

DENİZ TAŞIMACILIĞI KAYNAKLI EMİSYONLARIN BELİRLENMESİNDE UZAKTAN ALGILAMA YAKLAŞIMI

Cemre Fazilet Aldoğan¹, Hande Demirel²

¹İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, Coğrafi Bilgi Teknolojileri Programı, 34469, Sarıyer, İstanbul

²İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü, 34469, Sarıyer, İstanbul

aldogan17@itu.edu.tr, demirelha@itu.edu.tr

Özet

Aşırı hava olaylarının görülme sıklığının artması ve iklim değişikliğinin önemli nedenlerinden birinin ulaştırma kaynaklı emisyonlar olduğu bilinmektedir. Emisyonların tahmini için ulaştırma hareketliliğinin izlenmesi gerekli olup, uzaktan algılama veri ve yöntemleri; sürekliliği geniş kapsama alanı ve ilgili diğer veriler ile bütünleştirilme kolaylığı nedeniyle öne çıkmaktadır. Bu çalışmada deniz taşımacılığı kaynaklı emisyonların tahmin edilmesi için bölgesel ölçekte gemi hareketlerinin derin öğrenme algoritmalarından YOLOX ile tespit edilmesi amaçlanmıştır. Sentinel-2 verisi ulaştırma hareketliliğinin izlenmesinde ve emisyon tahmininde yardımcı bir veri kaynağıdır. Bu sebeple, kara-deniz, çevre ve iklim izleme verileri araştırmacılara ücretsiz sunulmakta olduğu Avrupa Uzay Ajansı Copernicus programının bir parçası olan Sentinel-2 RGB görüntülerinden yeni bir veri seti oluşturulmuş olup, bu veri seti gemilerin otomatik çıkarımında kullanılmıştır. Veri çeşitliliği, model eğitiminde ve modelin genelleme yeteneğini artırmada önemli bir parametredir. Veri çeşitliliğini sağlamak ve modelin öğrenme kapasitesini artırmak için dünyanın farklı konteyner limanlarından alınan Sentinel-2 görüntüleri bir araya getirilmiş ve çeşitli ön işlem adımlarından geçirilmiştir. İlk kez 2021 yılında kullanıcılara tanıtılan YOLOX algoritması farklı büyüklükteki nesneleri tespit edebilme kapasitesine sahip bir algoritma olup, bu yönü ile önceki diğer YOLO mimarilerinden ayrılmaktadır. Bu sebeple, bu çalışma özelinde YOLOX algoritması tercih edilmiştir. Tespit doğruluğunu artırmak amacıyla, her bir standart YOLOX modeli (YOLOX-s-m-l-x) ayrı oturumlarda, hiperparametreler üzerinde değişiklik yapılmadan eğitilmiştir ve aralarından en yüksek metrik değerlere ulaşan YOLOX-l modeli ile gemiler tespit edilmiştir. Model ortalama kesinlik, ortalama duyarlılık ve F1 puanı sırasıyla %56.39, %65.45 ve %60.48 bulunmuştur. Gemi çıkarımları, Rotterdam limanında 2023 yılı deniz taşımacılığı kaynaklı karbonmonoksit (CO) emisyonlarının tahmininde kullanılmıştır ve sonuç olarak emisyon miktarı 148,504-ton olarak görülmüştür.

Anahtar Kelimeler: Deniz Taşımacılığı Kaynaklı Emisyonlar, Uzaktan Algılama, Gemi Tespiti, Derin Öğrenme.

A REMOTE SENSING APPROACH TO IDENTIFY SHIPPING EMISSIONS

Abstract

Shipping emissions are recognized as a significant contributor to climate change, increasing the frequency of extreme weather events. It is important to monitor transportation mobility for estimating emissions, and remote sensing data and methods are valuable due to their continuity, wide coverage, and ease of integration with other relevant data. Sentinel-2 data enables monitoring of transportation mobility and can be used as proxy data to infer shipping emissions. For this purpose, this study aims to monitor ship movements on a regional scale with YOLOX-assisted ship detection to estimate emissions. A new dataset was curated from Sentinel-2 RGB images provided by the European Space Agency's Copernicus program, in which environmental and climate monitoring data are available free of charge. The dataset covers various locations of busy container ports to support data diversity. The YOLOX object detector, introduced to the computer vision community in 2021, is known for its versatility in detecting multi-scale objects. Thus, YOLOX was chosen to perform ship detection, and each standard YOLOX model (YOLOX-s-m-l-x) was trained on the dataset in separate sessions with default hyperparameters. As a result, the model with the highest evaluation score, YOLOX-l, was utilized to extract ship instances and localize ships from the dataset. Average precision (AP), average recall (AR), and F1-score were found to be 56.39%, 65.45%, and 60.48%, respectively. Ship extractions were utilized to estimate carbon monoxide (CO) emissions for 2023 in the port of Rotterdam, and a total of 148.504 tons of shipping-related CO emissions were inferred as a result.

Keywords: Shipping Emissions, Remote Sensing, Ship Detection, Deep Learning.

Sorumlu Yazar: Cemre Fazilet Aldoğan

Geliş Tarihi: 15 Nisan 2025

Kabul Tarihi: 24 Haziran 2025

Yayın Tarihi: 30 Haziran 2025

Atıf Şekli: Aldoğan, C.F., Demirel, H. (2025). Deniz Taşımacılığı Kaynaklı Emisyonların Belirlenmesinde Uzaktan Algılama Yaklaşımı, *Atmosfer ve İklim Dergisi*, 1(2), 28-36.

