

**YERE NÜFUZ EDEN RADAR VERİLERİNDE TEL TESPİTİ
İÇİN AKTARIM VE ÇOK GÖREVLİ ÖĞRENME
YÖNTEMLERİ**

**TRANSFER AND MULTI TASK LEARNING METHODS FOR
WIRE DETECTION FROM GROUND PENETRATING
RADAR DATA**

ENVER AYDIN


YRD. DOÇ. DR. SENİHA ESEN YÜKSEL
Tez Danışmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin
Elektrik-Elektronik Mühendisliği Anabilim Dalı için Öngördüğü
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2018

ENVER AYDIN'ın hazırladığı “**Yere Nüfuz Eden Radar Verilerinde Tel Tespiti İçin Aktarım ve Çok Görevli Öğrenme Yöntemleri** ” adlı bu çalışma aşağıdaki jüri tarafından **ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Gözde BOZDAĞI AKAR
Başkan




Yrd. Doç. Dr. Seniha Esen YÜKSEL
Danışman



Prof. Dr. Birsen SAKA TANATAR
Üye



Doç. Dr. Özlem ÖZGÜN
Üye



Yrd. Doç. Dr. Yakup ÖZKAZANÇ
Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU
Fen Bilimleri Enstitüsü Müdürü

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

- ☒ **Tezimin/Raporumun tamamı dünya çapında erişime açılabilir ve bir kısmı veya tamamının fotokopisi alınabilir.**

(Bu seçenekle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etseniz ve kütüphane bu talebinizi yerine getirirse bile, tezinin arama motorlarının önbelleklerinde kalmaya devam edebilecektir.)

- ☐ **Tezimin/Raporumun tarihine kadar erişime açılmasını ve fotokopi alınmasını (İç Kapak, Özet, İçindekiler ve Kaynakça hariç) istemiyorum.**

(Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin/raporumun tamamı her yerden erişime açılabilir, kaynak gösterilmek şartıyla bir kısmı ve ya tamamının fotokopisi alınabilir)

- ☐ **Tezimin/Raporumun tarihine kadar erişime açılmasını istemiyorum, ancak kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisinin alınmasını onaylıyorum.**

- ☐ **Serbest Seçenek/Yazarın Seçimi**

12 / 03 / 2018



Enver AYDIN

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

12 / 03 / 2018

Enver AYDIN

ÖZET

YERE NÜFUZ EDEN RADAR VERİLERİNDE TEL TESPİTİ İÇİN AKTARIM VE ÇOK GÖREVLİ ÖĞRENME YÖNTEMLERİ

Enver AYDIN

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü

Tez Danışmanı: Yrd. Doç. Dr. Seniha Esen YÜKSEL

Şubat 2018, 87 sayfa

Yere Nüfuz Eden Radar (YNER), gömülü hedef tespiti, sınıflandırması ve tanımlanması uygulamalarında yaygın olarak kullanılan bir araçtır. YNER, gömülü hedeflerin toprağa göre elektriksel iletkenlik farklılıklarından yararlanarak çıktı oluşturmaktadır. Aynı şekle sahip ancak farklı materyallerden oluşan hedeflerin sınıflandırılması, özellikle benzer elektriksel iletkenliğe sahip hedeflerde zor bir problemdir. Hedef dışındaki cisimlerden kaynaklı yansımalar, yani gürültüler, bu zorluğun katlanarak artmasına neden olmaktadır. Böyle bir sınıflandırma probleminde, öznelilik çıkarımının çok zor olması ve alan bilgisi gerektirmesi nedeniyle, derin öğrenme yöntemi kullanılmıştır. Derin öğrenme, verideki öznelilikleri ve sınıflandırıcıyı otomatik olarak öğrenmesi sayesinde son beş yıldır üstün performans sergileyerek öne çıkan bir yöntemdir.

Derin öğrenme modeli, öznelilikleri otomatik olarak öğrenmek için çok sayıda veriye ihtiyaç duymaktadır. Gerçek veri toplamanın maliyetli ve zor olması nedeniyle bu tezde YNER benzetimi yapan gprMax programı ile sentetik YNER verisi

üretmiştir. Bu veri kümesi, kuru/nemli/ıslak topraklara yerleştirilmiş plastik tel hedefleri ile başka materyallerden yapılmış teller ve parazit cisimlerden oluşmaktadır. Üretilen veriler, üç çeşit sınıflandırma algoritmasıyla sınıflandırılmıştır. Bunlar, (i) standart derin evrimsel sinir ağları, (ii) aktarım öğrenmesi kullanılan bir derin öğrenme modeli ve (iii) çok görevli öğrenme kullanan bir derin öğrenme modelidir. Aktarım öğrenmesi, önceden çok sayıda veri ile eğitilmiş bir derin öğrenme modelinden kazanılan bilgilerin mevcut modele aktarılması işlemidir. Bu sayede önceden eğitilmiş modelin çok sayıda veriden kazandığı genel öznitelikler (ör. renk ve kenar algılama), mevcut derin öğrenme modeline aktararak, az sayıda eğitim verisi olmasına rağmen iyi bir sınıflandırılma başarımı elde edilmesi sağlanmıştır. Fakat farklı toprak türlerinde hedef tespitin zorlaştığı görülmüştür. Bu nedenle hedef tespit başarımını daha da yükseltmek için çok görevli öğrenme yöntemi kullanılmıştır. Çok görevli öğrenme, diğer ilgili görevlerin eğitim bilgilerini kullanarak bir göreve yönelik öğrenmeyi iyileştiren bir yaklaşımdır. Bu tezde çok görevli öğrenmenin birincil görevi, hedefler ile hedef olmayan cisimlerin ayrılmasıdır. İkinci görevi ise toprak türünün tespitidir. Her görev için öğrenilenler, diğer görevlerin daha iyi öğrenilmesine yardımcı olabilir. Bu sayede, toprağın çeşidine göre hedef tespiti yapan, daha özelleştirilmiş bir sınıflandırıcı eğitilmiştir. Çok görevli öğrenme yönteminin uygulanması ile toprak türü görevinin öğrendiklerinin hedef tespit başarımına olumlu katkı sağladığı görülmüştür.

