



The Effect of Data Generated by GAN Method on Embedded Target Detection with YOLO v5 Model

Sertan AkÇali and Fatih Erden

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

May 4, 2021

ÜÇA Metoduyla Üretilen Verilerin YOLO v5 Modeliyle Gömülü Hedef Tespitine Etkisi

Sertan Akçalı*, 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 nesnelerin tespitinde kullanılan bir uzaktan algılama ölçüm cihazıdır. Ancak yer altına gömülü nesnelerin tespitinde, yer yüzeyinden yansıyan dalgalar, çevresel etkiler, antenler arası kuplaj, istenmeyen nesnelerin varlığı gibi nedenlerden ötürü kargaşa oluşur ve hedef kargaşa tarafından maskelenir [1]. Literatürde, kargaşanın giderilmesi ve hedef sinyalinin artırılmasına yönelik birçok yöntem önerilmiştir. Bu çalışmalarda, Khan ve Al-Nuaimy [2], Gebremichael vd. [3], YNR tarafından elde edilen nesnelerin tespit edilebilirliğini artırmak için farklı sinyal işleme tekniklerini denemişlerdir. Genel olarak bu gibi teknikler ile dağınıklıklar verilerden tamamen çıkarılmasa da, büyük ölçüde bastırılır ve hedef daha belirgin hale getirilir. Ancak, hedef yapısından faydalanarak, kargaşa giderme yöntemleri kullanmadan nesne tespiti yapan algoritmalar da mevcuttur. YNR görüntülerinin hiperbolik nesnelere içermesi nedeniyle, literatürde hiperbolik nesnelerin tespit edilmesine yönelik yapılan çalışmalar incelendiğinde; Hough dönüşümü göze çarpan metotlardan birisidir [4]. Windsor vd. [5] ile Harkat vd. [6] yaptıkları çalışmada Hough dönüşüm tekniğini uygulayarak hiperbolik tespiti yapmışlardır. Fakat hiperbolik yansımaya sahip nesnelere, yüzey şekil bozuklukları, toprak yapısı, istenmeyen gürültüler hiperbolik nesnelerin bozulmasına neden olmaktadır.

2014 yılı sonrasında nesne tespiti alanında Evrişimsel Sinir Ağlarının (ESA) kullanılmaya başlanmasıyla bu alanda önemli gelişmeler yaşanmıştır. Bu alanda yapılan çalışmalar incelendiğinde Pham ve Levefre [7] ile Kafedziski vd. [8] çalışmalarında benzetim verisi olarak elde edilen hiperbolik görüntülerden oluşan veri setleri ile gerçek ortamdan elde edilen verileri kullanarak Daha Hızlı BESA (Bölgesel Evrişimsel Sinir Ağları) yöntemi ile hiperbolik nesnelerin tanınması çalışmasını yapmışlardır. Kafedziski vd. yaptıkları çalışmada eğitim aşamasında kullanılan verilerin artırılmasının kullandıkları modelin performansını artıracaklarını göstermişlerdir.

Bu amaçla gerçekleştirilen bu çalışmada öncelikle gprMax [9] programıyla 80 adet B-tarama görüntülerinden oluşan simüle veriler elde edilmiştir. Ardından elde edilen mevcut veriler ile Pytorch kütüphanesi kullanılarak YOLO v5 algoritmasıyla eğitim yapılmış, sonuçlar hem simüle veriler hem de gerçek ortamdan elde edilen veriler üzerinde değerlendirilmiştir. Bir sonraki aşamada Üretken Çekişmeli Ağ (ÜÇA) metodu kullanılarak veriler artırılmış ve bir önceki modelde kullanılan parametreler ile aynı oranlar ve aynı ortamda eğitime tâbi tutulmuştur. Eğitim her iki veri seti için 1500 iterasyon sayısı ile sınırlandırılmıştır.

2. Metot


Bu çalışmada bir ESA modeli olan YOLO v5 algoritması 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 [10]. Ancak ESA modellerinde yüksek doğruluk oranına sahip bir tespit işlemi için kapsamlı bir veri setine ihtiyaç duyulmaktadır. Elde, faydalanılabilecek gerçek ortamdan elde edilen 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 [11].

3. ÜÇA Metodu ile Sentetik Verilerin Üretilmesi

Veri artırma işleminin, resmin boyutunun değiştirilmesi, sağa-sola, yukarı-aşağı döndürülmesi gibi yöntemlerle yapılmasından başarılı sonuçlar elde edilememesi neticesinde 2014 yılında ÜÇA modeli önerilmiştir [12]. Önerilen ÜÇA modelinde, birbirleriyle bağlantılı Üretici (Generator) ve Ayırt edici (Discriminator) yapıları olmak üzere iki ESA modeli bulunur. 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 öğrenme gerçekleşir [13]. Bu çalışmada kullanılan modelde 128x128 boyutlarında 100 adet veri üretilmiştir.