Makale Tipi: Araştırma Makalesi

e-ISSN: 3023-8560

GİRİŞ

Küresel taşımacılığın önemli bir bileşeni olan gemilerden atmosfere salınan sera gazları ve hava kirleticileri, iklim üzerinde zarar verici etkilere sebep olmakla beraber insan sağlığı ile ilgili ciddi problemlerin doğmasına yol açmaktadır (Corbett ve Fischbeck, 1997; Deniz ve Durmuşoğlu, 2003; Zhang vd., 2014; Nunes vd., 2017; Wan vd., 2020; Alamoush vd., 2022; Christodoulou ve Cullinane, 2024). Taşımacılık faaliyetleri sonucu karbonmonoksit (CO), sülfür oksit (SO_x), nitrojen oksit (NO_x), karbondioksit (CO₂) gazlarının yanı sıra PM_{2.5} ve PM₁₀ gibi partikül maddeler atmosfere salınmaktadır. Sera gazı ve partikül madde emisyon miktarı, EMEP, CAMS, EDGAR vb. bir çok emisyon envanterinde yerel, bölgesel ve küresel ölçekte hesaplanmaktadır. Bu envanterler emisyon hesaplamada “aşağıdan yukarıya” (bottom-up) ya da “yukarıdan aşağıya” (top-down) yaklaşımını benimsemektedirler. “Aşağıdan yukarıya” yaklaşımında, gemi türü, hızı, yakıt türü, motor tipi, emisyon faktörü gibi parametreler ile bir geminin saldıgı emisyon hesaplanması üzerinden sektörel bazda emisyon miktarına ulaşılmaktadır. Bu yaklaşım çalışmalarda sıklıkla tercih edilmektedir fakat bazı kısıtları içinde barındırmaktadır. Bu kısıtlar; toplam emisyonu doğrulamada karşılaşılan problemler, emisyon hesaplamasının karmaşıklığı ve harcanan zamanın fazlalığıdır (Luo vd., 2024). Uzaktan algılama yöntemleri, insan kaynaklı emisyon envanterlerinin oluşturulması ve emisyon seviyesinin hesaplanmasında, ve bu hesaplamaların daha hızlı yürütülmesinde önemli bir alternatiftir. Yer gözlem uyduları, sadece yeryüzünün izlenmesinde değil, aynı zamanda atmosferdeki değişimlerin gözlemlenmesinde de rol oynamaktadır. Yer gözlem uydularının düzenli aralıklarla sağladığı uydu görüntüleri ile iklim verilerinin bir araya getirilmesi sonucu gaz ve partikül madde emisyonları ve bunların kaynağı hakkında daha hassas bilgiler edinilebilmektedir.

Evrişimsel sinir ağları (CNNs), gemi tespitinde önemli kilometre taşlarından biridir (LeCun vd., 2015). İki aşamalı tespit edicilerden RCNN (Girshick vd., 2014), Fast-RCNN (Girshick, 2015), Faster-RCNN (Ren vd., 2015) CNN mimarisinin nesne tespitindeki türevleri olarak karşımıza çıkmaktadır. Bu tespit edicilerin, istenilen tespit hızını yakalayamaması YOLO (Redmon vd., 2016) gibi tek aşamalı tespit edicilerin doğmasına öncülük etmiştir. Uzaktan algılama özelinde incelendiğinde tespit edicilerin karşılaştığı diğer sorunlar, nesne boyutu çeşitliliği, hava koşullarının (mevsimler değişimleri, sislilik, bulutluluk vb.) uydu görüntülerinde oluşturduğu bulanıklık ve gürültü miktarıdır (Er vd., 2023). Bununla beraber, nesne tespit modellerinin eğitilmesinde harcanan sürenin uzun olması, performans değerlendirme metrikleri olan kesinlik ve duyarlılık değerleri arasındaki dengesizlik, tespit hızı dışında karşılaşılan diğer problemler olmuştur. Bu problemlere yenilikçi bir bakış açısı geliştirmeyi hedefleyen YOLO, model hızı ve doğruluğu arasındaki dengeyi tesis etmek için 2015'ten bu yana piyasaya sürülen çeşitli YOLO versiyonları aracılığıyla mimaride yapısal değişiklikler deneyimlemiştir. Bu versiyonlardan YOLOX, Ge Zheng tarafından 2021 yılında geliştirilmiş ve önceki YOLO versiyonlarına göre daha yüksek bir performans sergilemeyi amaçlamıştır.

Hava kalitesi izleme istasyonları, enerji santralleri ve endüstriyel bölgelere ait emisyon miktarının tahmin edildiği bazı çalışmalarda, uydu tabanlı hava kalitesi verisinin yanında ikame bir veri kaynağı olarak Sentinel-2 görüntülerinin kullanıldığı görülmüştür (Strandgren vd., 2020; Hanna vd., 2022; Jain A., 2022; Hobbs vd. 2023; Rowley ve Karakuş, 2023; Rouet-Leduc ve Hulbert, 2024). Avrupa Uzay Ajansı, Copernicus programı, (https://www.esa.int/Applications/Observing_the_Earth/Copernicus – web 1), Sentinel-2 misyonu, (<https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2> – web 2) ürün hasadı, bitki ve arazi örtüsünün izlenmesinin yanında hava kalitesi gözlemlerinde de araştırmacılara geniş olanaklar tanımaktadır (Helber vd. 2019; Scheibenreif vd. 2021). Scheibenreif vd., rastgele noktalarda NO₂ emisyon seviyelerini tahmin edebilmek amacıyla, uydu tabanlı atmosferik hava kirliliği verisi ile beraber ikame veri olarak Sentinel-2 görüntülerinden yararlanmışlardır (2021). Bir başka çalışmada, fosil enerji santrallerinden yayılan CO₂ emisyon lokasyonları hakkında çıkarımlarda bulunmak için, sıcaklık, nem ve rüzgar gibi parametreleri içeren ERA-5 verisine ek olarak Sentinel-2 verisi kullanılmıştır. (Hanna vd., 2023). Başka bir çalışmada ise, birden fazla optik uydu verisi (Sentinel-2, Landsat-8, and PlanetScope) CO₂ emisyon tahmininde kullanılmıştır (Couture vd., 2024). Balasundaram ve diğerleri tarafından yürütülen çalışmada, Sentinel-2 verisi üzerinden sanayi sitelerinden yayılan duman (smoke plumes) konsantrasyon seviyesinin tahmini yapılmıştır (2024). Bahsedilen bu çalışmalarda, hava kalitesi izleme istasyonları, sanayi siteleri, enerji santralleri, kirliliğin

