

Optik Görüntülerdeki Deniz Vasıtalarının Derin Öğrenme Yöntemleriyle Tespiti ve Sınıflandırılması

Yahya İZALA^{1,*}, Yaşar BECERİKLİ^{1,2,**}

¹Bilgisayar Mühendisliği / Mühendislik Fakültesi, Kocaeli Üniversitesi, Türkiye
²Adli Bilişim İhtisas Dairesi, Adli Tıp Kurumu, İstanbul, Türkiye

*yahyaizala@gmail.com

**ybecerikli@kocaeli.edu.tr

(Geliş Tarihi: 06 Temmuz 2023, Kabul Tarihi: 24 Temmuz 2023)

(5th International Conference on Applied Engineering and Natural Sciences ICAENS 2023, July 10 - 12, 2023)

ATIF/REFERENCE: İzala, Y. & Becerikli Y. (2023). Optik Görüntülerdeki Deniz Vasıtalarının Derin Öğrenme Yöntemleriyle Tespiti ve Sınıflandırılması. *International Journal of Advanced Natural Sciences and Engineering Researches*, 7(6), 139-144.

Özet – Optik görüntüler neredeyse etrafımızı sarmış durumdadır. Uydulardan, insansız hava araçlarından ve mobil cihazlardan elde edilen görüntüler çalışmanın önemli veri kaynaklarını teşkil etmektedir. Günümüzde yaygın olarak kullanılan insansız hava araçları ve yapabildikleri işler düşünüldüğünde, özellikle düzensiz göçmen sorunları ve çeşitli güvenlik protokollerinin uygulanması gereken ülkemizde optik görüntülerin incelenmesi önem arz etmektedir. Ülkemizdeki sınırların yer yer fazla yükseltiyeye sahip olması, deniz sınırlarının fazla olması gibi nedenlerle insanın fiziksel olarak takip edemeyeceği konumlarda, insansız hava araçları (İHA) ve uyduların kullanılması zorunluluk haline gelmektedir. Kullanılan bu araçlardan elde edilen görüntülerin otomatik olarak incelenmesi ve bir karar protokolünün işletilmesi açısından önemlidir. Bu çalışmada gemi türlerinin tespit edilmesi ve sınıflandırılması amaçlandığından hedef görüntüler gemi türleri ile sınırlı tutulmuştur.

Anahtar Kelimeler – İnsansız Hava Araçları, Gemi Tespiti, Otomatik Gemi Tespiti ve Sınıflandırma, Gemi Sınıflandırma

I. GİRİŞ

İnsansız Hava Araçları (İHA) birçok uygulama alanına sahiptir. Kurumsal olarak paket servisi, arazi gözetimi, izinsiz balık avı, maden (değerli taş, altın vs.) arama, trafik takibi ve kuşların hava alanlarında takibi gibi işlerde kullanılmaktadır. Son zamanlarda İHA'ların askeri amaçla da kullanılması ile gündemi çokça meşgul ettiği görülmektedir. Temel olarak İHA'lar halk arasında dron olarak bilinen bir insan veya otonom olarak kontrol edilebilen insansız hava araçlarıdır. Kullanım amaçlarına bağlı olarak dronlar çeşitli aksesuarlarla donatılabilmektedir. Çalışmanın özünü oluşturan dronlar, bir kamera sistemine

sahip olup bu kamera sistemi ile yapılan çekimler önem arz etmektedir. Yapılan çekimlerin görüş alanı (viewport) çok geniş olabilmektedir. Bu görüş alanından dolayı nesnelere olduğundan çok daha küçük görülmektedir. Cisimlerin küçük olması hedef tespitini zorlaştırmaktadır. Bu çalışmada İHA görüntülerinden elde edilen optik resimlerden gemi tespiti ve sınıflandırılması ele alınacaktır.

Bu çalışma 6 bölüm halinde olup, çalışmanın 2. bölümünde literatür incelemesi, 3. bölümünde kullanılan veri kümesi 4. bölümde materyal ve yöntem, 5. bölümünde bulgular ve 6. bölümünde sonuçlar verilmiştir.

