederken, c sınıf sayısını temsil etmektedir.

YOLOv8 ve YOLOv9 modellerinin eğitim süreçleri boyunca elde edilen eğitim metrik değerlerinin değişimini gösteren grafikler Şekil 3 ve Şekil 4'te sunulmaktadır.



Şekil 3. YOLOv8 Eğitim Metrikleri (YOLOv8 Training Metrics)



Şekil 4. YOLOv9 Eğitim Metrikleri (YOLOv9 Training Metrics)

Bu grafikler, modellerin eğitim sürecindeki başarısını ve öğrenme hızını göstermektedir. YOLOv8 ve YOLOv9'un performans analizi eğitim kayıpları, doğrulama kayıpları, kesinlik ve duyarlılık değerleri, ortalama hassasiyet kriterleri açısından değerlendirilmiştir. Eğitim kayıpları açısından bakıldığında; YOLOv8 ve YOLOv9'un eğitim kayıp değeri iterasyon sayısı arttıkça azalma eğilimi göstermektedir. Ancak, YOLOv8'in kayıp eğrileri biraz daha yumuşak olması daha stabil bir eğitim süreci olduğunu göstermektedir. YOLOv9'un eğitim kayıpları başlangıçta daha hızlı bir düşüş göstermektedir ve bu da modelin daha hızlı yakınsadığını işaret etmektedir. YOLOv8 ve YOLOv9'un doğrulama kayıpları da zamanla azalmakta, ancak eğitim kayıplarına göre daha fazla dalgalanma göstermektedir. YOLOv9'un doğrulama kayıpları sonlarda biraz daha düşük görünmekte, bu da doğrulama setinde daha iyi bir genelleme performansı sergilediğini göstermektedir. Yine de her iki modelde de bir miktar dalgalanma mevcut olduğundan modele ek düzenleme veya veri artırımı uygulanmasının faydalı olabileceği öngörülmektedir.

YOLOv9, eğitimin başlarında YOLOv8'e göre biraz daha yüksek kesinlik ve duyarlılık değerlerine ulaşmaktadır. Bu, özellikle bu veri seti için daha iyi bir tespit kapasitesine işaret etmektedir. YOLOv8'in duyarlılık değerleri başlangıçta daha düşük, ancak zamanla YOLOv9'un seviyelerine yaklaşmaktadır. YOLOv9, YOLOv8'e kıyasla daha yüksek mAP değerlerine ulaşmakta (özellikle başlangıç iterasyonlarında) bu durum genel tespit performansının daha iyi olduğunu göstermektedir. Modellerin mAP@0.5:0.95 değerlerindeki fark mAP@0.5'e göre daha küçük, bu da her iki modelin yüksek Intersection over Union (IoU) eşiklerinde iyi performans sergilediğini ancak YOLOv9'un daha küçük ya da kısmen gizli nesnelere tespitinde ufak bir üstünlük sağladığını göstermektedir.

4. Tartışma ve Sonuç (Discussion and Conclusion)

İki model, YOLOv8 ve YOLOv9, bu çalışmada gemi tespiti uygulaması için incelenmiştir. Her iki model de YOLO (You Only Look Once) ailesinin üyeleri olup, nesne tespiti ve görüntü segmentasyonu için son teknoloji çözümler sunmaktadır. Bulgularda gözlemlenen sonuçlar doğrultusunda YOLOv9, genel olarak mAP ve duyarlılık açısından YOLOv8'e göre biraz daha iyi performans sergilemektedir. YOLOv9'un gelişmeleri özellikle erken iterasyonlarda belirgin, bu da modelin daha hızlı yakınsadığını ve daha az iterasyon ile eğitildiğinde bile yüksek performans gösterebileceğini işaret etmektedir. Eğer önceliğiniz tespit kalitesi ise, YOLOv9 bu veri seti için daha iyi bir seçim olabilir. Ancak, seçim aynı zamanda çıkarım hızı ve hesaplama verimliliği gibi diğer faktörlere de bağlı olabilir. Her iki modelin de gemi tespiti için etkili çözümler sunduğu görülmüştür. Ancak, YOLOv9'un performansı ve verimliliği, onu gemi tespiti uygulaması için özellikle cazip bir seçenek haline getirirken, YOLOv8 daha geniş bir uygulama yelpazesi sunmaktadır. Bu nedenle, seçim, belirli bir uygulamanın gereksinimlerine ve mevcut kaynaklara bağlı olacaktır.