Bu tezin amacı, gömülü olarak bulunan hedeflerin yüksek başarımla doğru sınıflandırılmasıdır. Bu amaç doğrultusunda, derin öğrenme, aktarım öğrenmesi ve çok görevli öğrenme yöntemleri önerilmiş ve başarımları incelenmiştir.

Anahtar kelimeler: Yere Nüfuz Eden Radar, derin öğrenme, aktarım öğrenmesi, çok görevli öğrenme, gprMax.

ABSTRACT

TRANSFER AND MULTI TASK LEARNING METHODS FOR WIRE DETECTION FROM GROUND PENETRATING RADAR DATA

Enver AYDIN

**Master of Science, Department of Electrical and Electronics
Engineering**

Supervisor: Asst. Prof. Seniha Esen YUKSEL

February 2018, 87 pages

Ground Penetrating Radar (GPR) is a commonly used tool for buried target detection, classification and identification applications. GPR produces output based on the electrical conductivity differences of buried targets relative to the ground. Classification of targets with same shape but made up of different materials is a difficult problem, especially for targets with similar electrical conductivity. Reflections from objects except the target exponentially increase the difficulty of this problem. In such a classification problem, deep learning has been used since the extraction of features is very difficult and requires expert knowledge. Deep learning is a method that has demonstrated state-of-art performance over the last five years thanks to automatic learning of features in data and classifier.

The deep learning model needs a lot of data to learn the features automatically. Since real data collection is costly and difficult, in this thesis synthetic GPR data is generated with the gprMax program, which simulates GPR. This dataset consist of plastic wire targets, wires which are made of other materials and clutter objects placed in dry / damp / wet soils. Generated data has been input into three classification algorithms; namely; (i) standard deep convolutional neural networks, (ii) a deep learning model that uses transfer learning and (iii) a deep learning model that uses multitask learning. Transfer learning is a process of transferring information acquired from a deep learning model previously trained with a large number of data to the current model. In this way, general features (color and edge perception) of the pre-trained model acquired from a large number data are transferred to the existing deep learning model and target detection performance has been increased. However, it has been observed that detecting targets in different soil types is difficult. For this reason, multitask learning method has been used to increase performance of the target detection. Multitask learning is an approach that improves learning about a task using the training knowledge of other related tasks. In this thesis, the primary task of multitask learning is to separate target and non-target objects. The second task is to determine the soil type. Learning from each task can provide a better learning process for the other task. With multitask learning, a customized classifier has been trained to detect targets according to soil type. Application of the multitask learning method has shown that soil type task contributes positively to the achievement of target detection.

The purpose of this thesis is to correctly classify buried targets with high performance. For this purpose, deep learning, transfer learning and multitask learning methods have been proposed and their contribution of achievement has been examined.

Keywords: Ground Penetrating Radar, deep learning, transfer learning, multitask learning, gprMax.

TEŞEKKÜR

Zamanını, tecrübesini ve bilgilerini paylaşarak bu tezin oluşturulmasında büyük emeği geçen tez danışmanım Yrd. Doç. Dr. Seniha Esen YÜKSEL'e teşekkürlerimi sunuyorum.

Her zaman yanımda olan aileme, tez süresince bana moral veren tüm arkadaşlarıma, işyerindeki yöneticilerime ve ASELSAN A.Ş.'ye destekleri için teşekkür ediyorum.



İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ŞEKİLLER	viii
ÇİZELGELER	x
SİMGELER VE KISALTMALAR	xi
TERİMLER	xiii
1. GİRİŞ	1
1.1. Veri Kümeleri	9
1.1.1. Birinci Veri Kümesi	9
1.1.2. İkinci Veri Kümesi	15
1.2. Tezin Amacı	15
1.3. Tezin Akışı	16
2. LİTERATÜR ÖZETİ	18
2.1. Uzaktan Algılama Teknolojisi	18
2.1.1. Yere Nüfuz Eden Radar (YNR)	18
2.1.2. Gömülü Nesne Tespitinde Kullanılan Diğer Yöntemler	21
2.1.2.1. Elektriksel Empedans Tomografisi (EET)	21
2.1.2.2. X-ışını Geri Yansıması	21
2.1.2.3. Kızılötesi Sistemler	22
2.1.2.4. Akustik / Sismik Sistemler	22
2.1.2.5. Nötron Yöntemi	23
2.1.2.6. Diğer Yöntemler	23
2.2. Literatürde Kullanılan Sınıflandırma Yöntemleri	23
3. DERİN ÖĞRENME: EVRİŞİMSEL SİNİR AĞI	33
3.1. Algılayıcı	33
3.2. Sinir Ağları	34
3.3. Evrişimsel Sinir Ağları	35
3.3.1. Evrişimsel Katman	35

3.3.2.	Aktivasyon Katmanı.....	36
3.3.3.	Toparlama Katmanı.....	37
3.3.4.	Tamamen Bağlı.....	39
3.4.	Aktarım Öğrenmesi	39
3.5.	Çok Görevli Öğrenme.....	40
4.	YNR VERİ KÜMESİNİN OLUŞTURULMASI	43
4.1.	YNR Modellemesi.....	43
4.1.1.	GprMax Koordinat Sistemi	44
4.1.2.	GprMax ile YNR Modelleme.....	44
4.1.2.1.	Adım Aralığı	44
4.1.2.2.	Sönümleyen Sınır Koşulu	45
4.1.3.	GprMax Girdi Dosyası Komutları.....	46
4.1.4.	Gömülü Nesnelerin EM özellikleri	50
4.2.	Ön İşleme.....	51
4.2.1.	Yer Yansıması Kaldırma	54
4.2.2.	Beyazlatma	56
5.	DERİN ÖĞRENME YÖNTEMİ İLE GÖMÜLÜ HEDEF TESPİTİ	58
5.1.	Çok Görevli Öğrenme Yöntemi Detayları	60
5.2.	Evrişimsel Sinir Ağı Ne Öğrendi?	64
5.3.	Çalışma Detayları, Deneysel Sonuçlar, Başarımlar ve Limitler	66
6.	SONUÇLAR.....	73
	KAYNAKLAR.....	75
	EKLER	82
	ÖZGEÇMİŞ	86