II. LİTERATÜR İNCELEMESİ

P. Mittal ve ark. [1] yaptıkları inceleme (Survey) çalışmasında İHA'ların elde ettiği görüntülerden hedef tespitinde kullanılan yöntemleri incelemişler. Bu çalışmadaki görüntüler düşük çekimdeki veri setlerinden oluşmakta olup karşılaşılan sorunlar küçük nesnelerin olması ile nesnelerin üst üste binmesi olarak gösterilmiştir. Ayrıca çalışmada sınıf dengesizliği ve odak hatası (focal loss) diğer aşılması gereken bir problem olarak bahsedilmektedir. P. Luo ve ark. [2] yaptığı çalışmada İHA'ya bağlanan bir kamera sistemi sayesinde durgun ve hareketli araçların tespiti için bir model önerilmiştir. İHA görüntüleri üzerine yapılan çalışmaların çoğunda görüntü işleme bir sunucu üzerinde yapılmaktadır. Bu işlem yüksek bantlarda veri aktarımını gerektirdiği için maliyetli bir işlem olabilmektedir. Ayrıca bağlantı her zaman stabil olmayabileceği gibi anlık olarak değerlendirilmede gecikmelerin olması söz konusudur. C. Wang ve ark. Yaptıkları çalışmada yukarıda belirttiğimiz duruma çözüm olarak Faster R-CNN (Region Convolutional Neural Network) yöntemini önermiştir. [3] Bu yöntemde görüntü işlemeyi daha hızlı yapan algoritma kullanılarak hem yüksek veri bağlantısı gereksinimi çözmüş hem de oluşabilecek gecikmeler en aza indirgemıştır. Ayrıca [4] çalışmasında Faster R-CNN tabanlı olan Detectron2 frameworkü ile yapılan Global Road Damage Detection Challenge 2020, yarışmasında iyi bir derece yapmıştır.

Hedef tespiti için Tek aşamalı (One Stage) veya İki aşamalı (Two Stage) algoritmaların kullanılabilir. İki aşamalı algoritmalar biraz daha yavaş çalışan ve yüksek hesaplama gerektiren algoritmalar. Diğer taraftan tek aşamalı algoritmalar daha az karmaşık ve daha hızlı çalışabilmektedir. Z. Xu ve ark. [5] yaptıkları çalışmada YOLO (You Only Look Once) v2 tek aşamalı algoritmasını kullanarak İHA görüntülerinden araç tespiti yapmıştır. Özellik çıkarımı için yoğunluk topolojisi (dense topology) ve optimal havuzlama (optimal pooling) stratejileri birleştirilerek küçük hedeflerden yüksek oranda belirleyici alanların çıkarılması sağlanmıştır. İHA görüntülerindeki hedeflerin küçük olması, eğer sunucu tarafında bir hedef tespiti yapılacaksa ortamdaki sinyali bozan parazitler, gürültü, çekim açısı ve birçok nesnenin aynı sahnede olması geleneksel sınıflandırma yöntemlerinin zayıf başarısıyla sonuçlanacaktır.

