

Derin Öğrenme Yöntemini Kullanarak Yere Nüfuz Eden Radar ile Gömülü Hedef Tespiti

Buried Target Detection with Ground Penetrating Radar Using Deep Learning Method

Enver AYDIN^{1,2}, Seniha Esen YÜKSEL²

¹Aselsan, Ankara, Türkiye

²Elektrik ve Elektronik Mühendisliği Bölümü, Hacettepe Üniversitesi, Ankara, Türkiye
enveraydin@aselsan.com.tr, eyuksel@ee.hacettepe.edu.tr

Özetçe—Derin öğrenme, verideki öznitelikleri ve bu öznitelikleri ayırt edebilen sınıflandırıcıyı otomatik olarak öğrenmesi nedeniyle, son beş yıldır yüksek performans sergileyerek öne çıkan bir yöntemdir. Bu çalışmada da derin öğrenme, gömülü bir hedefin yere nüfuz eden radar (YNR) ile tespiti için kullanılmıştır. GprMax benzetim programı kullanılarak oluşturulan YNR verilerini hedef var/yok şeklinde sınıflandırmak için, iki evrişim ve iki toparlama katmanı içeren bir derin öğrenme modeli önerilmiştir. Bu yapı yüz adedi hedef ve yüz adedi hedef-değil olacak şekilde iki sınıftan verilerle eğitilmiştir. Eğitimin sonucunda, derin mimarinin hangi katmanda ne gibi öznitelikler öğrendiği incelenmiştir. Bildiride sunulan ilk sonuçlar, derin öğrenmenin öznitelik çıkarımına gereksinim duymadan yüksek sınıflandırma başarısı vermesi nedeniyle, geleneksel sınıflandırma yöntemlerine göre avantajlarını vurgulamaktadır.

Anahtar Kelimeler — Derin Öğrenme, gprMax, Yere Nüfuz Eden Radar.

Abstract—Deep learning has started to outperform its rivals over the last five years, due to its capability to automatically find the features in the data, and classify them. In this study, deep learning is used to detect a buried target collected by a ground penetrating radar (GPR). The GPR data is generated by the GprMax simulation program, and a deep learning model of two convolution and two pooling layers is proposed to classify this data. The proposed model is trained with two classes, with a hundred targeted targets and a hundred non-targets. At the end of the training, the resulting features were examined in each layer of the deep architecture. The initial results presented in this study emphasize the advantages of deep learning over traditional classification methods, since it allows for high classification rates without the need for feature extraction.

Keywords — Deep Learning, gprMax, Ground Penetrating Radar.

I. GİRİŞ

YNR, yüksek frekanslı elektromanyetik (EM) dalgalar kullanarak yeraltı haritalaması için kullanılan bir araçtır. Gömülü nesnelere bulmak için kullanılan YNR ile metal ve metal içerikli olmayan mayın, tel ve boru vb. tespit edilebilir [1]. YNR, mühendislik, jeofizik ve tıp gibi birçok alanda etkin bir şekilde kullanılmaktadır. Örnek olarak; köprülerin, yolların ve demiryollarının altyapı değerlendirmesi, gömülü nesnelere bulunması, buzulların derinlik tespiti, yeraltı suyu haritalaması, mayın ve patlamamış mühimmat tanıma ve meme kanseri tümörlerinin saptanması verilebilir. EM dalgaların doğal olarak oluşmuş veya insan yapımı heterojen ortamlarda nasıl yayıldığını modellemek zor bir problemdir [2]. Gömülü nesnelere tespiti için kullanılacak olan algoritmaların ihtiyacı olan veriyi üretmek için YNR kullanmak her zaman mümkün olmamaktadır. YNR ile veri elde etmenin zorluğu ve bileşen maliyeti sebebiyle, bu ihtiyacı gidermek için bir modelleme yazılımına ihtiyaç duyulmaktadır. GprMax, bu ihtiyacı karşılayan ve YNR'nin sayısal modellemesi için EM dalga yayılımını benzetim yoluyla taklit eden açık kaynaklı bir yazılımdır [2].