ŞEKİLLER

Sayfa

Şekil 1. Örnek gprMax A ve B tarama görüntüleri	3
Şekil 2. Farklı toprak türlerine gömülü 1cm yarıçapındaki bakır telin A ve B tarama görüntüleri	4
Şekil 3. Kuru toprağa gömülü 1cm yarıçapındaki farklı materyaldeki tellerin A-tarama görüntüsü	6
Şekil 4. Kuru toprağa gömülü 1cm yarıçapındaki bakır telin 10 ve 20 cm derinliklerdeki A ve B tarama görüntüleri.....	7
Şekil 5. Çok katmanlı bir derin öğrenme yapısı	8
Şekil 6. Verileri oluşturmak için kullanılan model.....	11
Şekil 7. Modele girdi oluşturacak verilere gürültü ekleme işlemi.....	12
Şekil 8. Hedef tespiti veri kümesinden örnek resimler (ön işlem uygulanmış)	13
Şekil 9. Islak toprağa gömülü 20cm derinlikteki yaklaşık 5x5cm boyutlarındaki bir taşın modellenmesi	14
Şekil 10. Islak toprağa gömülü 20cm derinlikteki yaklaşık 5x5cm boyutlarındaki bir taşın gprmax B-tarama görüntüleri	14
Şekil 11. Tez sürecinde yapılan işlem adımları	16
Şekil 12. Yere nüfuz eden radar işleyiş şeması.....	19
Şekil 13. Gömülü bir cisim, ortam ve sinyallerin gösterimi.....	20
Şekil 14. İmza oluşturulması için kullanılan yöntem [12]	24
Şekil 15. EHD ile gömülü cisim imzaları	25
Şekil 16. İki farklı düşük oranda metal içeren gömülü cisim EYS'si [10].....	28
Şekil 17. Tam uyumlu öznitelik paylaşım yapısı	31
Şekil 18. Çapraz dikiş yöntemi mimarisi [35]	32
Şekil 19. Algılayıcı yapısı	34
Şekil 20. Çok katmanlı bir sinir ağı yapısı.....	34

Şekil 21. Örnek bir evrişimsel sinir ağı yapısı	35
Şekil 22. Toparlama katmanı işleyişi	38
Şekil 23. Derin öğrenme ağlarında birleşik parametre paylaşımı	41
Şekil 24. Derin öğrenme ağlarında ayırık parametre paylaşımı	42
Şekil 25. GprMax koordinat sistemi	44
Şekil 26. ABC ile sınırlandırılmış bir YNR modellemesi [52]	46
Şekil 27. Örnek bir GprMax girdi dosyası ve açıklamaları	47
Şekil 28. Kuru toprağa gömülü plastik telin gprMax girdi dosyası	48
Şekil 29. Kuru toprağa gömülü asfalt telin gprMax girdi dosyası	48
Şekil 30. Kuru toprağa gömülü beton bozuk yüzeyli cismin gprMax girdi dosyası	49
Şekil 31. *.vti dosya formatını Paraview ile görüntüleme işlemi	53
Şekil 32. GprMax YNR modeli sonuçları	54
Şekil 33. Yer yansıması kaldırma işlemi	55
Şekil 34. Beyazlatma işlemi	57
Şekil 35. Önerilen ESA model mimarisi genel yapısı	58
Şekil 36. Önerilen derin öğrenme mimarisi modeli katmanları ve geçişi	59
Şekil 37. Çok görevli öğrenme ile hedef tespit görevi başarıımı	61
Şekil 38. Çapraz dikiş yöntemi işleyiş şeması	62
Şekil 39. Bir verinin öğrenilen modelden geçişi	65
Şekil 40. Eğitim sonucu öğrenme eğrileri	68
Şekil 41. Tez kapsamında üretilen verilerde doğru sınıflandırma örnekleri	70
Şekil 42. Tez kapsamında üretilen verilerde yanlış sınıflandırma örnekleri	71
Şekil 43. Yılmaz'ın verilerinde doğru sınıflandırma örnekleri	72
Şekil 44. Yılmaz'ın verilerinde yanlış sınıflandırma örnekleri	72

ÇİZELGELER

	<u>Sayfa</u>
Çizelge 1. Hedef tespit görevi için veri kümesi	10
Çizelge 2. Toprak türü görevi için veri kümesi	10
Çizelge 3. Hedef tespit görevi için Yılmaz'ın veri kümesi	15
Çizelge 4. GprMax benzetim parametreleri	49
Çizelge 5. Kullanılan materyallerin EM özellikleri	51
Çizelge 6.Önerilen model mimarisi: ESA.....	59
Çizelge 7.Önerilen model mimarisi: aktarım öğrenmesi	60
Çizelge 8. Deneysel sonuçlar	69
Çizelge 9. Sabit tutulan parametreler	71

SİMGELER VE KISALTMALAR

Simgeler

ϵ	Elektriksel Geçirgenlik
μ	Manyetik Geçirgenlik
σ	Elektriksel İletkenlik
$\approx$	Yaklaşık Eşit
c	Işık Hızı
λ	Dalga Boyu
f	Frekans

Kisaltmalar

ABC	Absorbing Boundary Condition	Sönümleyen Sınır Koşulu
EM	Electromagnetic	Elektromanyetik
ESA	Convolutional Neural Network	Evrişimsel Sinir Ağı
FDTD	Finite Difference Time Domain	Zaman Döneminde Sonlu Farklar
FOWA	Feed-Forward Order Weighted Average Network	İleri Besleme Sıralı Ağırlıklı Ortalama Ağ
HDF5	Hierarchical Data Format, version 5	Hiyerarşik Veri Biçimi, sürüm 5
EYS	Energy Density Spectrum	Enerji Yoğunluk Specturumu
ICA	Independent Component Analysis	Bağımsız Değer Analizi
PCA	Principal Component Analysis	Temel Bileşen Analizi
PEC	Perfect Conductor	Mükemmel İletken
ReLU	Rectified Linear Units	Doğrultulmuş Lineer Birimler
RMS	Root Mean Square	Etkin Değer

SVD	Singular Value Decomposition	Tek Değer Ayrışması
YNR	Ground Penetrating Radar (GPR)	Yere Nüfuz Eden Radar