Berkeley Üniversitesindeki Ross B. Girshick ve diğerleri Bölgesel tabanlı CNN (R-CNN) kullanarak geleneksel sınıflandırma başarısını artırmakla kalmamış aynı zamanda bilim çevrelerince geniş yankı uyandırmışlardır. Daha sonra Ross B. Girshick ve ekibi R-CNN algoritmasını optimize ederek Fast R-CNN algoritmasını geliştirmişlerdir. Daha sonra YOLO ve SSD (Single Shot Detection) yöntemleri geliştirilmiştir. T. Zhao ve ark.[6] yaptıkları çalışmada YOLO ve SSD yöntemleri regresyon tabanlı oldukları için küçük hedefleri bulmakta çok başarılı olamadığını iddia ederek ResNet algoritmasını önermektedir. Y. Hu ve ark. [7] yaptıkları çalışmada İHA görüntülerinden hedef tespiti için YOLO v3 kullanmışlardır. Yapılan çalışmada 3 farklı özellik yerine 4 farklı özellik haritası kullanılmıştır. 4 farklı özelliğin kullanılması daha fazla doku ve eğrelti sağlamıştır. Yapılan çalışma kullanılan önceki çalışmalarla karşılaştırılmış ve sonucun daha iyi olduğu görülmüştür. Y. Hu ve ark. YOLO v3 (Şekil 2.3) algoritmasını fast R-CNN, faster R-CNN ve Multi-SDD ile karşılaştırarak karşılaştırmalı bir sonuç elde etmiştir. C. Zu ve ark. [8] yaptıkları İHA görüntülerinden gemi tespiti çalışmasında, nesnelerin ön plan segmentasyonu için genel arka plan modeli Grabcut algoritması tabanlı bir yaklaşım sunmuştur. Çalışmada öncelikle denizlerin içinde bulunduğu resimlerden örnek bir şablon hazırlanmıştır. Bölge genişleme algoritması (Region Growing Algorithm) ile bu şablondaki üçlü haritalar (Trimap) oluşturulmuştur. Bu çıktılar Grabcut için arka plan olarak başlangıçta verilmiştir. Geliştirilen algoritma düşük seviyelerdeki görüntülerden iyi bir sonuç vermekle kalmamış ayrıca Grabcut algoritmasının çıkaramadığı arka plan sonuçlarının çıkarılmasını da sağlamıştır. İki aşamalı sınıflandırıcı kullanılarak gerçekleştirilen çalışmada görüntüden alanlar seçilerek bu seçilen bölgelere CNN algoritmasının uygulanarak sınıflandırma işleminin yapılması sağlanmaktadır. Alan tespiti için edged box, mean shift, region proposal network ve feature pyramid network gibi yöntemler denenmiştir. İki aşamalı yöntemlerin pahalı ve gömülü sistemlere entegre edilmesi ile performans artırımı zor olduğundan tek aşamalı yöntemlerin kullanılması önerilmektedir. Tek aşamalı yöntemler YOLO ailesi, SSD, DSSD ve RetinaNet gibi algoritmalar. Kullanılan bu yöntemlerin

küçük hedefler için en uygunun seçimi başarıyı doğrudan etkileyebilmektedir. Genel olarak literatür çalışmasında küçük hedefler, çekilen görüntünün açısı, hava şartları, ortam gürültüsü gibi nedenler hedef tespitini zorlaştırmaktadır. İki aşamalı yöntemlerin maliyetli olmasından dolayı tek aşamalı yöntemlerin kullanılması uygun görülmektedir.

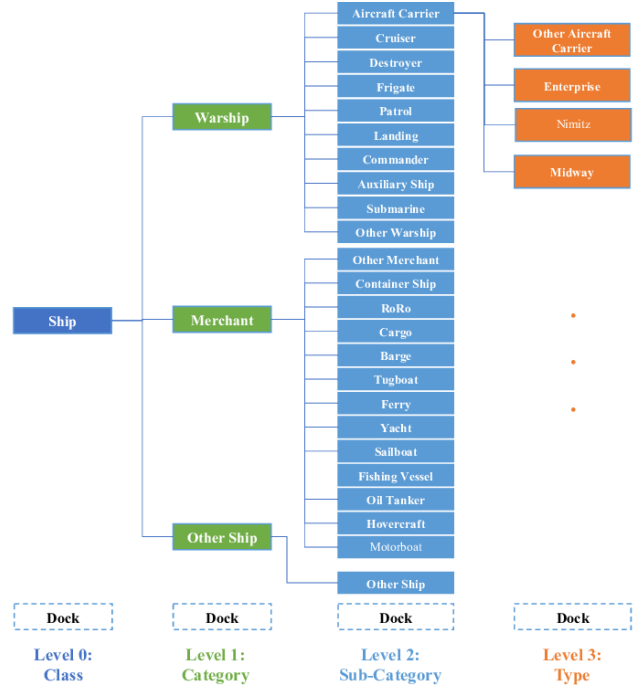
III. VERİ KÜMESİNİN HAZIRLANMASI

Gemi sınıflandırma alanında [9] yapılan literatür çalışmasında deniz vasıtalarını tespit etmek için kullanılan veri kümeleri listelenmiştir. Ele alınan çalışmada önemli görülen veri kümeleri Tablo 1'de gösterilmiştir.