YOLOv8 ve YOLOv9 mimarileri ile gemi örneklerinden oluşan bir veri setinin sınıflandırılması başarı ile gerçekleştirilmiştir. YOLO mimarilerinin başka türdeki veri setleri üzerinde de başarılı sonuçların elde edildiğine dair literatürde çalışmalar bulunmaktadır. Gelecekteki çalışmalarda, sadece gemi türleri değil deniz araçlarının birçoğunu kapsayacak bir veri seti ile çalışılması planlanmaktadır. YOLO mimarilerinin gelişimi ile en güncel YOLO mimarilerinin kullanımı gelecekteki çalışmalarında başarılı sonuçlarla yapılabileceğine imkân tanıyacaktır.

5. Kaynaklar (References)

- [1] M. Çelik, F. Akar, C. Bayılmış, D. Akgün, A real-time valve counting system based on YOLOv8, in: 2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP), IEEE, 2024, pp. 1–5, <https://doi.org/10.1109/IDAP64064.2024.10710962>.
- [2] H. Li, L. Deng, C. Yang, J. Liu, Z. Gu, Enhanced YOLO v3 Tiny Network for Real-Time Ship Detection from Visual Image, IEEE Access 9 (2021) 16692–16706, <https://doi.org/10.1109/ACCESS.2021.3053956>.
- [3] C. Zhang, X. Zhang, G. Gao, H. Lang, G. Liu, C. Cao, Y. Song, Y. Guan, Y. Dai, Development and Application of Ship Detection and Classification Datasets: A review, IEEE Geosci Remote Sens Mag (2024), <https://doi.org/10.1109/MGRS.2024.3450681>.
- [4] B. Li, X. Xie, X. Wei, W. Tang, Ship detection and classification from optical remote sensing images: A survey, Chinese Journal of Aeronautics 34 (2021) 145–163, <https://doi.org/10.1016/j.cja.2020.09.022>.
- [5] Z. Zhao, K. Ji, X. Xing, H. Zou, S. Zhou, Ship surveillance by integration of space-borne SAR and AIS - Review of current research, Journal of Navigation 67 (2014) 177–189, <https://doi.org/10.1017/S0373463313000659>.
- [6] E. Chuvieco, Fundamentals of Satellite Remote Sensing: An Environmental Approach, n.d.
- [7] T. Zhao, Y. Wang, Z. Li, Y. Gao, C. Chen, H. Feng, Z. Zhao, Ship Detection with Deep Learning in Optical Remote-Sensing Images: A Survey of Challenges and Advances, Remote Sens (Basel) 16 (2024), <https://doi.org/10.3390/rs16071145>.
- [8] M.J. Er, Y. Zhang, J. Chen, W. Gao, Ship detection with deep learning: a survey, Artif Intell Rev 56 (2023) 11825–11865, <https://doi.org/10.1007/s10462-023-10455-x>.
- [9] A.F. Bayram, V. Nabiyevev, Derin öğrenme tabanlı saklanan kamufle tankların tespiti: son teknoloji YOLO ağlarının karşılaştırmalı analizi, Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi (2023), <https://doi.org/10.17714/gumusfenbil.1271208>.
- [10] S. Wang, Y. Li, S. Qiao, ALF-YOLO: Enhanced YOLOv8 based on multiscale attention feature fusion for ship detection, Ocean Engineering 308 (2024), <https://doi.org/10.1016/j.oceaneng.2024.118233>.
- [11] Y. Gong, Z. Chen, W. Deng, J. Tan, Y. Li, Real-Time Long-Distance Ship Detection Architecture Based on YOLOv8, IEEE Access 12 (2024) 116086–116104, <https://doi.org/10.1109/ACCESS.2024.3445154>.
- [12] L. Ting, Z. Baijun, Z. Yongsheng, Y. Shun, Ship Detection Algorithm based on Improved YOLO V5, in: Proceedings - 2021 6th International Conference on Automation, Control and Robotics Engineering, CACRE 2021, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 483–487, <https://doi.org/10.1109/CACRE52464.2021.9501331>.
- [13] X. Cao, J. Shen, T. Wang, C. Zhang, Ship Detection Based on Improved YOLOv8 Algorithm, in: 2024 3rd International Conference on Robotics, Artificial Intelligence and Intelligent Control, RAIIC 2024, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 20–23, <https://doi.org/10.1109/RAIIC61787.2024.10670907>.
- [14] S. Liang, X. Liu, Z. Yang, M. Liu, Y. Yin, Offshore Ship Detection in Foggy Weather Based on Improved YOLOv8, J Mar Sci Eng 12 (2024), <https://doi.org/10.3390/jmse12091641>.
- [15] Z. Zhang, L. Tan, R.L.K. Tiong, Ship-Fire Net: An Improved YOLOv8 Algorithm for Ship Fire Detection, Sensors 24 (2024), <https://doi.org/10.3390/s24030727>.