TERİMLER

“0” Ekleme	Padding
Ağırlık	Weight
Alan Uyumlaması	Domain Adaptation
Algılayıcı	Perceptron
Ayrık	Soft
Birleşik	Hard
Çok Görevli Öğrenme	Multi Task Learning
Çözünürlük	Resolution
Hedef Dışı Yansıma Azaltma	Clutter Reduction
Dalga Boyu	Wavelength
Derin Öğrenme	Deep Learning
Doğrulama	Validation
Eğitim	Traning
Eşik Değer	Threshold
Evrişimsel	Convolutional
Geri Yayılım	Back Propagation
Görüntü	Image
Gradyan	Gradient
İleri Besleme	Feed-Forward
İz	Trace
Kaydırma	Stride
Kayıp Fonksiyonu	Loss Function

Kenar Histogram Tanımlayıcıları	Edge Histogram Descriptor
Köşegen	Diagonal
Medyan	Median
Ortalama	Mean
Ödünleşim	Trade-off
Öğrenim Oranı	Learning Rate
Özdeğer	Eigenvalues
Özvektör	Eigenvector
Piksel	Pixel
Sapma	Bias
Veri	Data
Yer Yansıması	Ground Bounce


1. GİRİŞ

Gömülü bir hedefin doğru olarak tespit edilebilmesi zor bir problemdir. Gömülü cisimlerin tespitinde geleneksel bir tespit yöntemi olarak metal detektörü kullanılmaktaydı. Ancak bu yöntem ile sadece metal içerikli malzemeleri tespit edebilmektedir. Günümüzde, özellikle insan hayatını tehdit eden gömülü cisimler genelde plastikten yapılmakta veya çok az metal bileşen içermektedirler. Gömülü cisim içeriklerinde meydana gelen değişim, metal dedektörlerinin gömülü hedefler için işlevsiz kalmasına neden olmuştur. Metal içermeyen veya az miktarda metal içeriğe sahip olan gömülü cisimlerin tespiti için Yere Nüfuz Eden Radar (YNR) geliştirilmiştir. YNR, görevi yeraltındaki nesneleri tespit etmek ve belirlemek olan bir radar olarak tanımlanmaktadır [1]. YNR, literatürdeki karşılaştırmalarda gömülü hedefleri tespit etmek için en iyi performansın elde edildiği uzaktan algılama teknolojisidir [2], [3], [4], [5]. Gömülü hedef tespiti konusunda en iyi yöntem olarak gösterilmesine rağmen dezavantajları bulunmaktadır. YNR sisteminin gömülü cismi algılaması için gömülü hedefin gömülü olduğu toprak ile aralarında dielektrik farklılık bulunması gerekmektedir. YNR sistemi açısından en önemli sorun bu farklılığın yeterince olmadığı durumlardan kaynaklanmaktadır. Bu soruna bağlı olarak dielektrik farklılık çok fazla değilse bu cisimlerin tespiti zorlaşmaktadır [6]. Büyük ve metalik nesneler toprak yüzeyine daha yakın gömüldüklerinde tespit edilmesi daha kolay olsa da; daha küçük, daha derine gömülmüş ve dielektrik malzemelerden yapılmış nesneler farkedilmemektedir [7]. Ayrıca, hava-toprak geçişi ve hedef dışı yansımaların gömülü cisim imzalarına göre daha belirgin olması gömülü cisimlerin görünmemesine neden olmaktadır. Bu sorunları ortadan kaldırmak ve imzaları daha belirgin hale getirmek için yer yansıması ve hedef dışı yansımaların kaldırılmasına yönelik ön işlemler uygulanmıştır. Bunun yanında YNR sistemi, çeşitli gömülü hedefler, farklı toprak koşulları, sıcaklık, hava şartları ve değişen arazi vb. koşullardan olumsuz etkilenmektedir. Bu olumsuzluklar, hedef tespitinde yanlış alarmlara sebebiyet vermekte ve gömülü cismin patlayıcı içerdiği durumlarda ölüm veya yaralanma gibi tehlikeli sonuçlar doğurabilmektedir. Mayın tespiti uygulamalarında olduğu gibi bazı alanlarda, gerçek zamanlı veri işleme ve yanlış alarm oranlarının düşüklüğü önem arz etmektedir [8]. Bu sebeple hedefleri doğru olarak sınıflandırmak ve bu verileri işlemek için gömülü hedef tespit çözümlerinin başlangıcından itibaren birçok yöntem önerilmiştir. Son yıllarda, yeraltından bilgi

almak askeri konuların yanı sıra çeşitli sektörler tarafından; petrol, gaz arama, jeoloji, kanal ve boru lokalizasyonu vb. farklı uygulama alanlarıyla tespit algoritmaları geliştirilmektedir [9].


Gömülü cisimlerin görüntülenmesinde kullanılan YNR sistemi ile gerçek ortamda veri toplanması zaman gerektirmekte ve maliyetli olmaktadır. Dolayısıyla bu tezde, YNR sisteminin benzetimini yapmak için gprMax programı ile sentetik YNR verisi üretilmiştir. GprMax, zaman döneminde sonlu farklar (FDTD – Finite Difference Time Domain) yöntemini kullanarak elektromanyetik dalga yayılım benzetimi yapan bir programdır. YNR sisteminin ve gprMax programının ürettiği A ve B tarama olarak iki farklı tarama türü bulunmaktadır. YNR verilerinin nasıl veriler olduğunu anlamak için bu tarama türleri incelenmiştir. YNR antenlerinin sabit bir konumda aldığı tek bir tarama sonucuna A-tarama görüntüsü, antenlerin farklı konumlarda topladıkları A-taramaların toplamına B-tarama görüntüsü denmektedir.