Geleneksel sınıflandırma yöntemleri, YNR verilerinden öncelikli olarak öznitelik çıkarmaktadır [3]. Fakat öznitelik çıkarımı alan bilgisi gerektirmekte ve vakit almaktadır [4]. Bu sebeple, derin öğrenme algoritmalarının öznitelik çıkarımı için özel bir bilgi gerektirmemesi ve öznitelik çıkarımını sınıflandırıcı model ile eş zamanlı olarak öğrenmesi önem arz etmektedir. Oldukça yüksek işlem gücü sebebiyle daha önceleri tercih edilmeyen derin öğrenme algoritmalarının kullanımı,

özellikle son yıllardaki bilgisayar teknolojisindeki gelişmeye paralel olarak artmaktadır.

Bu çalışmada, gprMax ile elde edilen çıktuların bir ön işlem sürecinden geçirildikten sonra bir derin öğrenme algoritması kullanılarak sınıflandırılması ve bu sınıflandırmayı yaparken kendi kendine nasıl öznetelikler çıkarttığı değerlendirilmiştir.

II. DERİN ÖĞRENME: EVRİŞİMSSEL SINIR AĞLARI

Evrışimsel Sinir Ağları, sinir ağları yapılarının en gelişmiş halidir. Genel hatlarıyla bir Evrışimsel Sinir Ağları yapısı; evrişim, toparlama ve ileri besleme katmanlarından oluşmaktadır. Derin öğrenme algoritmalarının kullanılmasındaki temel amaç öznetelikleri kendi kendine öğrenebilmesidir. Bu çalışmada derin öğrenme algoritması olarak bir evrişimsel sinir ağı modeli olan Matconvnet altyapısı kullanılmıştır.

Matconvnet, Matlab için tasarlanmış olan bir Evrişimsel Sinir Ağları uygulamasıdır [5]. Bu ağıdaki katmanlar belli bir düzen içindedir. Bu bölümde tipik bir evrişimsel sinir ağları katmanlarının işlevleri anlatılacaktır.

A. Evrişimsel

Evrışimsel katman, (1)'de temsili olarak boyutları belirtilen f ile gösterilen çok boyutlu bir filtreden geçirilerek bu katmanın çıkış verisini üretmektedir. H, W, D ifadeleri ise sırasıyla satır, sütun, derinlik boyutlarına karşılık gelir. İşlemler sonucu oluşan çıkış y ile gösterilmiş olup, hesabı (2)'de verilmiştir. Bu denklemlerdeki ifadelerden x giriş verisini, f çok katmanlı ağırlık matrislerinin birleşimini, b sapma miktarını ifade eder.

$$x \in \mathbb{R}^{H \times W \times D}, f \in \mathbb{R}^{H' \times W' \times D \times D'}, y \in \mathbb{R}^{H'' \times W'' \times D''} \quad (1)$$

$$y_{i''j''d''} = b_{d''} + \sum_{i'=1}^{H'} \sum_{j'=1}^{W'} \sum_{d'=1}^D f_{i'j'd'} \times x_{i'+i''-1, j'+j''-1, d'+d''} \quad (2)$$

Evrışim işleminin geçerli olabilmesi için uygulanacak olan her filtre giriş verisi ile örtüşmelidir. Bu sebeple giriş matrisinin çevresine '0' ekleme veya uygulanan filtrenin kaydırılma miktarı üzerinde farklılıklar uygulanmaktadır. Bu işlem sonucu (2)'de verilen denklemin güncelleştirilmiş hali (3)'te verilmiştir. Denklemden bulunan P_h^- ve P_w^- sırasıyla sütuna ve satıra '0' ekleme S_h ve S_w ise düşey ve yatay yöndeki kaydırmaları ifade etmektedir.

$$y_{i''j''d''} = b_{d''} + \sum_{i'=1}^{H'} \sum_{j'=1}^{W'} \sum_{d'=1}^D f_{i'j'd'} \times x_{S_h(i''-1)+i'-P_h^-, S_w(j''-1)+j'-P_w^-, d'+d''} \quad (3)$$

İşlemler sonucu oluşan çıkış matrisinin boyutlarını hesaplamak için (4) kullanılabilir.

$$H'' = 1 + \left\lfloor \frac{H - H' + P_h^- + P_h^+}{S_h} \right\rfloor \quad (4)$$

B. Tamamen Bağlı

Evrışimsel katman ile aynı hesaplama yöntemlerini kullanılmaktadır. Eğer bu katman uygulandıktan sonra çıkış matrisinin satır ve sütun bilgisi 1'e eşit olduğunda tamamen bağlı katmanı olarak adlandırılmaktadır.

