

ÜÇA Metoduyla Üretilen Verilerin YOLO v5 Modeliyle Gömülü Hedef Tespitine Etkisi

Sertan Akçali*, Fatih Erden

*Milli Savunma Üniversitesi, Barbaros Deniz Bilimleri ve Mühendisliği Enstitüsü
Elektronik Sistemleri Mühendisliği Anabilim Dalı
Tuzla, İstanbul
sertanakcali@gmail.com,

Milli Savunma Üniversitesi, Deniz Harp Okulu Dekanlığı
Elektronik Mühendisliği Bölümü
Tuzla, İstanbul
ferden@dho.edu.tr

Özet: Gömülü hedeflerin tespit edilebilmesi çeşitli bozucu etkilerden dolayı zor bir işlemdir. Bu zorluklara bir çözüm olarak son zamanlarda nesne tespiti problemlerinde başarılı sonuçlar elde eden YOLO v5 algoritması ön plana çıkmıştır. Bu çalışmada, elde gerçek verilerin olmaması nedeniyle gprMax programı ile B-taramalarından oluşan simüle veriler elde edilmiştir. Daha sonra Üretken Çekişmeli Ağ (ÜÇA) metodu ile simüle veri sayısı artırılmıştır. Burada hedeflenen, ÜÇA algoritmasıyla elde edilen verilerin, gömülü hedef tespitinde kullanılabilirliği ve yapılan eğitimde öğrenmeye olan etkisinin YOLO v5 algoritması üzerinden değerlendirilmesidir. Önerilen modelde farklı özelliklerden oluşan veri seti ile yapılan eğitimlerin performansı, elde edilen metrik değerleri üzerinden sayısal olarak analiz edilmiştir.

Abstract: The detection of buried targets is a difficult process due to various disruptive effects. As a solution to these difficulties, YOLO v5 algorithm, which has achieved successful results in object detection problems, has come to the fore. In this study, simulated data consisting of B-scans were obtained with the gprMax program, since we did not have real data. Then, the number of data simulated with the Generative Adversarial Network (GAN) method was increased. The aim is to evaluate the usability of the data obtained by the GAN algorithm in embedded target detection and its effect on learning in the training through the YOLO v5 algorithm. In the proposed model, the performance of the trainings made with the data set consisting of different features was analyzed numerically based on the metric values obtained.

1. Giriş

Yere Nüfuz Eden Radar (YNR), yer altındaki nesnelere tespitinde yaygın olarak kullanılan bir uzaktan algılama cihazıdır. Ancak YNR ile görüntü elde edilmesi, literatürde “kargaşa” olarak tabir edilen bozulmalar nedeniyle oldukça zor bir işlemdir [1]. Literatürde oluşan kargaşanın giderilmesine yönelik birçok yöntem önerilmiştir. Bu yöntemler incelendiğinde kullanılan teknikler ile oluşan bozulmalar verilerden tamamen çıkarılmamakta, hedef daha belirgin hale getirilmektedir. Ancak, hedef yapısından faydalanarak, kargaşa giderme yöntemleri kullanmadan nesne tespiti yapan algoritmalar da mevcuttur. 2014 yılı sonrasında nesne tespiti ve sınıflandırma alanında Evrişimsel Sinir Ağlarının (ESA) kullanılmaya başlanmasıyla bu alanda önemli gelişmeler yaşanmıştır. Bu alanda yapılan çalışmalar incelendiğinde Pham ve Lefevre [2] ile Kafedziski vd. [3] çalışmalarında benzetim verisi olarak elde edilen hiperbolik görüntülerden oluşan veri setleri ile gerçek ortamdaki elde edilen verileri kullanarak Daha Hızlı BESA (Bölgesel Evrişimsel Sinir Ağları) yöntemi ile hiperbolik nesnelere tanınması çalışmasını yapmışlardır. Kafedziski vd. yaptıkları çalışmada eğitim aşamasında kullanılan verilerin artırılmasının kullandıkları modelin performansını artıracaklarını göstermişlerdir. Bu amaçla gerçekleştirilen bu çalışmada elde gerçek ortamdaki elde edilen yeterli veri olmaması nedeniyle bir benzetim programı olan gprMax [4] programıyla 80 adet B-tarama görüntülerinden oluşan simüle veriler elde edilmiştir. Ardından elde edilen mevcut veriler ile YOLO v5 algoritmasıyla eğitim yapılmış, sonuçlar hem simüle veriler hem de gerçek ortamdaki elde edilen veriler üzerinde değerlendirilmiştir. Bir sonraki aşamada Üretken Çekişmeli Ağ (ÜÇA) metodu kullanılarak farklı özelliklerde veriler elde edilmiş ve bir önceki modelde kullanılan parametreler ile aynı eğitime tâbi tutulmuştur. Eğitim her iki veri seti için 1500 iterasyon sayısı ile sınırlandırılmıştır. Yaptığımız eğitimlerin her iki veri seti için aynı iterasyon sayısı ile sınırlandırılmasının amacı ÜÇA ile üretilen verilerin kullanılabilirliği ve eğitim performansına olan etkisinin incelenmesidir.