Kuru bir toprağa gömülü 1cm yarıçapındaki bakır telin A-tarama görüntüsü Şekil 1 (a)'da ve B tarama görüntüsü Şekil 1 (b)'de gösterilmiştir. Şekilde de gözüktüğü üzere A-Tarama görüntüsünde oluşan ilk sinyaller 250 civarında oluşmuş, sinyalin genliği pozitif yönde 1200 ve negatif yönde 1700 civarlarında olup bu sinyaller hava-toprak geçişinden kaynaklanmaktadır. Toprağın 10 cm altına yerleştirilen bir bakır telin görüntüsü ise 500 civarlarında gözükmemektedir. Bu sinyalin genliği ise pozitif yönde 500 ve negatif yönde 400 civarlarındadır. Gömülü cisimlerin genel özellikleri A-taramalarda [10] görülebilmekle birlikte, sınıflandırma algoritmalarının çoğu bir nesnenin uzaysal özelliklerini kullanmaktadır [11], [12], [13]. A tarama görüntüsü, B-tarama görüntüsü üzerindeki siyah çizginin olduğu hattı göstermektedir. Bu uzaysal özellikler, B-tarama verilerinde görülebilmektedir. Bu görüntülerde oluşan hiperbolik şekil, değişen zamanla üretilmektedir. Yani sensör konumu gömülü cisme referansla hareket ettiği için yansıyan sinyalin antenlere erişmesini farklı zaman dilimlerinde farklı açılarda olmaktadır. Birkaç istisna dışında [10], [14] çoğu algoritma, hedefleri içeren B-taramalarında görülen hiperbolik benzeri şekillere yanıt vermek üzere tasarlanmış öznitelikleri çıkarmaktadır.




Şekil 1. Örnek gprMax A ve B tarama görüntüleri


Gömülü hedeflerin farklı ortam koşullarında nasıl gözüktüğü ve farklı materyale sahip gömülü cisimlerin nasıl bir YNR çıktısı verdiği sırasıyla anlatılmıştır. Şekil 2’de 1cm yarıçapındaki bir telin farklı ortam koşullarındaki A ve B tarama görüntüleri gösterilmiştir.




(a) A- tarama



(b) Kuru toprak



(c) Nemli toprak




(d) Islak toprak

Şekil 2. Farklı toprak türlerine gömülü 1cm yarıçapındaki bakır telin A ve B tarama görüntüleri

Gözöktüğü üzere farklı ortam koşullarında hem oluşan sinyallerin genliği hem de oluştuğu konum etkilenmiştir. Yani farklı ortam koşullarında aynı derinlikte gömülü olarak bulunan hedef farklı noktalarda ve farklı genliklerde belirlenmiştir. Bunun sebebi ortamların dielektrik sabitleri ve iletkenliklerinden kaynaklanmaktadır. Su yoğunluğu daha yüksek bir toprak ortamına gittikçe geçirgenlik azalmakta dielektrik sabiti artmaktadır. Kuru ortamda 3 olan bağıl dielektrik sabiti nemli toprakta 8 ve ıslak toprakta ise 20 dir. Dielektrik sabiti sinyalin ortamdaki yayılım hızını belirlemektedir [15]. Bu yavaşlamadan dolayı su yoğunluğu daha çok olan ortamdaki radar dalgaları geçirgenlikten dolayı daha yavaş hareket etmesine ve bu yavaşlık sinyalin zaman ekseninde daha ileride oluşmasının sebep olmaktadır. Sinyalin toprak ortamına yaklaşık 200br seviyesinde girdiği gözükmemektedir. Buna bağlı olarak kuru topraktaki cismin yansıması toprak yüzeyinden 307br sonra nemli ortamdaki yansıma ise 570br sonra oluşmaktadır. Materyale bağlı olarak sinyal hızı denklem (1) ile gösterilmiştir.


$$c_T = \frac{c}{\sqrt{\epsilon_r \mu_r}} \quad (1)$$

Denklemden c_T , topraktaki hızı; c ışık hızını ϵ_r ve μ_r ise sırasıyla dielektrik sabiti ile manyetik geçirgenliği ifade etmektedir. Kuru ($\epsilon_r = 6, \mu_r = 2$) ve ıslak ($\epsilon_r = 20, \mu_r = 1$) toprağın birbirine göre hızları arasında $\sqrt{\frac{20 \times 1}{6 \times 2}} \cong 1,83$ oranı bulunmaktadır. Oluşturdukları yerler arasındaki oran ise $\frac{570}{307} \cong 1,86$ olmaktadır. Ölçüm hataları göz önüne alındığında ortam farklılığından kaynaklı olarak sinyalin zaman ekseninde daha ileride oluştuğu matematiksel olarak doğrulanmıştır. Sinyal genliğinin daha küçük olmasının sebebi ise ortamın su yoğunluğuna bağlı olarak artan iletkenlik seviyesidir. Yani nemli ve ıslak topraktaki sinyaller kuru toprak türüne göre daha zayıf yansımışlardır. Bu durum, Şekil 2’de görülebilmektedir. Şekil 3’te kuru toprak ortamında 10cm derinliğe gömülü bir bakır tel ve plastik tel karşılaştırılmıştır.




Şekil 3. Kuru toprağa gömülü 1cm yarıçapındaki farklı materyaldeki tellerin A-tarama görüntüsü


Aynı ortamda oldukları için hava-toprak geçişi yansımalarının yeri ve genliği aynı noktalarda oluşmuştur. Hedef olarak gömülen iki farklı cismin gönderilen radyo sinyallerini yansıtma ya da geçirmeleri arasındaki farklılıklardan yani dielektrik sabitlerinden kaynaklı olarak bakır telde ($\epsilon_r = 10000$) sinyalin büyük bir kısmı geri yansıdığı için o bölgedeki genlik plastik tele ($\epsilon_r = 6$) göre büyük olmuştur. Sinyal hızı ortamın malzemesine bağlı olduğu için konumlar etkilenmemiştir. Aynı ortamda aynı hedef malzemesinin farklı derinliklere gömülmesi sonucu ortaya çıkan A ve B tarama görüntüleri ise Şekil 4'te verilmiştir. Daha derine gömülmüş olan hedefe sinyalin ulaşma ve yansıma süreleri daha uzun sürdüğü için x eksenindeki konumu daha ileride çıkmaktadır. Ayrıca hedefe doğru yol alan bu sinyaller daha derine gömülen hedeften yansıdığı yani ortamda daha fazla kaldığı için daha çok zayıflamaktadır. Şekil 4'te de görüldüğü gibi yüzeyin 10cm altına gömülü olan hedefin genliği 500 civarı bir değerde çıkarken, 20cm derinlikte olan hedefte bu genlik 250 civarındır.