C. Toparlama

Toparlama katmanı, matris boyutunu küçültmek için kullanılmaktadır. Derin öğrenme modellerinde bu yöntem için 2 farklı teknik kullanılmaktadır. Bu teknikler maksimum ve ortalama toparlama olup model tasarımına bağlı olarak uygulanmaktadır. Denklem (5) ile gösterilen maksimum toparlama işlemi, ilgili matrisin $H' \times W'$ boyutlarında alınan parçası üzerinden matris içinde kalan elemanların en büyüğünü seçer.

$$y_{i''j''d''} = \max_{1 \leq i' \leq H', 1 \leq j' \leq W'} x_{i'+i''-1, j'+j''-1, d} \quad (5)$$

Ortalama toparlama işlemi (6) ile gösterilmiştir. Buradaki işlemde alınan parça içinde kalan elemanların ortalaması alınmaktadır.

$$y_{i''j''d''} = \frac{1}{W'H'} \sum_{1 \leq i' \leq H', 1 \leq j' \leq W'} x_{i'+i''-1, j'+j''-1, d} \quad (6)$$

D. Aktivasyon

Aktivasyon fonksiyonu, belli bir değer altındaki tüm elemanları o değere çekmek için kullanılmaktadır. Literatürde uygulanan yöntemlerde bu değer '0' olarak seçilmektedir. Bu katman için (7)'deki fonksiyon kullanılmaktadır ve bu denklemin aktivasyon fonksiyonlarından olan "Düzeltilmiş Doğrusal Birimi" hesaplar.

$$y_{ij} = \max\{0, x_{ij}\} \quad (7)$$

E. Grup Düzgeleme


Grup Düzgeleme katmanı (8)'deki parametreler ile (9)'da ifade edilen denklemi kullanarak Grup Düzgeleme işlemini uygulamaktadır. Çıkış matrisini hesaplamak için giriş verisindeki her kanal (3 boyutlu bir matris için 3. boyut renk boyutudur) ayrı ayrı işleme alınır.

$$x, y \in \mathbb{R}^{H \times W \times K \times T}, w \in \mathbb{R}^K, b \in \mathbb{R}^K \quad (8)$$

Denklem (8)'de geçen T ifadesini grup boyutu kabul edersek; (9)'da kullanılacak olan ortalama ve standart sapma değerleri ise (10)'daki gibi hesaplanır.

$$y_{ijkt} = w_k \frac{x_{ijkt} - \mu_k}{\sqrt{\sigma_k^2 + \epsilon}} + b_k \quad (9)$$

$$\mu_k = \frac{1}{HWT} \sum_{i=1}^H \sum_{j=1}^W \sum_{t=1}^T x_{ijkt}, \sigma_k^2 = \frac{1}{HWT} \sum_{i=1}^H \sum_{j=1}^W \sum_{t=1}^T (x_{ijkt} - \mu_k)^2 \quad (10)$$




Şekil 1. Önerilen Derin Öğrenme Modeli

III. DERİN ÖĞRENME ÖNCESİ ÖN İŞLEM SÜRECİ

YNR ile alınan verilerde çeşitli gürültüler ve hava-toprak geçişinden kaynaklı istenmeyen sinyaller oluşmaktadır. GprMax ile alınan verilerde ise tamamen homojen bir ortam oluşturduğumuz için gürültü oluşmamakta ve bunları kaldırmak için bir işlem gerekmemektedir. Bu kısımdaki sorun hava-toprak geçişinden kaynaklanmaktadır. Bu geçişteki EM dalgaların ilgilendiğimiz hedefin oluşturduğu EM dalgalarına göre daha baskın yansımalar vermesi hedefin Şekil 2-a'daki gibi çok net seçilememesine neden olmaktadır. Derin Öğrenme öncesi gprMax programından alınan çıktıların ve bu çıktılarda gömülü olarak oluşturduğumuz hedeflerin Evrişimsel Sinir Ağına daha iyi bir girdi oluşturmak adına ön işlem sürecinden geçirilmesi gerekmektedir.

A. Yer Yansıması Kaldırma

YNR sistemlerinde bulunan hava-toprak geçişlerinden kaynaklanan istenmeyen sinyaller kaldırılarak gömülü olarak bulunan hedef ortaya çıkarılmıştır. Bu sinyalleri kaldırmanın çeşitli yolları bulunmakla birlikte, eğer düzgün bir yer yüzeyine sahipseniz ortalama çıkarma yöntemi kullanılarak Şekil 2-b'deki gibi bir çıktı elde edilmektedir.