4. Uygulama

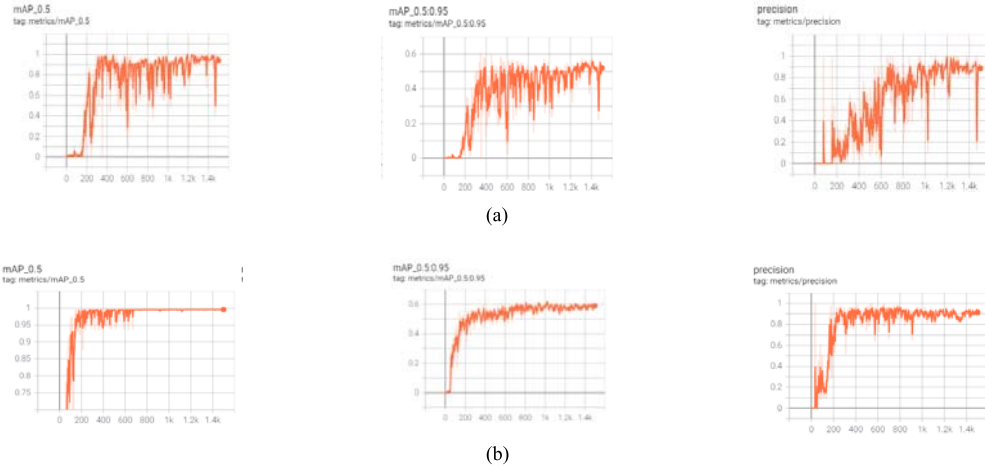
Çalışmanın ilk adımında sadece gprMax programıyla elde edilmiş ve ham veriler olarak adlandırılan veriler ile eğitim yapılmıştır. İkinci adımda ÜÇA algoritmasıyla elde edilen veriler ile gprMax verileri (Ham+ÜÇA) toplamından oluşan veri seti ile eğitim yapılmıştır. Kullanılan her iki modelde de yapılan 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.



Şekil 1. Farklı B- taramaları görüntü sonuçlarında tespit performansları, (a) Ham veriler, (b) Ham+ÜÇA verileri

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



Şekil 2. Farklı B- taramaları görüntü sonuçları metrik değerleri, (a) Ham veriler; (b) Ham+ÜÇA verileri

	mAP 0.50	mAP 0.50-0.95	AP
Ham	0.947	0.532	0.870
Ham+ÜÇA	0.996	0.591	0.893

Tablo 2. Eğitim sonu elde edilen metrik sonuçları

5. Sonuçlar ve Yorumlar

Ham+ÜÇA verileriyle yapılan eğitimin güven skoru, sadece ham verilerle yapılan eğitimin skoruna göre benzetim verilerinde yaklaşık %10'luk bir artış göstermiştir (Şekil 1, Tablo 1). Bunun yanında gerçek ortamdan elde edilen veriler üzerinde yine Ham+ÜÇA verileriyle yapılan eğitimin güven skoru sadece ham verilerle yapılan eğitimin skoruna göre %10 ile %15 arasında bir artış göstermiş ve tespit edilemeyen hiperbollerin de tespiti sağlanmıştır. Her iki test sonucu elde edilen toplam kayıp değerleri Ham için 0.02795, Ham+ÜÇA için 0.02279 hesaplanmıştır. Ham+ÜÇA verileriyle yapılan eğitim sonucunda daha yüksek Metrik değerleri 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 artırılması, daha çeşitli hiperbolik resimlerin eğitime dahil edilmesi ve veri sayılarının artırılarak 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]. Khan U., ve Al-Nuaimy, W. "Background removal from GPR data using Eigenvalues," Proceedings Of The XIII International Conference On Ground Penetrating Radar, Lecce, İtalya, s.1-5, 2010.
- [3]. Gebremichael, T., Mali, D., ve Zoubir, A. "Clutter reduction techniques for GPR based buried landmine detection," 2011 International Conference On Signal Processing, Communication, Computing And Networking Technologies. Thuckalay, Hindistan, s.182-186, 2011.
- [4]. Hough, P.V.C. Method ve means for recognizing complex patterns. United States Patent 3,069,654, 1962.
- [5]. Windsor, C., Capineri, L., ve Falorni, P., "A Data Pair-Labeled Generalized Hough Transform for Radar Location of Buried Objects," IEEE Geoscience And Remote Sensing Letters, 11(1), s.124-127, 2014.
- [6]. Harkat, H., Elfakir, Y., Bennani, S., Khaissidi, G., ve Mrabti, M. "Ground penetrating radar hyperbola detection using Scale-Invariant Feature Transform." International Conference On Electrical And Information Technologies (ICEIT). Tangiers, Fas, s.392-397, 2016.
- [7]. 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.
- [8]. 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.
- [9]. 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.
- [10]. Du, J., "Understanding of Object Detection Based on CNN Family and YOLO," Journal Of Physics: Conference Series, Cilt 1004, s.1-8, Hong Kong.
- [11]. 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.
- [12]. 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.
- [13]. 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.