(a) A-tarama



(a) 10cm derinlik




(b) 20cm derinlik

Şekil 4. Kuru toprağa gömülü 1cm yarıçapındaki bakır telin 10 ve 20 cm derinliklerdeki A ve B tarama görüntüleri

YNR verilerinden hedef tespiti, geleneksel sınıflandırma algoritmalarının yanı sıra derin öğrenme algoritmaları ile de yapılmaktadır. Bilgisayarların işlem gücünün yükselmesi ile birlikte geleneksel tespit algoritmaları yerini derin öğrenme algoritmalarına bırakmaktadır. Geleneksel sınıflandırma algoritmaları öznetelik bilgisine ihtiyaç duymakta ve alan bilgisi gerektirmektedir. Derin öğrenme, bir veya daha fazla gizli katmana sahip olan çok katmanlı bir sinir ağı yapısıdır. Her bir katmanda farklı veri öznetelikleri öğrenilmekte ve bu öznetelik bilgileri doğrudan

eğitim verisinden elde edilmektedir. Bu avantajları ile derin öğrenme birçok alanda geleneksel sınıflandırma algortimalarına göre üstünlüğünü kanıtlamaktadır. Yapıda bulunan gizli katmanlar, yapının derin olarak adlandırılmasına neden olmuştur. Çok katmanlı bir derin öğrenme yapısı Şekil 5'te gösterilmiştir.



Şekil 5. Çok katmanlı bir derin öğrenme yapısı

Şekilde gizli katmanlardan oluşan bir derin öğrenme mimarisi gösterilmiştir. Tez kapsamında 3 evrişimsel, 3 toplama ve 1 tamamen bağlı katmanı içeren bir derin öğrenme modeli, üretilen sentetik YNR verileri ile eğitilmiştir. Derin öğrenme algoritması, eğitim ve doğrulama verilerinin sınıflandırmasını kendi öğrendiği özelliklere göre sağlamaktadır. Bu tez çalışmasında belirlenmiş olan boyut ve değerlerde farklı filtrelerden oluşan bir model oluşturulmaktadır. Oluşturulan bu model test verilerini sınıflandırmasına göre başarımı belirlenmiştir.

Sınıflandırma yöntemlerinin asıl amacı, model başarısını en iyi konuma getirmeye çalışmaktır. Bunu yapmak için belli derin öğrenme algoritmaları kullanarak bir ESA modeli eğitilmektedir. Daha sonra bu eğitilen modelin başarımı arttırmak için filtre boyutları gibi bazı parametreleri düzenleyerek başarımları yükseltilmektedir. Bu denemeler başarımları artmaya kadar tekrarlanmaktadır. Sınıflandırma başarımını arttırmanın bu düzenlemeler dışında farklı yolları da bulunmaktadır. Derin öğrenme yönteminde geleneksel yöntemlerden farklı olarak çok sayıda veri gerekmektedir. Üretilen veriler kullanılarak derin öğrenme modeli eğitilmiştir. Eğitilen modelin başarımını iyileştirmek için literatürde farklı uygulama alanlarında kullanılan “Aktarım Öğrenmesi” ve “Çok Görevli Öğrenme” yöntemleri uygulanmıştır. Aktarım öğrenmesinin kullanılma sebebi, üretilen veri kümesinin sayısal azlığı sebebiyle derin öğrenme modelinin yeteri kadar özellik öğrenememesidir. Bu eksikliği kapatmak için daha önceden eğitilmiş (~14 milyon mertebesinde resim ile) olan derin öğrenme modelinden temel özelliklerin bulunduğu ilk katmanlar mevcut

modele aktarılmıştır. Bu sayede eğitilen modele daha iyi bir öznitelik çıkarım yeteneği kazandırılmıştır. Bu işleme aktarım öğrenmesi denmektedir. Çok görevli öğrenme, diğer ilgili görevlerin eğitim bilgilerini kullanarak bir göreve yönelik öğrenmeyi geliştiren bir yaklaşımdır. Çok görevli öğrenmede yardımcı ve ilişkili başka bir görev modelinin hedef tespitine yardımcı olması düşünülmektedir. İlişkili olması adına yardımcı görev olarak cismin gömülü olduğu toprağın belirleneceği bir toprak türü görevi oluşturulmuştur. Farklı toprak türlerinde hedef tespitinin zorlaştığı görülmüş ve hedef tespitine faydalı olması için diğer görev, toprak türü tespiti olarak seçilmiştir.

YNR üzerine uygulanan derin öğrenme yöntemlerinin hedef olarak ayırt etmeye çalıştıkları genelde hiperbolik şekile sahip olan gömülü cisimler ile bu şekil dışında kalan gürültü ve hedef dışı yansıma gibi istenmeyen cisimleri ayırt etmeye yönelik çalışmalardır. Bu ayırım materyal olarak bir ayırımdan daha çok şekil temelli bir sınıflandırmayı işaret etmektedir. Bu tez çalışmasında, aynı şekile sahip iki farklı materyalden oluşan gömülü cisimlerin ayırt edilmesi için bir ESA modeli ve geliştirmek için aktarım öğrenmesi ve çok görevli öğrenme yöntemleri sunulmuştur. Ayrıca, bozuk yüzeyli cisimler hedef dışı olarak sınıflandırılmıştır.

1.1. Veri Kümeleri

Bu tez çalışmasında kullanılacak olan veriler, YNR sisteminin benzetimi yapan gprMax programı ile elde edilmiştir. Bu veriler sınıflandırma için kullanılacak olan veri kümelerini oluşturmuştur. Tez çalışması kapsamında üretilen veri kümesi birinci veri kümesi olarak isimlendirilmiştir. Farklı bir çalışmadan elde edilen veri kümesi ise ikinci veri kümesi olarak adlandırılmıştır. Makine öğrenmesi ile sınıflandırma yapılırken veri kümesinin eğitim, doğrulama ve test adı altında 3 ayrı parçaya ayrılması gerekmektedir. İncelenen tez ve makalelerde uygulamaya bağlı olarak eğitim, doğrulama ve test oranlarının sırasıyla %50/25/25'ten %90/5/5'e kadar farklı oranlarda ayrıldığı görülmüştür. Kullanılan veri kümeleri ve dağılımları sırasıyla verilmiştir.