2. Metot

Bu çalışmada derin öğrenme tabanlı nesne tanıma algoritması olan YOLO v5 modeli kullanılmıştır. YOLO modelinde veri bir bütün olarak ele alınır, nesnelere ve koordinatları aynı anda tespit edilir. Tespiti yapılmak istenen

resim üzerinde, algoritma sayesinde bölgeler oluşturulur ve bu bölgeler içinde tespit edilen nesnelere etrafına çerçeve çizilir [5]. Ancak ESA modellerinde yüksek doğruluk oranına sahip bir tespit işlemi için kapsamlı bir veri setine ihtiyaç duyulmaktadır. Elde, gerçek ortamdan faydalanılabilecek veri seti bulunmaması nedeniyle öncelikle gprMax programıyla sentetik ham veriler üretilmiştir. Bu program ile oluşturulan verilerin parametreleri sistematik olarak değiştirilerek farklı benzetim YNR görüntüleri elde edilmiştir. Bu veri setinde yedi farklı toprak tipi, iki farklı hedef materyali ve iki farklı gömülme derinliği kullanılmıştır [6].

3. ÜÇA Metodu ile Sentetik Verilerin Üretilmesi


Önceleri veri artırma işleminin, resmin boyutunun değiştirilmesi, sağa-sola, yukarı-aşağı döndürülmesi gibi yöntemlerle yapılmaktaydı. Bu teknik ile model performansı bir miktar artırılmaktaydı fakat yeterli performans artışı sağlanamamaktaydı. 2014 yılında gerçeğine oldukça yakın verilerin üretilmesi amacıyla ÜÇA modeli önerilmiştir [7]. ÜÇA modelinde, birbiriyle bağlantılı Üretici (Generator) ve Ayırt edici (Discriminator) yapılar olmak üzere iki farklı ağ yapısı bulunmaktadır. Üretici kısmında sentetik veriler oluşturulur ve ayırt edici ağ kısmında oluşturulan bu resimler ile gerçek resimler dahil edilir. Ayırt edici ağ kısmında gerçek resim ile üretilen resim arasındaki kayıp fonksiyonu hesaplanarak ve her bir iterasyonda ağlardaki değerler güncellenerek daha gerçekçi resimler üretilir [8]. Bu çalışmada kullanılan modelde farklı çözünürlüklerde 100 adet sentetik veri üretilmiştir.

4. Uygulama


Çalışmanın ilk adımında sadece gprMax programıyla elde edilmiş ve ham veriler olarak adlandırılan veriler ile eğitim yapılmıştır. İkinci adımda ÜÇA algoritmasıyla elde edilen veriler ile gprMax verileri (Ham+ÜÇA) toplamından oluşan veri seti ile eğitim yapılmıştır. Kullanılan her iki modelde de yapılan eğitimlerde verilerin %80'i eğitim, %20'si doğrulama verileri olarak kullanılmıştır. Modelin test verileri her iki model için aynı veriler olarak seçilmiştir. Ham veriler ile yapılan eğitimde toplam 50 veri, Ham+ÜÇA eğitiminde 150 veri kullanılmıştır. Test için ilk veri setinden farklı özelliklerde beş resim ayrılmıştır. Bununla beraber simule veriler ile yaptığımız eğitimler hem simule veriler üzerinde hem de 2009 yılında Uluslararası İnsani Mayın Arındırma Test ve Değerlendirme Programı'nın (ITEP) bir projesi olarak Almanya'da gerçekleştirilen mayın temizleme operasyonlarından elde edilen gerçek ortam verisi üzerinde incelendi. Kullanılan gerçek ortam verisi 5 hedef nesne içeren, farklı derinliklerde ve farklı mesafelere yerleştirilmiş kara mayınlarından oluşmaktadır [6].

