

Uydu Görüntülerinden Örnek Segmentasyonu ile Gemi Tespiti

Şaziye Özge Atik ^{1*}, Cengizhan İpbüker ²

¹Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 41400, Kocaeli

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

Özet

Uydu görüntülerinde nesne tespiti, derin öğrenme (DÖ) yaklaşımlarının kullanıldığı en yaygın uygulamalardan biridir. Derin öğrenme uygulamalarında uzaktan algılama verilerinin kullanımı nesnelerin yoğunluğu, kalabalık tespiti ve askeri uygulamalar vb. gibi birçok alanda her geçen gün hızla yaygınlaşmaktadır. Obje tespitine bir örnek olan, otomatik gemi tespit uygulamalarının bazı kullanım alanları arasında nakliye trafiği, liman faaliyetlerini izlemek ve tedarik zinciri analizi gibi örnekler sayılabilir. Bu çalışmada, evrişimli sinir ağları (ESA) kullanılarak uydu görüntülerinde örnek segmentasyonu ile otomatik gemi tespiti yapılması amaçlanmıştır. Uygulamada erin öğrenme modeli olarak, ResNet-101 omurgasına sahip Mask-R CNN mimarisi kullanılmış ve deneyler 1.5 m çözünürlüklü SPOT uydusunun görüntülerinden oluşan AIRBUS Gemi Tespit veri setinde gerçekleştirilmiştir. Veri setindeki görüntüler deniz, gemi, limanlar ve bazı arazi örtüsü sınıflarını içerir. Kullanılan veri setindeki görüntülerde gemilerin referans verisi de mevcuttur. Çalışmada kullanılan model 25 epok ile eğitilmiştir. Modelde eğitim için 34000 ve validasyon için 8500 gemi örneği kullanılmıştır. 120 test görüntüsünde tespit edilen gemiler maskelenerek, sınırlayıcı kutu ile işaretlenmiştir. Uygulamada performans metrikleri olarak, kesinlik değeri % 68.89, hassasiyet değeri % 61.57 ve F-1 skoru % 65.02 olarak elde edilmiştir. Test görüntülerinde tahmin edilen gemi sınıfının ortalama güven olasılığı %99.17'dir. Örnek segmentasyonlarının sonuçları gemi tespit skorları ile birlikte görselleştirilmiştir.

Anahtar Sözcükler: Derin öğrenme, Bilgisayarlı görü, Otomatik nesne tespiti, Örnek segmentasyonu, Gemi tespiti

1. Giriş

Makine Öğrenimi (MÖ) algoritmalarının kullanımı birçok endüstri alanı ve bilimsel çalışmalarda her geçen gün daha da popüler hale gelmektedir. Birçok farklı alanda, veri analistleri çeşitli MÖ algoritmalarını yaygın olarak kullanmaktadır. Gelişen teknolojiyle birlikte uydu görüntülerinin çözünürlüklerin yükselmesi ve görüntüleme sıklığının artması ile birçok farklı alanda yer izleme uygulamaları yapılmaktadır. Bu uygulamalara örnekler arasında çevre izleme, doğal afetler ve güvenlik için askeri uygulamalar sayılabilir. Nesne tespiti uygulamalarında uydu ve kamera görüntülerini kullanılmaktadır (Atik ve İpbüker, 2020). Denizlerdeki görüntüler, havaalanları, heliport vb. alanlarda nesne tespiti uygulanan bölgelerin bazılarıdır. Bu alandaki popüler uygulama konularından biri de otomatik gemi tespitidir. Gemi tespiti uygulamalarının geliştirilmesi ve iyileştirilmesi için bazı yarışmalar (Planet uydusu ve AIRBUS veri setleri) düzenlenmektedir. Bilgisayarla görü uygulamalarında, farklı hedefler belirlenebilmektedir. Bunlar arasında, tekil nesne tespiti, birden çok sınıf için sınıflandırma, lokalizasyon ve örnek segmentasyonu sayılabilir. Örnek segmentasyonu, görüntülerde, aynı denemelerde birden fazla nesnenin algılanmasını içerir. Örnek segmentasyonu tekil bir nesne için veya birden fazla sınıf için uygulanabilmektedir. Derin öğrenme ile olan uygulama çeşitleri arasında anormallik tespiti, kullanıcı aktif kimlik doğrulamasını yüz desenleri (Atik ve Duran, 2021) gibi olarak tek sınıflı evrişimli sinir ağı (ESA) bulunmaktadır.