1.1.1. Birinci Veri Kümesi

Bu çalışma kapsamında çalışılan veri kümeleri içerdikleri veriler aynı olmakla birlikte farklı sınıf türlerine ayrılmışlardır. Hedef tespit görevi için veri kümesinde 2 sınıf oluşturulmuştur. Bunlardan ilkinde plastikten gömülü tel, silindir ve küre gibi şekli

düzgün cisimler yerleştirilmiş ve bu sınıfa hedef sınıfı adı verilmiştir. Diğer sınıfa ise yine aynı şekildeki cisimler asfalt olarak gömülmüş ve ilave olarak bozuk yüzeyli cisimler eklenerek hedef-dışı sınıfı olarak adlandırılmıştır.

Hedef tespit görevi için veri kümesinin eğitim, doğrulama ve test verilerinin dağılımı Çizelge 1’de gösterilmiştir.

Çizelge 1. Hedef tespit görevi için veri kümesi

	HEDEF			HEDEF-DIŞI					
Gömülen Malzeme	Tel (Plastik)			Tel (Asfalt)			Bozuk yüzeyli cisimler		
Toprak Türü	Kuru	Nemli	Islak	Kuru	Nemli	Islak	Kuru	Nemli	Islak
Eğitim	34	33	33	34	33	33	7	7	6
Doğrulama	17	17	16	17	17	16	7	7	6
Test	17	17	16	17	17	16	7	7	6
Toplam	200			200			60		


Toprak türü görevi veri kümesinde ise farklı toprak türlerinde 3 ayrı sınıf oluşturulmuştur. Bu sınıflar kuru, nemli ve ıslak olarak ayrılmıştır. Bu veri kümesinde gömülü cismin hedef olup olmamasından bağımsız bir şekilde, veriler gömülü oldukları toprak türlerine göre ayrılmıştır. Toprak türü görevi için veri kümesinin eğitim, doğrulama ve test verilerinin dağılımı Çizelge 2’de bulunmaktadır.

Çizelge 2. Toprak türü görevi için veri kümesi

	KURU TOPRAK		NEMLİ TOPRAK		ISLAK TOPRAK	
Gömülen Malzeme	Tel	Bozuk yüzeyli	Tel	Bozuk yüzeyli	Tel	Bozuk yüzeyli
Eğitim	150	50	150	50	150	50
Doğrulama	40	10	40	10	40	10
Test	70	30	63	47	42	34
Toplam	350		360		326	

Gömülen malzemeler bakır, plastik, mükemmel iletken (PEC-Perfect Electric Conductor), beton, asfalt türlerinden herhangi birinden olabilmektedir. GprMax ile

veri oluşturmak eğer 3B (3 boyutlu) FDTD bir ortam kullanırsak uzun sürmektedir. Derin öğrenme için de çok sayıda veriye ihtiyacımız bulunduğundan 2B (2 boyutlu) bir ortamda çalışmalara devam edilmiştir. Z eksenini yönünde bir işlem adımı yani adım aralığı kadar bir boyut belirlenmiştir ve 2B benzetim yapılmıştır. Z eksenini boyunca toprağa gömülen cisimlerin tel, silindir ve küre olması 2B bir şekilde gözüktükleri yani Z ekseninde bir kesit alınacağı için benzetim sonuçlarında çok büyük bir farklılık oluşturmamaktadır. Verileri oluşturmak için kullanılan model Şekil 6'da gösterilmiştir.



Şekil 6. Verileri oluşturmak için kullanılan model

Şekilde gözüktüğü üzere gprMax ortamı, 0.5 x 0.6 x 0.002 metre boyutlarında bir alan kullanılarak modellenmiştir. Alıcı ve vericiden oluşan tek bir anten çifti anten tarama yönünde 4 cm aralıkla yerleştirilmiştir. Benzetimlerde radar sinyali olarak, merkez frekansı 1.5 GHz olan ricker dalga formunda bir sinyal kullanılmıştır. Nesneler, 50 x 50 x 0.2 cm'lik toprak alanda nesneler şeklinde d ile gösterilen farklı derinliklere yerleştirilmiştir. Yerleştirilen nesneler farklı yarıçaplarda (5-10-15 mm) tellerdir ve 2mm'lik eksen boyunca yerleştirilmiştir. Bu yarıçap şeklinde r ile gösterilmiştir. Bu veri kümesi önerilen sınıflandırma algoritmalarına girdi olmuştur. Eğitim ve doğrulama verileri ile farklı sınıflandırmalar yapılarak derin öğrenme modeli eğitilmiştir. Veri kümelerinin nasıl oluşturulduğu bölüm 4'te anlatılmıştır.

Oluşturulan veri kümesini gerçek sonuçlara yakın hale getirmek ve algoritmamızı gerçek koşullara uyumlu hale getirmek için gprMax çıktılarına belli oranlarda '0' ortalamalı '1' varyanslı bir gürültü eklenerek modelimize girdi olması adına veriler


oluşturulmuştur. Bu gürültü ekleme işlemi sonucu hedef sınıfında bulunan bir verinin gürültüsüz B ve A tarama görüntüleri sırasıyla Şekil 7 (a) ve (b)'de, gürültülü görüntüler ise Şekil 7 (c) ve (d)'de verilmiştir. Hedef dışı sınıfındaki bir verinin görüntüsü ise sırasıyla Şekil 7 (e), (f), (g), (h)'de verilmiştir.




(a) Hedef sınıfı B-tarama




(e) Hedef-dışı sınıfı B-tarama




(b) Hedef sınıfı A-tarama




(f) Hedef-dışı sınıfı A-tarama




(c) Hedef sınıfı gürültülü B-tarama



(g) Hedef-dışı sınıfı gürültülü B-tarama




(d) Hedef sınıfı gürültülü A-tarama




(h) Hedef-dışı sınıfı gürültülü A-tarama

Şekil 7. Modele girdi oluşturacak verilere gürültü ekleme işlemi

Eklenen gürültüler ile verilerin ayırt edilmesinin zorlaştığı görülmektedir. ESA modeline girdi olacak gürültülü YNR verilerinden bazı örnekler Şekil 8'de verilmiştir.



(a) Hedef




(b) Hedef Dışı


Şekil 8. Hedef tespiti veri kümesinden örnek resimler (ön işlem uygulanmış)

Son olarak hedef-dışı sınıfa ait olan bozuk yüzeyli bir cisim temsili olarak bir taş benzetimi yapılmıştır. Bu bozuk yüzeyli cismin Şekil 9'da model görüntüsü ve Şekil 10'da B-tarama görüntüsü verilmiştir. Bu üretilen verilerden sadece birisidir.