Tablo 1. Deniz Veri Kümeleri Tablosu

Veri Kümesi	Resim adedi	Gemi sınıf sayısı
VAIS	2865	15
ABOShips	98880	9
MCShips	14,709	13
Singapore	17,450	6
SeaShips	31,455	6
MARVEL	2,000,000	29
HRSC2016	1061	19
Airbus Ship Detection	208,162	1
BCCT200	800	4
ShipRSImageNet	3435	50

Yaptığımız çalışma açısından kullanımı daha uygun olan ShipRSImageNet veri kümesi seçilmiştir. Bu veri kümesinde yaklaşık olarak 3324 adet görüntü ile deniz vasıtaları kategorize edilmiş ve genel kullanıma açık olarak yayımlanmıştır. Bu veri kümesinde öncelikle 4 seviyeli bir hiyerarşi kurulmuş ve 50 adet farklı gemi türü tanımlanmıştır. Birinci seviyede gemi, ikinci seviyede savaş, ticari ve diğer gemiler olmak üzere 3 farklı kategori oluşturulmuştur. Son seviyede ise gemiye ait tam adı tanımlanmıştır. (Şekil 1)



Şekil 1. ShipRSImageNet organizasyon şeması



Şekil 2. ShipRSImageNet kullanılan veri setinin dağılımı

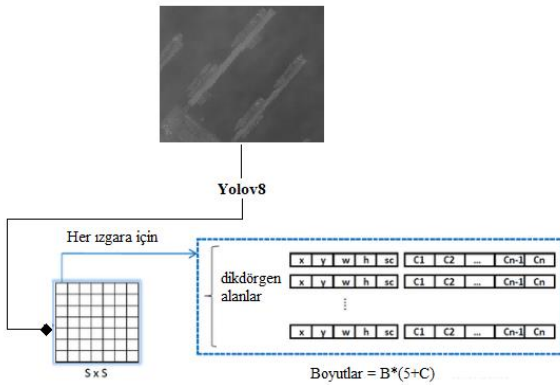
ShipRSImageNet, veri setinde gemi dışında rihtım (Dock) olarak etiketlenmiş dikdörtgen alanlar da bulunmaktadır. Bunun sebebi rihtımın gemi tanımada önemli bir unsur olduğudur.[9] çalışmasında, veri setlerinin birbirine yakınlığından dolayı bazı literatür çalışmalarında dağ, ağaç, yapılar, gökyüzü ve iskele sınıflarının da tanımlandığı görülmektedir. Bu işlemin sebebi nesnelere arasındaki farkın daha belirgin olmasını sağlamaktır. Ele aldığımız veri kümesinde görüntüler Eğitim (Train), Doğrulama (Validation) ve Test olmak üzere 3 farklı kategoriye ayrılmıştır. (Şekil 2) Daha sonra bu veri kümeleri sırasıyla tek aşamalı nesne tanıma algoritmalarında olan Yolov8 ve ikili aşamalardan olan Mark-RCNN mimarileriyle geminin tespiti ve sınıflandırılması sağlanmıştır.

IV. MATERYAL VE YÖNTEM

İHA görüntülerinde gemi tespiti için yapılan çalışmalar incelendiğinde makine öğrenmesi ve derin öğrenme yöntemlerinin bazen beraber bazen de ayrı ayrı kullanıldığı görülmektedir. Yapılan çalışma nesne tanıma ve sınıflandırma üzerinde yapıldığından makine öğrenmesi yöntemleri bu çalışmada yer verilmemiştir. Nesne tanıma sistemleri genel olarak iki aşamalı ve tek aşamalı olmak üzere iki farklı şekilde ilerlemektedir. Tek aşamalı algoritmalar verilen görüntüyü karelere (gridlere) bölme yöntemine, çift aşamalı yöntemler ise verilen görüntüde nesne olabilecek bölgelere yoğunlaşmaktadır.