Tek sınıflı nesne tespiti uygulamalarında hedef nesnenin en farklı varyasyonlarının doğru bir şekilde sınıflandırılması amaçlanır. Ancak uygulamanın hedefi nesne üzerindeki değişikliklerle (anormallikler) ilgili değilse algoritma; hız, model doğruluğu ve performans ölçütleri gibi sorunlara farklı çözümlerde farklılık gösterebilir. Tekil hedef belirleme uygulamalarından biri olan gemi tespit uygulamaları birçok amaca hizmet edebilir niteliktedir. Ekonomik analiz ve güvenlik kaygıları, gemilerin sınırlardan geçişleri gibi nedenlerle liman faaliyetlerinin izlenmesinin birçok amacı olmaktadır.

Bu çalışmada uydu görüntülerinde gemi tespiti derin öğrenme yaklaşımı ile eğitim yapılmıştır. Eğitilen model test görüntüleri kullanılarak test edilerek performans metrikleri hesaplanmış ve gemi sınıfı için örnek segmentasyonu yapılmıştır. Derin öğrenme modeli olarak Mask R-CNN algoritması kullanılmış ve öğrenmenin ardından model test görüntülerine tatbik edilip, performans metrikleri hesaplanmıştır.

1.1. Literatür Araştırması

Standart bir ESA tek başına kullanılmadığında çıktı katmanı sabit değil değişken olacaktır. R-CNN (Bölgesel – ESA) yaklaşımında algılama, görüntülerde farklı ilgi bölgesini ve farklı mekânsal konumları seçerek uygulanır. Girshick vd. (2014) R-CNN algoritmasını uygulayan, sürekli olarak yüksek seviyeli bağlamı düşük seviyeli görüntü özellikleriyle bütünleştiren nesne tespiti, karmaşık sistemler için en iyi performans gösteren yöntemlerden biridir. Daha sonra, aynı yazar tarafından Fast R-CNN adı verilen daha hızlı bir nesne algılama algoritması geliştirilmiştir. Bu algoritmada, sabit bir boyuta yeniden şekillendirmek için ilgi alanı (ROI) havuzlama katmanı ile bölge tekliflerini tanımlama katmanı vardır. Fast R-CNN algoritması (Girshick, 2015), çeşitli avantajlar sağlayan bir nesne algılama algoritması olarak farklı

Uydu Görüntülerinden Örnek Segmentasyonu ile Gemi Tespiti

nesnelerin tespitinde yaygın olarak kullanılmaktadır. Fast R-CNN'nin rotasyon sınırlayıcı kutulu kullanımına ilişkin bazı örnekleri de mevcuttur. Yazarların deneylerine göre, gemi tespiti için rotasyon çapalarının kullanılmasının hassasiyet analizi üzerinde önemli bir pozitif etkiye sahip olduğu gözlenmiştir (Yang vd., 2018). Bir başka çalışmada otomatik gemi tespiti için Google görüntüleri ile veri seti oluşturulmuş ve önce Fast R-CNN algoritması kullanılmıştır. Daha sonra Bayezyen füzyon kullanılarak elde edilen sonuçların doğrulukları yükseltilmiştir (Kim vd., 2018). Liu vd. gemi tespiti ve sınıflandırmasını Google Earth platformundan indirilen 0.5 m çözünürlüklü görüntüler üzerinden önerilmiş DÖ algoritması ile gerçekleştirmişlerdir (Liu vd., 2017). Bir başka çalışmada, Gaofen-1 ve 2 ve Jilin-1 uydu görüntüleri üzerinden DÖ kullanımı ile gemi tespiti yapılmıştır (Gao vd., 2019).