- [16] C. Niu, D. Han, B. Han, Z. Wu, SAR-LtYOLOv8: A Lightweight YOLOv8 Model for Small Object Detection in SAR Ship Images, *Computer Systems Science and Engineering* 48 (2024) 1723–1748, <https://doi.org/10.32604/csse.2024.056736>.
- [17] T. Singh, T. Babu, R.R. Nair, P. Duraisamy, Ship Detection in Synthetic Aperture Radar Imagery: An Active Contour Model Approach in Computer Vision Deep Learning, in: *Procedia Comput Sci*, Elsevier B.V., 2024, pp. 1793–1802, <https://doi.org/10.1016/j.procs.2024.04.170>.
- [18] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, You only look once: Unified, real-time object detection, in: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, 2016, pp. 779–788, <https://doi.org/10.1109/CVPR.2016.91>.
- [19] Y. Yin, H. Li, W. Fu, Faster-YOLO: An accurate and faster object detection method, *Digital Signal Processing: A Review Journal* 102 (2020), <https://doi.org/10.1016/j.dsp.2020.102756>.
- [20] M. Hussain, YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection, *Machines* 11 (2023), <https://doi.org/10.3390/machines11070677>.
- [21] J. Terven, D.M. Córdova-Esparza, J.A. Romero-González, A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS, *Mach Learn Knowl Extr* 5 (2023) 1680–1716, <https://doi.org/10.3390/make5040083>.
- [22] J. Redmon, A. Farhadi, YOLO9000: Better, Faster, Stronger, (2016), <http://arxiv.org/abs/1612.08242>.
- [23] J. Redmon, A. Farhadi, YOLOv3: An Incremental Improvement, (2018), <http://arxiv.org/abs/1804.02767>.
- [24] A. Bochkovskiy, C.-Y. Wang, H.-Y.M. Liao, YOLOv4: Optimal Speed and Accuracy of Object Detection, (2020), <http://arxiv.org/abs/2004.10934>.
- [25] Q. Yu, Y. Han, X. Gao, W. Lin, Y. Han, Comparative Analysis of Improved YOLO v5 Models for Corrosion Detection in Coastal Environments, *J Mar Sci Eng* 12 (2024), <https://doi.org/10.3390/jmse12101754>.
- [26] C. Li, L. Li, H. Jiang, K. Weng, Y. Geng, L. Li, Z. Ke, Q. Li, M. Cheng, W. Nie, Y. Li, B. Zhang, Y. Liang, L. Zhou, X. Xu, X. Chu, X. Wei, X. Wei, YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications, (2022), <http://arxiv.org/abs/2209.02976>.
- [27] C.-Y. Wang, A. Bochkovskiy, H.-Y.M. Liao, YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, (2022), <http://arxiv.org/abs/2207.02697>.
- [28] M. Talib, A.H.Y. Al-Noori, J. Suad, YOLOv8-CAB: Improved YOLOv8 for Real-time Object Detection, *Karbala International Journal of Modern Science* 10 (2024) 56–68, <https://doi.org/10.33640/2405-609X.3339>.
- [29] J.J. Yen, Y.H. Pan, C.H. Wang, Deer Species and Gender Detection system based on YOLO v9, in: *11th IEEE International Conference on Consumer Electronics - Taiwan, ICCE-Taiwan 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 463–464, <https://doi.org/10.1109/ICCE-Taiwan62264.2024.10674650>.
- [30] M. Sohan, T. Sai Ram, Ch.V. Rami Reddy, A Review on YOLOv8 and Its Advancements, in: 2024, pp. 529–545, https://doi.org/10.1007/978-981-99-7962-2_39.
- [31] S. Du, W. Pan, N. Li, S. Dai, B. Xu, H. Liu, C. Xu, X. Li, TSD-YOLO: Small traffic sign detection based on improved YOLO v8, *IET Image Process* 18 (2024) 2884–2898, <https://doi.org/10.1049/ipr2.13141>.
- [32] Y. Li, M. Wang, C. Wang, M. Zhong, A method for maize pest detection based on improved YOLO-v9 model, in: *2024 7th International Conference on Computer Information Science and Application Technology, CISAT 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 858–861, <https://doi.org/10.1109/CISAT62382.2024.10695307>.
- [33] Robin Public, Roboflow Universe, <https://Universe.Roboflow.Com/Robin-Public/Kaggle-Ships-in-Google-Earth-Dfqwt> (2022).