Şekil 2. (a) İşlenmemiş gprMax verisi, (b) Hava-Toprak geçişi kaldırılmış gprMax verisi

B. Beyazlatma İşlemi

Yer yansıması kaldırıldıktan sonra Şekil 2-b'de gözükten hiperbol şeklindeki yansımanın kollarına doğru yansıma sinyallerinin azaldığı gözükmemektedir. Bu azalmanın sebebi toprak derinliklerine indikçe YNR verici anteninden basılan EM dalgaların alıcı antene ulaşana kadar sinyal gücünü kaybetmesi

olarak gösterilebilir. Derinliğe bağlı olarak değişen sinyal güçlerini derinlikten bağımsız olacak şekilde veri elde etmek için beyazlatma işlemi uygulanmaktadır [6]. Beyazlatma işlemi sonucu oluşan gprMax verisi Şekil 3'te gösterilmektedir.



Şekil 3. Beyazlatma işlemi uygulanmış gprMax verisi

C. Önerilen Derin Öğrenme Model Mimarisi

Matconvnet kütüphanesinde hazır olarak bulunan modellerden yola çıkılarak ve benzetim süreleri göz önünde bulundurularak Tablo I 'deki bir model önerilmiştir.


TABLO I. MODEL MİMARISI

Katman	Evrişim	Toparlama	Evrişim	Toparlama	Tamamen Bağlı	Tamamen Bağlı
Parça	11x11	3x3	5x5	2x2	6x6	1x1
Derinlik	12	12	96	96	96	2
Kaydırma	4	2	2	2	1	1
"0" ekleme	-	-	-	-	-	-

Tablo I 'de gösterilen modele göre derin öğrenme algoritmasının işleyişi Şekil 1'de gösterilmiştir.

D. Eğitim Verileri

Evrişimsel Sinir Ağı 200 adet eğitim verisi ile eğitilmiştir. Bu eğitimi doğrulama için 22 adet doğrulama verisi kullanılmıştır. Eğitim verileri 2 farklı sınıfa ayrılarak yer altında gömülü bir cisim bulunup bulunmamasına göre hedef ve hedef



Şekil. 4. Eğitilmiş Evrişimsel Sinir Ağı Görüntülenmesi (Aktivasyon ve Grup Düzgeleme katmanları gösterilmemiştir.)

değil olarak sınıflandırılmıştır. Hedef olarak 1 cm'den 50 cm'ye kadar farklı derinliklerde; kuru, nemli ve ıslak toprak çeşitlerinde 1, 2 ve 3 cm çapında bakır teller; 5, 10 ve 15 cm çapında 5 cm yüksekliğinde silindirler gömülmüş ve bu cisimler hedef sınıfı olarak tanımlanmıştır. Hedef değil sınıfına ise farklı gürültüler eklenmiş gömülü cisim bulunmayan hedef sınıfındaki toprak çeşitleri verilmiştir. Bu eğitim sonucu eğitim hata oranı %0,5 ve doğrulama hata oranı %0 olarak hesaplanmıştır. 2 ayrı sınıftan 10'ar adet olacak şekilde 20 adet test verisi ile yapılan testler sonucu başarı oranı %100 olarak çıkmıştır.