yoğun olduğu şehir ve kırsal alanların lokasyonlarını tespit etmede Sentinel-2 görüntülerinden yararlanmışlardır. Sentinel-2 verisinin benzer amaçlarla tercih edildiği bazı çalışmalarda, nesne tespiti, görüntü sınıflandırma ve anlamsal bölütleme gibi bilgisayarlı görü teknikleri ile konum hakkında bilgi üretilmiştir. Poucin vd. (2023) baskın emisyon noktalarının konumunu belirlemek ve emisyon seviyesini tahmin etmek için gradient boosting ve ResNet gibi sınıflandırma modellerini tercih ederken, Wu vd. (2023) nesne tespiti ve anlamsal bölütleme tekniklerini tercih etmiştir. Bildiğimiz kadarıyla, Sentinel-2 verisinden elde edilen gemi çıkarımlarının öznetelikleri baz alınarak deniz taşımacılığı kaynaklı emisyonların tahmin edildiği bir çalışma literatürde henüz yer almamaktadır. Bu sebeple bu çalışmanın amacı; deniz taşımacılığı kaynaklı emisyonların tahmininde ilk aşamada YOLOX nesne tespit algoritması ile gemilerin tespit edilmesi ve ikinci aşamada bu tespitlere göre CO emisyonlarının hesaplanmasıdır.

Çalışmada, Sentinel-2 veri seti üzerinden tespit edilen gemi sayısını artırmak için en yüksek performanslı YOLOX modeli seçilmiş ve bu model ile nesne tespiti sonrası elde edilen gemi özneteliklerini (gemi boyutu ve sayısı) baz alarak Rotterdam limanında deniz taşımacılığı kaynaklı CO emisyonları tahmin edilmiştir. Makalenin diğer bölümlerinde, “Veri ve Yöntem” başlığı altında Sentinel-2 veri seti ve YOLOX eğitim detayları hakkında bilgiler verilmiştir. “Bulgular” başlığı altında gemi tespiti görsel sonuçları ve modellerin istatistiki değerlendirmeleri tartışılmış olup, “Sonuç” bölümünde elde edilen bulgular değerlendirilmiştir.

VERİ

Sentinel-2, Avrupa Uzay Ajansı tarafından 2015 yılında kara ve deniz alanlarının küresel çapta ve sistematik olarak izlenmesi amacıyla başlatılan bir uydu misyonudur. Sentinel-2A (23.06.2015), Sentinel-2B (07.03.2017) ve Sentinel-2C (05.09.2024) uyduları, bünyelerinde barındırdıkları çok bantlı algılayıcılar (Multispectral Instrument) (MSI) ile beş (5) günde bir yer gözlem verisi toplamaktadırlar. Sentinel-2A verisi, görünür kıızılötesinden kırsal kıızılötesi aralığına kadar 13 farklı spektral banttan oluşmaktadır. Bantların mekansal çözünürlüğü sırasıyla 10m, 20m ve 60m arasında değişmektedir (Drusch vd., 2012). Sentinel-2A verisine erişim Copernicus Data Space Ecosystem üzerinden sağlanabilmektedir. Alternatif olarak, Google Earth Engine (GEE) ya da geemap Python kütüphanesi üzerinden indirilebilmektedir. Bu çalışmada Sentinel-2 Level-2A yüzey yansıma verisinin 10m mekansal çözünürlüklü görünür bantları (Red-Green-Blue, RGB) kompozit olarak geemap kütüphanesi üzerinden indirilmiştir. İndirme öncesinde tarih aralığı 2017-2024 yılları arası ve bulutluluk oranı %10'dan az olacak bir biçimde filtreleme uygulanmıştır. Gölge ya da düşük kontrast gibi negatif ışık etkilerinin görüldüğü görüntüleri elemek amacıyla ilkbahar ve sonbahar mevsimleri tercih edilmiştir. Böylelikle, gürültülü görüntüler elenerek, sadece yüksek kaliteli görüntülerin indirilmesi sağlanmıştır. Optik uydu görüntüleri atmosferik koşullardan büyük ölçüde etkilendiğinden, indirilen Sentinel-2 görüntü sayısı ve buna bağlı olarak veri seti örneklem büyüklüğü bu faktöre göre değişkenlik göstermiştir. Veri seti için seçilen coğrafi noktalar Bremerhaven (Almanya), Busan (Güney Kore), İzmir (Türkiye), Long Beach (ABD), Nantong (Çin), Rizhao (Çin), Taranto (İtalya), Abudhabi (BAE), Hong Kong (Çin), Savannah (ABD), Tianjin (Çin) ve Rotterdam (Hollanda) limanlarıdır. Rotterdam limanına ait görüntüler test setini oluşturduklarından, yıllık emisyon tahmini için mevsim farkı gözetilmemiş, toplamda yılın altmış iki (62) günü çalışmada temsil edilmiştir. Yukarıda bahsedilen tüm limanları içeren 1064 adet Sentinel-2A görüntüsü indirme işlemi sonrası karolara ayırma işlemine tabi tutulmuştur. Karo görüntüler, Roboflow ortamında etiketlenmiş ve yeniden boyutlandırma, görüntü zenginleştirme gibi ön-işlem adımlarından geçirilmiştir. İşlem yükünü azaltmak amacıyla görüntü boyutu 1024x1024 pikselden 400x400 piksele düşürülmüştür. Yeniden boyutlandırılmış bu görüntülere kontrast germe ve -10 ve 10 derece yatay döndürme veri artırımı uygulanmıştır. Kolaylık örnekleme türünün seçildiği çalışmada, veri setinde öncelikle coğrafi çeşitlilik sağlamak amacıyla ve daha fazla gemi örneği toplamak adına ağırlıklı olarak en işlek limanlardan ve farklı kıtalara ait limanlardan görüntülere yer verilmiştir. Bu limanlarda gürültü oranı daha az Sentinel-2 görüntülerine ulaşıldığı için bu örneklem tipi çalışmaya uygun bulunmuştur. 8:2 örneklem oranı ile 3626, 517 ve 254 görüntü sırasıyla eğitim, doğrulama ve test verisi olarak ayrılmıştır. Toplamda 4397 adet Sentinel-2 görüntüsünden oluşan bir veri seti oluşturulmuştur. 8:2 örneklem oranı bu büyüklükte bir veri setinin doğrulanmasında yeterli bulunmuş olup, bu sebeple çalışmada ek olarak çapraz doğrulama yapılmamıştır. Gemi tespiti sonrası 2023 yılına ait CO emisyonlarının hesaplanması