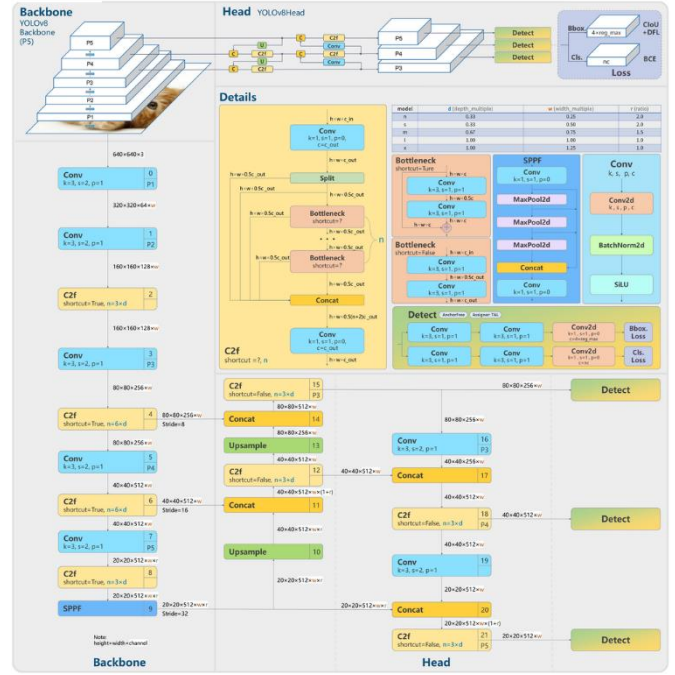
A. YOLO (You Look Only Once)

YOLO algoritması tek aşamalı bir algoritmadır. Algoritmada tüm görüntüye ait ilgili parçalara bakmak yerine, görüntü ızgara şeklinde parçalara ayrılır (Şekil 3). Bu şekilde dikdörtgensel bölgeler ve sınıflar tahmin edilmeye çalışılır. Tespit edilecek olan görüntüye ait merkez koordinatları, yükseklik, genişlik ve bu görüntüye ait sınıf tanımlanması ilk başta algoritmaya verilir.



Şekil 3. Resimlerin ızgaralara ayrılması ve sınıfların yüklenmesi

Algoritmada verilen bir kutuda, herhangi bir nesne tespit edilmezse bu arka plan olarak değerlendirilir. Ayrıca bir nesneyi bulan birden fazla kutu varsa bu kutulardan birinin seçilmesi gerekmektedir. Bu işlem için non-max suppression denilen bir yöntem kullanılır. YOLO mimarisi Ön işlemeden sonra elde edilen özellikler derin konvülyasyonel yapay sinir ağı ile eğitilerek uygun bir model oluşturulmaktadır (Şekil 4).



Şekil 4. Yolov8 mimarisi


B. Mark-RCNN

Detectron2 nesne tanıma sistemi, dikdörtgen alanları (Bounding Box), semantik parçalama (Semantic Segmentation) gibi alanlarda kullanılmaktadır. Facebook araştırma grubu tarafından geliştirilmiştir. Aslında bu bir modelden daha çok var olan modellerin daha rahat kullanılabilirdiği bir framework olarak düşünmek gerekir. Detectron2 modeli bir önceki Detectron modelinin yeniden yazılması ile oluşturulmuş ve kullanıma açılmıştır. Genel olarak iki aşamalı algoritmaları kapsamaktadır. Bu çalışma için Mask-RCNN modeli nesne tanıma için koşulmuştur. Bu modelde öncelikle bir konvülyasyon katmanıyla özellikler çıkarılmaktadır. Ardında özellik piramit ağı (Feature Pyramid Network) uygulanmaktadır. Özellik piramit ağından sonra önemli bölgeler tahmin edilmektedir (Region Of Interesting Point). Son olarak elde edilen bu bölgelerden önemli olan çerçeveleri çıkarmak için tam bağlı katmandan geçirilerek nihai sonuca ulaşılmaktadır.

V. BULGULAR


Hazırlanan modeller, hazırlanan veri seti %70 eğitim %10 doğrulama ve %20 test olmak üzere ayrıldıktan sonra uygulanmıştır. Bu modellerde daha önce elde edilen katsayılar kullanılarak daha ince bir ayar (fine tüne) yapılması ve az bir iterasyon ile daha iyi sonuçların alınması amacıyla

koşulmuştur. Veriler üzerindeki iterasyon sayısı Yolov8 için 25, Mask-RCNN için ise 2000 olarak belirlenmiştir. Hiper parametreler standart olarak kullanılmıştır. Elde edilen doğrulama hataları Şekil 5'te gösterilmiştir.