E. Evrişimsel Sinir Ağı Ne Öğrendi?

Evrişimsel Sinir Ağı'nın ne öğrendiğini yorumlamak için birkaç yöntem bulunmaktadır. Geliştirilen bu yöntemler, öznelikleri nasıl öğrendiğini anlamak için geliştirilmiştir [7]. Oluşturduğumuz modeli iyileştirmek ve daha karmaşık veriler için doğru sonuç vermesini sağlamak için bu yorumlamaya ihtiyaç bulunmaktadır [8]. Giriş verisinin katmanlarla etkileşiminin görüntülenmesi ve bu katmanlarının görüntülenmesi yorumlamaya yardımcı olmaktadır. Katmanlardaki ağırlık matrislerinin direkt olarak görüntülenmesi sonucu oluşan görüntüleri yorumlamak oldukça zordur. Bu nedenle giriş verisinin bu katmanlardan geçişi boyunca oluşturduğu görüntüleri yorumlamak daha anlamlı olmaktadır. Şekil 4'te toprağa gömülü olarak belli bir derinlikte bulunan bir telin eğitilmiş katmanlardan geçişi sırasında nasıl gözüktüğü anlamlandırılmaya çalışılmıştır. Bu şekilde evrişimsel ve toplama katmanları arasında bulunan grup düzgeleme ve aktivasyon katmanları gösterilmemiştir. Özellikle toplama katmanının sadece boyut küçültme odaklı olduğu düşünüldüğünde aktivasyon katmanında negatif değerlerin 0'a çekilmesi hedefin arka plandan ayrılmasına yardımcı olmuştur. Şekil 4'teki ilk toplama katmanında bu etki görülmektedir. Toprak olarak gözüken arka planları siyah piksele yaklaştırır ve asıl olan hedef bölgesini beyaz olarak göstermektedir [9]. Buradan hareketle evrişimsel katmanın tek başına sınıflandırma sağlayamayacağını söyleyebiliriz [9]. Son toplama katmanında da beyaz piksellerin hedefin olduğu bölgeye yoğunlaştığını ve daha önce bahsedilen hiperbol şeklinin korunmaya çalışıldığını görebiliriz. Son aktivasyon işlemi sonrası toplama katmanında gözüken gri matrisler bu filtreye takılan yani negatif değerli matrislerdir. Hedefin olduğu bölgedeki bu belirginlik bu algoritmanın sınıflandırmayı hedef yönünde yapacağını işaret etmektedir.

IV. SONUÇLAR VE GELECEK ÇALIŞMALAR

Bu çalışmanın sonucu olarak Evrişimsel Sinir Ağı'nın öğrendiği öznelikleri yorumlanmıştır. Derin öğrenme yöntemlerinde yüksek başarı oranı önemli olmakla birlikte burada öznelik çıkarım gereksinimi duymaması geleneksel sınıflandırma yöntemlerine göre üstünlüğünü göstermektedir. Derin öğrenme ile alınan ilk sonuçlar gelecek çalışmalar için ümit verici olmakla birlikte sadece gömülü bir cismin tespiti değerlendirilmiştir. Gelecek çalışmalarda iki farklı gömülü cismin birbirinden ayırt edilmesi değerlendirilecek ve bu değerlendirme çok sayıda daha zor veriler ile yapılacaktır. Bu çalışmadan alınacak sonuçlar ile öğrenilen modelin farklı toprak türlerinde gömülü cisimlere uygulanması üzerinde çalışılacaktır.

KAYNAKLAR

- [1] N. P. Singh and M. J. Nene, "Buried object detection and analysis of GPR images: Using neural network and curve fitting", *2013 Annual International Conference on Emerging Research Areas and 2013 International Conference on Microelectronics, Communications and Renewable Energy*, Kanjirapally, 2013, pp. 1-6.
- [2] Warren, C., Giannopoulos, A. and Giannakis I. "gprMax: Open source software to simulate electromagnetic wave propagation for Ground Penetrating Radar", *Computer Physics Communications*, 209, 163-170, 2016.
- [3] S. E. Yuksel, J. Bolton and P. Gader, "Multiple-Instance Hidden Markov Models With Applications to Landmine Detection", in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 12, pp. 6766-6775, Dec. 2015.
- [4] S. E. Yuksel and P. Gader, "Context-based classification via mixture of hidden Markov model experts with applications in landmine detection", *IET Computer Vision*, vol. 10, no. 8, pp. 873-883, 2016.
- [5] A. Vedaldi and K. Lenc, "MatConvNet - Convolutional Neural Networks for MATLAB", *Proc. of the ACM Int. Conf. on Multimedia*, 2015.
- [6] P. Gader, Wen-Hsiung Lee and J. N. Wilson, "Detecting landmines with ground-penetrating radar using feature-based rules, order statistics and adaptive whitening" in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 11, pp. 2522-2534, Nov. 2004.
- [7] *CS231n Convolutional Neural Networks for Visual Recognition*, [Online]. Available: <http://cs231n.github.io/understanding-cnn/>.
- [8] N. Mousavi, H. Siqueira, P. Barros, B. Fernandes and S. Wermter, "Understanding how deep neural networks learn face expressions", *2016 International Joint Conference on Neural Networks (IJCNN)*, Vancouver, BC, 2016, pp. 227-234.
- [9] M. D. Zeiler, R. Fergus, "Visualizing and understanding convolutional networks", *Proc. Eur. Conf. Comput. Vis.*, pp. 818-833, 2014.