Hiperboller	Simule Veriler (%)					Gerçek Veriler (%)				
	1	2	3	4	5	1	2	3	4	5
Ham	81	80	79	82	83	72	76	75	-	-
Ham+ÜÇA	87	88	86	89	88	78	77	85	76	75

Tablo 1. Güven Skorları Sonuçları



(a)



(b)
Şekil 4.1: Güven Skoru Sonuçları (a) Ham Veri, (b) Ham+ ÜÇA

	mAP 0.50	mAP 0.50-0.95	P	R	Loss
Ham	0.947	0.532	0.870	0.909	0.02795
Ham+ÜÇA	0.996	0.591	0.893	0.996	0.02279

Tablo 2. Eğitim sonu elde edilen metrik sonuçları

5. Sonuçlar ve Yorumlar

Ham+ÜÇA verileriyle yapılan eğitimin hem gerçek ortam verisi hem de simule verileri üzerindeki güven skoru, sadece ham verilerle yapılan eğitimin skoruna göre artış göstermiştir (Şekil 1, Tablo 1). Her iki test sonucu elde edilen toplam kayıp değerleri ve metrik değerleri incelendiğinde veri sayısı artırılmış eğitimin sonuçları daha başarılı elde edilmiştir. (Şekil 2, Tablo 2). Sonuç olarak, ÜÇA metoduyla artırılan veri sayısının eğitim sonucuna olumlu yönde etki ettiği gözlemlenmiştir. Gömülü nesnelerin derin öğrenme modelleriyle tespit edilmesinde, farklı derin öğrenme mimarilerinin kullanılması, eğitim sayısının ve veri sayısının artırılması, daha çeşitli hiperbolik resimlerin eğitime dahil edilmesi modelin daha da geliştirilmesi ilerideki çalışma hedefleridir.

Kaynaklar

- [1]. Kumlu D., ve Erer I., "Yerel Olmayan Ortalamalar Yaklaşımı İle Yere Nüfuz Eden Radar Görüntülerinde Kargaşa Giderme," Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, Cilt 35, sayı 3, s.1269-1284 2020.
- [2]. Pham M., ve Lefèvre S., "Buried Object Detection from B-Scan Ground Penetrating Radar Data Using Faster-RCNN," IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium, Valensiya, İspanya, s. 6804-6807, 2018.
- [3]. Kafedziski V., Pecov S. ve Tanevski D., "Detection and Classification of Land Mines from Ground Penetrating Radar Data Using Faster R-CNN," 2018 26th Telecommunications Forum (TELFOR), Belgrad, Sırbistan, s.1-4, 2018.
- [4]. Warren, C., Antonios G., ve Iraklis G., "gprMax: Open Source Software To Simulate Electromagnetic Wave Propagation for Ground Penetrating Radar," Computer Physics Communications, Cilt 209, s. 163-170. 2016.
- [5]. Du, J., "Understanding of Object Detection Based on CNN Family and YOLO," Journal Of Physics: Conference Series, Cilt 1004, s.1-8, Hong Kong.
- [6]. Kumlu, D., ve Erer, I., "Improved Clutter Removal in GPR by Robust Nonnegative Matrix Factorization," IEEE Geoscience And Remote Sensing Letters, Cilt.17(6), s.958-962, 2020.
- [7]. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., ve Ozair, S., "Generative adversarial networks," Communications Of The ACM, Cilt 63(11), s.139-144, 2014.
- [8]. Akçalı, S., ve Erden, F., "Gömülü Hedef Tespitinde Daha Hızlı BESA Metoduna ÜÇA ile Veri Desteği," 29. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Bahçeşehir Üniversitesi, İstanbul, 9-11 Haziran 2021.