2. Kullanılan Veri ve Yöntem


AIRBUS firması, uydu görüntülerindeki tüm gemileri mümkün olduğunca çabuk algılayan ve yüksek doğruluğa sahip bir model oluşturmak için bir yarışma düzenlemiştir. Hedeflenen, bulutlu veya puslu görüntülerde dâhi, uydu görüntüleri üzerinde gemilerin tespit edilmesidir. Bu amaca göre, örnek verileri içeren görüntülerden oluşan veri seti yaklaşık 29 GB'tır (Kaggle, 2018). Veri setindeki görüntüler 100.000'den fazla sayıda ve $768 \times 768 \times 3$ boyutlarında ve 1.5 m mekânsal çözünürlüklü SPOT uydu görüntüleridir. Veri setinde bulunan gemilerin konumları piksel koordinatları ile birlikte firma tarafından sunulmuş olup, referans verisi de veri setine dâhildir. Veri setinde görüntülerin bazılarında gemi sınıfı mevcut değildir. Aynı zamanda, görüntülerde bulunan gemilerin boyutları görüntüden görüntüye farklılık göstermektedir. Görüntüler, denizi ve kıyıları içermesinin yanı sıra, farklı olarak kentsel alanlara yakın liman, konteynır ve rıhtımları içerir.

Literatürde R-CNN, Fast R-CNN, Faster R-CNN gibi bölgesel nesne tespiti üzerine çalışan evrimsel sinir ağı kullanımları mevcuttur. Bunların yanı sıra, yine bölgesel çalışan, ek olarak segmentasyon yapan Mask R-CNN (He vd., 2017) algoritması nesneler için yüksek kaliteli segmentasyon maskesi oluşturarak nesne tespitini gerçekleştirir. Bu çalışmada, COCO (Common Objects in Context) veri seti önceden eğitilmiş Mask R-CNN ağırlıkları ve TensorFlow kütüphanesi kullanılmıştır. Eğitim ve validasyon verisi ile kullanılan model 25 epok ile eğitilmiştir. Çalışmada kullanılan algoritmada modelin içinde, Faster R-CNN sınırlayıcı kutusu ve görüntü sınıfı öngörüsünün yanı sıra ek olarak maskeleme ile segmentasyon özelliğine sahiptir. Modelde omurga olarak kullanılan mimari göre ResNet-101 (He vd., 2016) olarak seçilmiştir.


3. Uygulama

Uygulamada kullanılan model Mask R-CNN mimarisidir. Bu yöntemle, görüntülerdeki tespit edilen gemilerin konumlarıyla beraber geminin etrafına hizalı bir sınırlayıcı kutu çizilir. Gemi sınırlarının maskelemeye dayalı örnek segmentasyon işlemi gerçekleştirilir. Modelin eğitimi esnasında scikit-learn kütüphanesi yardımıyla kullanılan veri setindeki örnek maskeler rastgele olarak bölünmüş ve yaklaşık 34000 adet eğitim ve 8500 adet de validasyon gemi sınıfı maskesi kullanılmıştır. Uygulamada eğitilen model için IoU = 0.5 (birleşmenin kesişimi) olarak tatbik edilmiştir. Buna göre belirlenen IoU değerinin altında kalan kesişimli tahminleri gemi sınıfı olarak segmente işlemi gerçekleştirilmeyecektir.





Şekil 1.Referans veri (sağ) ve test sonucu (sol) örnekleri




Şekil 2. Test görüntülerinde tespit edilen gemi sınıfına (doğru pozitif) örnek segmentasyon örnekleri

Kullanılan derin öğrenme modelinde, gemi sınıfı tahmin eşik değeri 0.95 olarak belirlenmiş ve bu değerin altındaki tahminler gemi sınıfı olarak tespite dâhil edilmemiştir. Model, kodlanmış ve kodu çözülmüş (encoded & decoded) maske tekniği ile çalışmaktadır. Modelde tanımlanan sınıflar gemi ve gemi olmayan sınıf şeklinde belirlenmiş, tekil nesne tespiti

Uydu Görüntülerinden Örnek Segmentasyonu ile Gemi Tespiti

olarak hedef olarak gemi seçilmiştir. Sınırlayıcı kutu ile gemi tespiti aşaması için maksimum olmayan bastırma (non-maximum suppression) değeri 0.05 olarak belirlenmiştir. Modelin testi için eğitim ve validasyon görüntülerinden farklı olarak rastgele 120 görüntü belirlenmiştir. Test sonucunda elde edilen performans metrikleri Tablo 1’de gösterilmiştir. Tabloda mAP değeri ortalama kesinlik değerlerinin ortalamasına karşılık gelmekte ve uygulamada %71.34 olarak elde edilmiştir. Olasılık skoru ise, tahmin edilen gemi sınıfı için güven olasılığına karşılık gelmektedir. Aynı zamanda, test görüntülerinin sonuçlarında tespit edilen gemilerin üzerinde güven olasılığı değerleri yazmaktadır. Şekil 1’de test görüntüleri için örnek referans veri ve test sonucu gösterilmiştir. Şekil 2’de, eğitilen derin öğrenme modeli ile test aşamasında tahmin sonuçlarına doğru pozitif gemi örnekleri gösterilmiştir.