için brüt ton ve gemilerin limanda bekleme süresi verileri birleşmiş milletlerin veri portalından (UNCTAD Data Hub) alınmıştır (<https://unctadstat.unctad.org/datacentre/dataviewer/US.PortCalls>, - web 3) Motor gücü (kW), özgül yakıt tüketimi (g/kWh), emisyon faktörü (kg/tonne) Avrupa İzleme ve Değerlendirme Programı (European Monitoring and Evaluation Programme – EMEP) 2023 kılavuzu 1.A.3.d.i uluslararası deniz seyrüsefer emisyon raporundan alınmıştır. Emisyon formüllerine ise Hollanda Çevre Değerlendirme Ajansının 2023 yılına ait ulaştırma kaynaklı emisyonların hesaplanma yöntemleri raporundan ulaşılmıştır.

YÖNTEM

YOLOX, bilgisayarlı görü araştırmalarında sıklıkla tercih edilen YOLO serisinin güncel bir üyesidir. Açılımı “You Only Look Once” olan bu nesne tespit serisi tek aşamalı tespit ediciler sınıfına dahildir. İki aşamalı tespit modellerinin aksine, YOLO modelleri, bölge önerilerinin belirlenmesi ve nesnelerin tespit aşamalarını tek seferde yönetmektedir. YOLOX tespit edicisi, doğal görüntülerde ya da uydu görüntülerinde rastlanılan çeşitli büyüklüklerdeki nesnelerin tespit edilebilmesini kolaylaştırmak amacıyla geliştirilmiştir (Ge vd. 2021). İçerisinde farklı ağ yapılarında YOLOX-s, YOLOX-m, YOLOX-l, YOLOX-x ve YOLOX-Darknet53 varyantlarını barındırmaktadır. YOLOX-Darknet53 haricindeki tüm modeller YOLOv5 modellerinden türetilmiş iken YOLOX-Darknet53, YOLOv3 tespit edicisinden türetilmiştir (Ransheng vd. 2023). YOLOv5 mimarisine eklenen CSPNet, Focus, SPP ağ yapıları ile FPN ve PANet öznitelik piramit yapısı YOLOX mimarisini oluşturmaktadır. Bu çalışmada, yukarıda bahsedilen standart YOLOX modellerinin her biri (YOLOX-s, YOLOX-m, YOLOX-l, YOLOX-x) en yüksek performans gösteren YOLOX modelini bulmak için Sentinel-2 veri seti üzerinde eğitilmiştir. Diğerlerinden daha yüksek performans gösteren YOLOX-l modeli test edilerek gemi çıkarımları yapılmıştır. Gemi çıkarımları sonucu elde edilen sınırlayıcı kutu boyutları referans alınarak gemiler küçük, orta, büyük gemiler olarak COCO sınıflandırma kriterlerine göre sınıflandırılmıştır (Lin vd. 2024). Bu sınıflandırmaya göre sınırlayıcı kutu alanı 1024 pikselden azsa gemi küçük, 1024-9216 piksel arasında ise orta, 9216 pikselden fazla ise büyük gemi olarak sınıflandırılmaktadır. Her bir gemi sınıfı bilgisi ve gemi sayıları, karbonmonoksit (CO) emisyonlarının hesaplanmasında formüllerde kullanılmıştır. Emisyon formülleri aşağıdaki gibidir:

$$F_v = V_v * T_v * E_v \quad (1)$$

$$F_{v,f,m} = f_{v,f} * f_{v,m} * F_v \quad (2)$$

$$EM_{s,v,f,m} = F_{v,f,m} * \text{Emisyon faktörü}_{s,f,m} \quad (3)$$

F_v yakıt tüketimini (kg), V_v brüt tonu (GT), T_v demirde bekleme zamanını, E_v yakıt tüketim oranını, v ise gemi tipini ifade etmektedir. $F_{v,f,m}$ gemi, yakıt ve motor tipi başına yakıt tüketimini, $f_{v,f}$ gemi tipi başına yakıt fraksiyonunu, $f_{v,m}$ gemi tipi başına motor fraksiyonunu, $EM_{s,v,f,m}$ emisyon miktarını (kg), $\text{Emisyon faktörü}_{s,f,m}$ her bir madde, yakıt ve motor tipi başına emisyon faktörünü, f, m, s ise sırasıyla, yakıt, motor tipi ve maddeyi temsil etmektedir. Uygun CO emisyon faktörünün seçimi, dizel yakıt türüne ve limana yakın gemilerin orta hızla ilerlediğini göz önünde bulundurarak yapılmıştır. Eğitim, doğrulama ve test işlemleri, Google Colab ortamında A100 ve L4 NVIDIA grafik işlem birimi (GPU) kullanılarak yürütülmüştür. A100 GPU belirli bir ücret karşılığında kullanıcılara sunulmaktadır. YOLOX-s ve YOLOX-x modellerinin eğitiminde A100 GPU, YOLOX-m ve YOLOX-l modellerinin eğitiminde ise L4 GPU kullanılmıştır. YOLOX-s ve YOLOX-x modellerinin eğitilmesi sırasıyla 3 ve 6 saat, diğerlerinin ise ayrı oturumlar halinde toplam 32 saat sürmüştür. Devir, öğrenme oranı, ağırlık bozunumu, SGD momentumu, cihaz sayısı ve yığın boyutu sırasıyla 300, 0.01, 0.0005, 0.9, 1 ve 16'dır. Küçük gemilerin görüntüde temsil ettiği piksel sayısının, deniz yüzeyine göre çok az olması sebebiyle çalışmada büyük gemilerin tespiti üzerine yoğunlaşmıştır (Li vd. 2021). Son olarak, en yüksek doğruluk performansı gösteren model ile test için ayrılan Sentinel-2 görüntüleri test edilmiştir. YOLOX gemi tespitine dair metrik sonuçların yorumlaması öncesinde kesinlik, duyarlılık ve F1 puanı kavramlarının bilinmesi önemlidir.

Formüller aşağıdaki gibidir:

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} \quad (3)$$

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (4)$$

$$\text{F1 Puanı} = \frac{2 \cdot \text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

Kesinlik tüm tespitlerin içerisindeki doğru tespitlere odaklanırken, duyarlılık ise gözden kaçan tespitlerin dahil olduğu yer doğruluğu içerisindeki doğru tespitlere odaklanır. F1 puanı kesinlik ve duyarlılık değerlerinin harmonik ortası olarak hesaplanan temel değerlendirme metriklerinden biridir. 0 ve 1 arasında değer alır ve bu değerlere yakınlık sırasıyla modelin yüksek ve düşük doğruluğuna işaret etmektedir.

BULGU VE DEĞERLENDİRMELER

Sentinel-2 veri setine ait test görüntülerinden tespit edilen bazı gemi örnekleri sınırlayıcı kutular içerisinde Şekil 1’de aşağıda sunulmuş olup, sadece YOLOX-l modeli ile test edilen Sentinel-2 görüntüleri yer almaktadır. Güven eşiğinin 0.25 olarak ayarlandığı bu çalışmada, toplamda 696 tespit yapılmıştır. YOLOX-l modelinin çeşitli büyüklük ve ebatlarda yer alan gemileri tespit edebildiği göze çarpmaktadır. Öte yandan bazı gemilerin model tarafından tespit edilemediği, diğer bir ifadeyle, gözden kaçan gemilerin var olduğu görülmektedir.



Şekil 1. YOLOX Gemi Tespiti Sonuçları.


Ek olarak, yanlış alarm olarak nitelendirilen tespitler de bulunmaktadır. Bu tespitlerin düşük güven değeri ile tespit edildiği görülmektedir. Bir tespitin doğru pozitif (TF), doğru negatif (TN), yanlış pozitif (FP) ya da yanlış negatif (FN) olarak sınıflandırılması kesişimin birleşime oranı (IoU) değerine göre kesinlik kazanmaktadır. IoU, yer doğruluğu ve tespit edilmiş sınırlayıcı kutuların kesişiminin yine bu kutuların birleşimine oranı olarak ifade edilmektedir. Bu çalışmanın gelecek emisyon tahmin çalışmaları ile entegre edilmesi için büyük gemilerin tespitine odaklanılmıştır.

Tablo 1’de YOLOX standart model performanslarını özetleyen ortalama kesinlik, 0.5 eşik değerinde ortalama kesinlik (AP50), ortalama duyarlılık değerleri ve F1 puanı verilmiştir:

Tablo 1. YOLOX Gemi Tespit Değerlendirme Sonuçları

Model	AP (%)	AP50 (%)	AR (%)	F1 Puanı
YOLOX-s	47.17	89.0	57.83	51.95
YOLOX-m	54.06	89.5	63.91	58.57
YOLOX-x	54.84	91.1	63.94	59.04
YOLOX-l	56.39	91.2	65.45	60.58

Yukarıda Tablo 1’deki sonuçlar incelendiğinde, en yüksek metrik değerlerin YOLOX-l modeli ile elde edildiği gözlemlenmiştir. Bu bulgu, YOLOX-l modelinin diğerleri üzerinde bir tespit üstünlüğüne sahip olduğuna işaret etmektedir. Ek olarak YOLOX-l modelinde büyük gemileri lokalize eden sınırlayıcı kutulara göre ortalama kesinlik ve ortalama duyarlılık sırasıyla 0.739 ve 0.786 bulunmuştur. YOLOX-l modelinin tespit ettiği yanlış pozitif ve yanlış negatif örnek sayısının diğer modeller ile karşılaştırıldığında daha az olduğu gözlemlenmiştir. YOLOX-x modelinin YOLOX-l modelinden 44.9 milyon daha fazla parametre içerdiği bilinmesine karşın, YOLOX-l modelinin %60.58 F1 puanı ile daha yüksek doğruluk oranına eriştiği görülmektedir (Megvii-BaseDetection, 2022). Bununla birlikte, alınan ortalama kesinlik, ortalama duyarlılık ve F1 puanı değerleri, YOLOX-l modelinin tespit ettiği nesneler arasında yanlış pozitif örneklerin doğru pozitif, diğer bir ifadeyle, doğru tespit örnek sayısını aştığını göstermiştir. Gemilerin YOLOX-l ile tespit edilmesini takip eden gemi sınıflandırmasında her bir gemi sınıfına ait (küçük, orta, büyük) gemi sayıları aşağıdaki gibidir:



Şekil 2. Gemi Sınıflarına Göre Gemi Sayılarının Dağılımı

Şekil 2’de görüldüğü üzere, YOLOX-l modeli en fazla orta büyüklükteki gemileri tespit edebilmede başarı sağlamıştır. Deniz taşımacılığı kaynaklı CO emisyonları hakkında tahmin yöntemlerinin geliştirilmesi ve bir öngöründe bulunulması, diğer sera gazı ve kirleticilerin arasında ikincil öneme sahip olsa da, uluslararası ticaretin yoğun olarak gerçekleştiği limanlarda ortaya çıkan CO kaynaklı hava kirliliğinin boyutlarının bilinmesi; küresel ısınma, halk sağlığı, bölgesel hava kalitesi çalışmalarına katkı sağlayacaktır (WHO, 2021). Yakıt-motor tipi, gemi boyut ve sayısı gibi birden fazla faktörün belirleyici olduğu CO emisyon miktarı ($EM_{sv,f,m}$); küçük, orta ve büyük gemiler için sırasıyla, 1,202, 134,659 ve 12,642-ton olarak tahmin edilmiştir. Rotterdam limanına ait görüntülerde yer alan gemilerin CO emisyonunun hesaplandığı çalışmada, deniz taşımacılığı kaynaklı emisyon

miktarı toplamda 148,504-ton kaydedilmiştir. Gelecek dönemlerde CO₂, NO_x, SO_x, PM_{2.5} ve PM₁₀ gibi sera gazı ve hava kirleticilerinin tamamının bulunduğu kapsamlı bir tahmin çalışmasının yürütülmesi hedeflenmektedir.

SONUÇLAR

Gemilerin tespit edilmesinde kullanılan Sentinel-2 uydu görüntüleri, bu özelliği ile deniz taşımacılığı kaynaklı emisyonların tahmininde yardımcı bir veri kaynağı olarak kullanılmıştır. Bu çalışmada, ilk olarak YOLOX modelleri ile Sentinel-2 seviye 2A MSI görüntülerinden gemiler tespit edilmiştir. Çalışmada faydalanılan bu standart modeller deniz taşımacılığı kaynaklı emisyonların tahmini aşamasına geçilmesi için gereken gemilerin tespitinde ortalama bir performans sergilemiştir. Diğer taraftan, YOLOX mimarisi farklı büyüklüklerdeki gemilerin tespitinde etkili sonuçlar alınmasına imkan tanımıştır. Özellikle, küçük boyutlu gemilerin tespitinde büyük gemilerin tespit edilmesinden daha fazla başarı sağlanmıştır. Sentinel-2 görüntülerinden gemilerin tespit edilmesi ile uzaktan algılamaya dayalı gözlemler sunulmuş, optik uydu verilerinin CO emisyonlarının tahmin edilmesindeki potansiyeli değerlendirilmiştir. Rotterdam limanına ait Sentinel-2 görüntülerinden tespit edilen gemilerin büyüklük ve sayıları baz alınarak hesaplanan 2023 yılı CO emisyon miktarı 148,504-ton bulunmuştur.

TEŞEKKÜR

Bu makalede sunulan araştırma, ilk yazarın (Cemre Fazilet Aldoğan) İstanbul Teknik Üniversitesi (İTÜ), Bilişim Enstitüsü, Bilişim Uygulamaları Anabilim Dalı, Coğrafi Bilgi Teknolojileri (GIT) programında yaptığı doktora tez çalışmasının bir parçasıdır ve bu doktora tezi Türkiye Yükseköğretim Kurulu (YÖK) tarafından sağlanan 100/2000 doktora bursu ile desteklenmiştir. Sağladıkları destek için kurula teşekkürlerimizi sunarız.

KAYNAKLAR

- Alamouh, A. S., Ölçer, A. I. & Ballini, F. (2022). Ports' role in shipping decarbonisation: A common port incentive scheme for shipping greenhouse gas emissions reduction. In *Cleaner Logistics and Supply Chain* (Vol. 3). Elsevier Ltd. <https://doi.org/10.1016/j.clscn.2021.100021>
- Balasundram, A., Shaik, A., Banga, J. K. & Singh, A. K. (2024). U-Net inspired deep neural network-based smoke plume detection in satellite images. In *Computers, Materials & Continua*, 79(1), 779-799. <https://doi.org/10.32604/cmc.2024.048362>
- Christodoulou, A. & Cullinane, K. (2024). The prospects for, and implications of, emissions trading in shipping. *Maritime Economics and Logistics*, 26(1), 168–184. <https://doi.org/10.1057/s41278-023-00261-1>
- Couture, H. D., Alvara, M., Freeman, J., Davitt, A., Koenig, H., Rouzbeh Kargar, A., O'Connor, J., Söldner-Rembold, I., Ferreira, A., Jeyaratnam, J., Lewis, J., McCormick, C., Nakano, T., Dalisay, C., Lewis, C., Volpato, G., Gray, M. & McCormick, G. (2024). Estimating Carbon Dioxide Emissions from Power Plant Water Vapor Plumes Using Satellite Imagery and Machine Learning. *Remote Sensing*, 16(7). <https://doi.org/10.3390/rs16071290>
- Deniz, C. & Durmuşoğlu, Y. (2008). Estimating shipping emissions in the region of the Sea of Marmara, Turkey. *Science of the Total Environment*, 390(1), 255–261. <https://doi.org/10.1016/j.scitotenv.2007.09.033>
- Drusch, M., del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F. & Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>
- Er, M. J., Zhang, Y., Chen, J. & Gao, W. (2023). Ship detection with deep learning: a survey. *Artificial Intelligence Review*, 56(10), 11825–11865. <https://doi.org/10.1007/s10462-023-10455-x>
- Everingham, M., van Gool, L., Williams, C. K. I., Winn, J. & Zisserman, A. (2010). The pascal visual object classes (VOC) challenge. *International Journal of Computer Vision*, 88(2), 303–338. <https://doi.org/10.1007/s11263-009-0275-4>
- Fontelle, J.-P., Fridell, E., Grigoriadis, A., Hill, N., Kilde, N., Lavender, K., Mamarikas, S., Reynolds, G., Rypdal, K., Thomas, R., Webster, A. & Winther, M. (n.d.). *EMEP/EEA air pollutant emission inventory guidebook 2023 1 Category Title NFR 1.A International maritime and inland navigation, national navigation, national fishing, recreational boats International maritime navigation, international inland navigation, national navigation (shipping), national fishing EMEP/EEA air pollutant emission inventory guidebook 2023 2*.
- Gascon, F., Bouzinac, C., Thépaut, O., Jung, M., Francesconi, B., Louis, J., Lonjou, V., Lafrance, B., Massera, S., Gaudel-Vacaresse, A., Languille, F., Alhammoud, B., Viallefont, F., Pflug, B., Bieniarz, J., Clerc, S., Pessiot, L., Trémas, T., Cadau, E., ... Fernandez, V. (2017). Copernicus Sentinel-2A calibration and products validation status. *Remote Sensing*, 9(6). <https://doi.org/10.3390/rs9060584>
- Ge, Z., Liu, S., Wang, F., Li, Z. & Sun, J. (n.d.). *YOLOX: Exceeding YOLO Series in 2021 V100 batch 1 Latency (ms) YOLOX-L YOLOv5-L YOLOX-DarkNet53 YOLOv5-Darknet53 EfficientDet5 COCO AP (%) Number of parameters (M) Figure 1: Speed-accuracy trade-off of accurate models (top) and Size-accuracy curve of lite models on mobile devices (bottom) for YOLOX and other state-of-the-art object detectors* (Vol. 5). <https://github.com/ultralytics/yolov3>