Şekil 5. Elde edilen sonuçlara ait doğrulama hataları (a) Yolov8 (b) Mask-RCNN

Modeller uygulandıktan sonra elde edilen sonuçlara göre dikketgensel bölgeler ve olasılık oranları görüntü üzerinde işaretlenerek saklanmıştır. (Şekil 6)



Şekil 6. Tespit edilen gemiler ve tespit olasılıkları

VI. SONUÇLAR

Yaptığımız çalışma ile İHA görüntülerinden gemi tespiti kullanılan yöntemler araştırılarak hızlı ve anlık (Real time) için uygun olan bir algoritma tespit edilmiştir. YOLO bu gereklilikleri taşıdığından dolayı birincil algoritma olarak uygulanmıştır. Yolo ailesinin birçok çeşidi olmasından dolayı en son sürümü kullanılmıştır. Ayrıca iki aşamalı bir algoritma olan Detectron2 frameworkünün sağladığı Mask-RCNN mimarisi

de kullanılarak Yolov8 algoritmalarıyla karşılaştırılmıştır. Elde edilen sonuçlara göre Yolov8 mimarisinin hem hızlı hem de daha iyi sonuçlar verdiği görülmüştür. Yolov8 mimarisi ile elde edilen sonuçlarda hem küçük gemiler hem de büyük gemilerin tespitinin yapıldığı fakat Mask-RCNN modelinde büyük gemilerin tespit edilmesinde sorunların olduğu veya tespit oranının daha az olduğu görülmüştür. Görüntülerin çözünürlüklerinin çok büyük olması, hava şartlarının güneşli ve aydınlık olması gibi nedenlerden dolayı, hava şartlarına göre bir çalışmanın yapılması ve verilen algoritmaların bu ortamlarda da uygulanması gerekmektedir. Bu aşamada veri setinin genişletilmesi gerekmektedir. Bir sonraki aşamada yapılacak çalışmalarda farklı hava şartlarında elde edilen görüntülerden gemi tespitinin yapılması ve sınıflandırılması ele alınacaktır. Ayrıca literatür çalışmalarımızda elde ettiğimiz makine öğrenme yöntemleri de geliştirilerek ve genişletilerek uygulanması ve derin öğrenme yöntemleriyle karşılaştırılması sağlanacaktır.

KAYNAKLAR

- [1] P. Mittal, R. Singh, and A. Sharma, "Deep learning-based object detection in low-altitude UAV datasets: A survey," *Image and Vision Computing*, vol. 104. Elsevier Ltd, 01-Dec-2020.
- [2] P. Luo, F. Liu, X. Liu, and Y. Yang, "Stationary vehicle detection in aerial surveillance with a UAV," *Proc. - ICIDT 2012, 8th Int. Conf. Inf. Sci. Digit. Content Technol.*, vol. 3, pp. 567–570, 2012.
- [3] C. Wang, R. Zhao, X. Yang, and Q. Wu, "Research of UAV target detection and flight control based on deep learning," in *2018 International Conference on Artificial Intelligence and Big Data, ICAIBD 2018*, 2018, pp. 170–174.
- [4] V. Pham, C. Pham, and T. Dang, "Road Damage Detection and Classification with Detectron2 and Faster R-CNN," *Proc. - 2020 IEEE Int. Conf. Big Data, Big Data 2020*, pp. 5592–5601, 2020.
- [5] Z. Xu, H. Shi, N. Li, C. Xiang, and H. Zhou, "Vehicle Detection under UAV Based on Optimal Dense YOLO Method," *2018 5th Int. Conf. Syst. Informatics, ICSAI 2018*, no. Icsai, pp. 407–411, 2019.
- [6] T. Zhao, J. Liu, and Z. Duan, "UAV Target Detection based on RetinaNet," *Proc. 31st Chinese Control Decis. Conf. CCDC 2019*, pp. 3342–3346, 2019.
- [7] Y. Hu, X. Wu, G. Zheng, and X. Liu, "Object Detection of UAV for Anti-UAV Based on Improved

- YOLO v3,” 2019.
- [8] C. Xu, D. Zhang, Z. Zhang, and Z. Feng, “BgCut: Automatic ship detection from UAV images,” *Sci. World J.*, vol. 2014, no. April, 2014.
- [9] E. Teixeira, B. Araujo, V. Costa, S. Mafra, and F. Figueiredo, “Literature Review on Ship Localization, Classification, and Detection Methods Based on Optical Sensors and Neural Networks,” *Sensors*, vol. 22, no. 18, p. 6879, Sep. 2022.