Şekil 3. Test görüntülerinde yanlış tahmin edilen gemi sınıfı (yanlış pozitif) örnek segmentasyon gösterimi

Şekil 3’te, modelin test aşamasında yanlış tahmin edilen (yanlış pozitif) gemi sınıfı örneği gösterilmiştir. Eğitilen model kullanılarak tespit edilen gemiler, maskelenerek ve gemi sınıfı olma olasılığı olan skorlarıyla birlikte sınırlayıcı kutu gösterimi yapılmıştır. Uygulamada, NVIDIA Tesla P100 GPU hesaplama işlemcisi kullanılmıştır.

Tablo 1. Test görüntüleri kullanılarak model için elde edilen performans metrikleri

Test	mAP	Kesinlik	Hassasiyet	Olasılık Skoru	F1-skoru
120 Görüntü	71.34	68.89	61.57	99.17	65.02

4. Sonuçlar ve Tartışma

Yıllar geçtikçe, makine öğrenimi algoritmaları giderek daha popüler hale gelmekte ve kullanım alanları her geçen gün daha da genişlemektedir. Zamanla daha da kapsayıcı hale gelen bilgisayarlı görü uygulamalarında hava veya uydu görüntülerinin kullanımı sağladıkları yüksek performansları nedeniyle her geçen gün artmaktadır. Bu alanda, son dönemlerde geliştirilen çok sayıda makine öğrenmesi yöntemi ve evrişimli sinir ağları mevcuttur. Bu yöntemler ile tekil veya çok sınıflı nesne algılama birçok uygulamada kullanılmaktadır. Otomatik gemi tespiti, bu alandaki uygulamalardan biridir. Bu çalışmada Mask R-CNN algoritması ile otomatik gemi tespiti gerçekleştirilmiş ve eğitilen modelin test aşamasında kesinlik değeri % 68.89, hassasiyet değeri % 61.57 ve F1-skoru % 65.02 olarak performans değerleri elde edilmiştir. Tahmin edilen gemiler maskelenerek örnek segmentasyonu ile tespit edilmiştir, gemi sınıfının ortalama güven olasılığı %99.17 olarak elde edilmiştir. Gelecek çalışmalarda, otomatik gemi tespiti için farklı derin öğrenme algoritmaları ve mimarisi kullanılıp, test sonuçlarında karşılaştırma yapılması amaçlanmaktadır.

Kaynaklar

Atik S.O., İpbuker C. (2020) Instance Segmentation of Crowd Detection in the Camera Images, *41th Asian Conference on Remote Sensing: Remote Sensing Enabling Prosperity, ACRS 2020*, November 9-11, Deqing – China, 422

- Atik, M. E., & Duran, Z. (2021). Deep Learning-Based 3D Face Recognition Using Derived Features from Point Cloud. In *Innovations in Smart Cities Applications Volume 4: The Proceedings of the 5th International Conference on Smart City Applications* (pp. 797-808). Springer International Publishing.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).
- Gao, L., He, Y., Sun, X., Jia, X., & Zhang, B. (2019). Incorporating negative sample training for ship detection based on deep learning. *Sensors*, 19(3), 684.
- Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- Yang, X., Sun, H., Fu, K., Yang, J., Sun, X., Yan, M., & Guo, Z. (2018). Automatic ship detection in remote sensing images from google earth of complex scenes based on multiscale rotation dense feature pyramid networks. *Remote Sensing*, 10(1), 132.
- Kaggle. Dataset For Airbus Ship Detection Challenge. <https://www.kaggle.com/c/airbus-ship-detection/> data, 2018.
- Kim, K., Hong, S., Choi, B., & Kim, E. (2018). Probabilistic ship detection and classification using deep learning, *Applied Sciences*, 8(6), 936.
- Liu, Y., Cui, H. Y., Kuang, Z., & Li, G. Q. (2017). Ship detection and classification on optical remote sensing images using deep learning. In *ITM Web of Conferences* (Vol. 12, p. 05012). EDP Sciences.
- Mask R CNN He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).