- Geilenkirchen, G., Bolech, M., Hulskotte, J., Dellaert, S., Ligterink, N., Sijstermans, M., Geertjes, K. & Felter, K. (n.d.). *Methods for Calculating the Emissions of Transport in the Netherlands Colophon Methods for calculating the emissions of transport in the Netherlands Author(s)*.
- Girshick, R. (n.d.). *Fast R-CNN*. <https://github.com/rbgirshick/>
- Girshick, R., Donahue, J., Darrell, T. & Malik, J. (n.d.). *Rich feature hierarchies for accurate object detection and semantic segmentation*. <https://arxiv.org/abs/1311.2524>
- Gorroño, J., Varon, D. J., Irakulis-Loitxate, I. & Guanter, L. (2023). Understanding the potential of Sentinel-2 for monitoring methane point emissions. *Atmospheric Measurement Techniques*, 16(1), 89–107. <https://doi.org/10.5194/amt-16-89-2023>
- Hanna, J., Borth, D. & Mommert, M. (2023). Physics-Guided Multitask Learning for Estimating Power Generation and CO₂ Emissions From Satellite Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 61. <https://doi.org/10.1109/TGRS.2023.3286444>
- Hanna, J., Mommert, M. & Borth, D. (n.d.). *Estimation of Power Generation and CO₂ Emissions Using Satellite Imagery*. <https://doi.org/10.5281/zenodo>
- Helber, P., Bischke, B., Dengel, A. & Borth, D. (2019). Eurosat: A novel dataset and deep learning benchmark for land use and land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(7), 2217–2226. <https://doi.org/10.1109/JSTARS.2019.2918242>
- Hobbs, M., Kargar, A. R., Couture, H., Freeman, J., Söldner-Rembold, I., Ferreira, A., Jeyaratnam, J., O'Connor, J., Lewis, J., Koenig, H., McCormick, C., Nakano, T., Dalisay, C., Davitt, A., Gans, L., Lewis, C., Volpato, G., Gray, M. & McCormick, G. (2023). Inferring Carbon Dioxide Emissions From Power Plants Using Satellite Imagery and Machine Learning. *IGARSS 2023 - IEEE International Geoscience and Remote Sensing Symposium*, 4911–4914. <https://doi.org/10.1109/igarss52108.2023.10283046>
- Hosang, J., Benenson, R., Dollar, P. & Schiele, B. (2016). What Makes for Effective Detection Proposals? *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(4), 814–830. <https://doi.org/10.1109/TPAMI.2015.2465908>
- Jain, A. (2022). Employing Deep Learning to Quantify Power Plant Greenhouse Gas Emissions via Remote Sensing Data. *AAAI 2022 Fall Symposium: The Role of AI in Responding to Climate Challenges*. <https://www.climatechange.ai/papers/aaaifss2022/11>
- Li, B., Xie, X., Wei, X. & Tang, W. (2021). Ship detection and classification from optical remote sensing images: A survey. In *Chinese Journal of Aeronautics* (Vol. 34, Issue 3, pp. 145–163). <https://doi.org/10.1016/j.cja.2020.09.022>
- Lin, Y., Li, J., Wei, S. & Liu, S. (2024). OptiShipNet: Efficient Ship Detection in Complex Marine Environments Using Optical Remote Sensing Images. *Journal of Marine Science and Engineering*, 12(10). <https://doi.org/10.3390/jmse12101786>
- Luo, Z., He, T., Yi, W., Zhao, J., Zhang, Z., Wang, Y., Liu, H. & He, K. (2024). Advancing shipping NO_x pollution estimation through a satellite-based approach. *PNAS Nexus*, 3(1). <https://doi.org/10.1093/pnasnexus/pgad430>
- Mommert, M., Sigel, M., Neuhausler, M., Scheibenreif, L. & Borth, D. (2020). *Characterization of Industrial Smoke Plumes from Remote Sensing Data*. <http://arxiv.org/abs/2011.11344>
- Nunes, R. A. O., Alvim-Ferraz, M. C. M., Martins, F. G. & Sousa, S. I. V. (2017). Assessment of shipping emissions on four ports of Portugal. *Environmental Pollution*, 231, 1370–1379. <https://doi.org/10.1016/j.envpol.2017.08.112>
- Passig, J., Schade, J., Irsig, R., Li, L., Li, X., Zhou, Z., Adam, T. & Zimmermann, R. (2021). *Detection of Ship Plumes from Residual Fuel Operation in Emission Control Areas using Single-Particle Mass Spectrometry*. <https://doi.org/10.5194/amt-2020-482>
- Poucin, F., Ouerghi, E., Lajouanie, S., de Almeida Rodrigues, H., Facciolo, G., de Franchis, C. & Hessel, C. (2023). Machine Learning and Feature Extraction for Industrial Smoke Plumes Detection from Sentinel-2 Images. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2023-July, 6113–6116. <https://doi.org/10.1109/IGARSS52108.2023.10282662>
- Ransheng, Y., Ying, H. & Hongfei, Z. (2023). Ship Detection in Maritime Surveillance System Based on YOLOX. *2023 8th International Conference on Image, Vision and Computing, ICIVC 2023*, 146–153. <https://doi.org/10.1109/ICIVC58118.2023.10269862>
- Redmon, J., Divvala, S., Girshick, R. & Farhadi, A. (n.d.). *You Only Look Once: Unified, Real-Time Object Detection*. <http://pjreddie.com/yolo/>
- Ren, S., He, K., Girshick, R. & Sun, J. (n.d.). *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. <https://github.com/>
- Rouet-Leduc, B. & Hulbert, C. (2024). Automatic detection of methane emissions in multispectral satellite imagery using a vision transformer. *Nature Communications*, 15(1). <https://doi.org/10.1038/s41467-024-47754-y>
- Rowley, A. & Karakuş, O. (2023). Predicting air quality via multimodal AI and satellite imagery. *Remote Sensing of Environment*, 293. <https://doi.org/10.1016/j.rse.2023.113609>
- Scheibenreif, L., Mommert, M. & Borth, D. (2021). *Estimation of Air Pollution with Remote Sensing Data: Revealing Greenhouse Gas Emissions from Space*. <http://arxiv.org/abs/2108.13902>
- Strandgren, J., Krutz, D., Wilzewski, J., Paproth, C., Sebastian, I., R. Gurney, K., Liang, J., Roiger, A. & Butz, A. (2020). Towards spaceborne monitoring of localized CO₂ emissions: An instrument concept and first performance assessment. *Atmospheric Measurement Techniques*, 13(6), 2887–2904. <https://doi.org/10.5194/amt-13-2887-2020>
- van Geffen, J., Folkert Boersma, K., Eskes, H., Sneep, M., ter Linden, M., Zara, M. & Pepijn Veefkind, J. (2020). S5P TROPOMI NO₂ slant column retrieval: Method, stability, uncertainties and comparisons with OMI. *Atmospheric Measurement Techniques*, 13(3), 1315–1335. <https://doi.org/10.5194/amt-13-1315-2020>
- Wan, Z., Ji, S., Liu, Y., Zhang, Q., Chen, J. & Wang, Q. (2020). Shipping emission inventories in China's Bohai Bay, Yangtze River Delta, and Pearl River Delta in 2018. *Marine Pollution Bulletin*, 151. <https://doi.org/10.1016/j.marpolbul.2019.110882>

- Wang, Q., Shi, W., Li, Z. & Atkinson, P. M. (2016). Fusion of Sentinel-2 images. *Remote Sensing of Environment*, 187, 241–252. <https://doi.org/10.1016/j.rse.2016.10.030>
- Wu, J., O’Sullivan, C., Orlandi, F., O’Sullivan, D. & Dev, S. (2023). Measurement of Industrial Smoke Plumes from Satellite Images. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2023-July, 5680–5683. <https://doi.org/10.1109/IGARSS52108.2023.10282713>
- Wu, Q. (2020). geemap: A Python package for interactive mapping with Google Earth Engine. *Journal of Open Source Software*, 5(51), 2305. <https://doi.org/10.21105/joss.02305>
- Zhang, F., Chen, Y., Tian, C., Wang, X., Huang, G., Fang, Y. & Zong, Z. (2014). Identification and quantification of shipping emissions in Bohai Rim, China. *Science of the Total Environment*, 497–498, 570–577. <https://doi.org/10.1016/j.scitotenv.2014.08.016>
- Zhang, Q., Geng, G. N., Wang, S. W., Richter, A. & He, K. bin. (2012). Satellite remote sensing of changes in NO_x emissions over China during 1996–2010. *Chinese Science Bulletin*, 57(22), 2857–2864. <https://doi.org/10.1007/s11434-012-5015-4>
- Zhang, Q., Huang, Y. & Song, R. (2022). A Ship Detection Model Based on YOLOX with Lightweight Adaptive Channel Feature Fusion and Sparse Data Augmentation. *AVSS 2022 - 18th IEEE International Conference on Advanced Video and Signal-Based Surveillance*. <https://doi.org/10.1109/AVSS56176.2022.9959441>
- WHO global air quality guidelines. (2021). Particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide.
- Web 1, https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2, (20.08.2024 tarihinde alınmıştır).
- Web 2, <https://dataspace.copernicus.eu/>, (20.08.2024 tarihinde alınmıştır).
- Web 3, <https://unctadstat.unctad.org/datacentre/dataviewer/US.PortCalls>, (20.08.2024 tarihinde alınmıştır).
- Web 4, <https://github.com/Megvii-BaseDetection/YOLOX?tab=readme-ov-file#standard-models>, (10.10.2024 tarihinde alınmıştır).
- Web 5, <https://github.com/ultralytics/yolov5>, (10.10.24 tarihinde alınmıştır).