Rastgele yüzey bozuklukları oluşturularak bozuk yüzeyli cisim çeşitliliği sağlanmıştır. Oluşturulan cisimler toprak içinde farklı noktalara yerleştirilmiştir. Uygulanan ön işleme yöntemleri Bölüm 4.2’de anlatılmıştır.



Şekil 9. Islak toprağa gömülü 20cm derinlikteki yaklaşık 5x5cm boyutlarındaki bir taşın modellenmesi



(a) Ham veri

(b) Arkaplan çıkarılmış

(c) Beyazlatma işlemi uygulanmış

Şekil 10. Islak toprağa gömülü 20cm derinlikteki yaklaşık 5x5cm boyutlarındaki bir taşın gprmax B-tarama görüntüleri

1.1.2. İkinci Veri Kümesi

Tez çalışması kapsamında üretilen veri kümesine ek olarak Yılmaz [16]'nın çalışmasında kullandığı veri kümesi ile derin öğrenme ve aktarım öğrenmesi yöntemleri test edilmiştir. Kullanılan veri kümesi ve dağılımları Çizelge 3'te verilmiştir.

Çizelge 3. Hedef tespit görevi için Yılmaz'ın veri kümesi


	HEDEF	HEDEF-DIŞI
Gömülen Malzeme	Tel (PEC)	Taş veya Homojen olmayan toprak
Eğitim	125	125
Doğrulama	50	50
Test	50	50
Toplam	225	225

Bu veri kümesi 1 x 1 x 0.20 metre boyutlarında bir alan kullanılarak modellenmiştir. Alıcı ve verici antenler yüzeyden 3 cm yukarıda ve 2cm aralıklı olarak yerleştirilmiş ve 15 cm derinliğinde bir toprak alanı kullanılmıştır. Toprak, %50 kum ve %50 kilden oluşacak şekilde %1'den %25'e kadar değişen su yoğunluklarında modellenmiştir. Her farklı tarama görüntüsünde homojen olmayan toprak rastgele üretilmiştir. B-tarama görüntüleri, anten tarama yönünde 10 cm'den 90 cm'ye kadar 1 cm'lik adımlarla toplam 81 adet A-tarama görüntüsünden oluşmaktadır. Teller 1-14cm aralığına gömülmüş ve bu tellerin yanına farklı plastik nesneler ve taşlar gömülmüştür.

1.2. Tezin Amacı

Bu çalışmanın amacı, YNR benzetimini yapan gprMax isimli programla oluşturulan sentetik veri kümesi kullanılarak yeraltında gömülü olarak bulunan hedefi veya hedefleri önerilen bir derin öğrenme modeli kullanarak yüksek başarımla tespit etmektir. Bu amaç doğrultusunda, derin öğrenme algoritmasının ne öğrendiğini anlamak, algoritma sonuçlarından alınan geri beslemelerle algoritmayı geliştirmek ve oluşturulan derin öğrenme modelini aktarım ve çok görevli öğrenim yöntemleri ile geliştirerek gömülü olan hedefi tespit başarımını iyileştirebilmektir.

Tez kapsamında yapılan çalışmalar ve işlem adımları Şekil 11'de gösterilmiştir.



Şekil 11. Tez sürecinde yapılan işlem adımları

Şekilde amaca ulaşmak için yapılan işlemler sırasıyla gösterilmiştir. İlk olarak gprMax girdi dosyaları oluşturularak sentetik bir YNR veri kümesi oluşturulmuştur. Daha sonra bu veri kümesine ön işleme adımları uygulanarak ESA modeline uygun hale getirilmiştir. Veri kümesi, bir derin öğrenme modeli kullanılarak eğitilmiş ve hedef tespitinde bir başarım oranı elde edilmiştir. Öznitelik çıkarıcı olarak önceden eğitilmiş imagenet ESA modeli, mevcut modele entegre edilerek aktarım öğrenmesi uygulanmış ve bir hedef başarım oranı bulunmuştur. Son olarak toprak türü tespit görevinin, hedef tespitinin başarımina faydalı olacağı düşünüldüğü için çok görevli öğrenme yöntemi uygulanmış ve hedef tespit başarıımı bulunmuştur. 3 farklı işlem sonucu oluşan başarım oranları aralarında karşılaştırılarak, sonuçlar ve yöntemler yorumlanmıştır.

Bu tezin hedefi, gömülü hedef tespiti amacı doğrultusunda, farklı tip görüntüler üzerinde geliştirilmiş olan derin öğrenme yöntemlerin YNR verileri üzerine uygulanarak hedef tespit başarımının artırılmasıdır.

1.3. Tezin Akışı

Bölüm 2’de uzaktan algılama teknolojisi, temelleri, uygulama alanları ve özellikle gömülü nesne tespitinde kullanılan sistemler ile YNR sistemi analiz edilmiştir. Gömülü hedef tespitine yönelik kullanılan yöntemlerle ilgili çalışmalardan, YNR ile gömülü hedef tespitine yönelik emsal olabilecek geleneksel sınıflandırma

yöntemlerinden bazılarına yönelik alıřmalardan ve bu tez kapsamında gemiř derin ğrenme algoritmaları ile yapılan alıřmaların yöntemleri, avantajları, dezavantajları ve sonuçları araştırılmıştır. Bölüm 3'te, YNR verisi üzerinde uygulanacak olan derin ğrenme yapısının detaylarından, uygulamaya yönelik yöntemlerden ve gemiř derin ğrenme yöntemlerinden bahsedilmiştir. Bölüm 4'te, sentetik YNR verilerinin nasıl oluşturulduğu ve bu verilere uygulanan ön işleme yöntemleri hakkında bilgi verilmiştir. Son olarak bölüm 5'te ise yapılan alıřmalardan bahsedilerek derin ğrenme yönteminin gelişmeye açık yönleri anlatılmıştır. Tezden ıkarılan sonuçlar, bölüm 6'da verilmiştir.



2. LİTERATÜR ÖZETİ


Yere Nüfuz Eden Radar çok çeşitli alanlarda kullanılmaktadır. Yer altına gömülü cisimlerin tespiti için kullanılan YNR'nin başarımı, özellikle insan hayatını tehdit eden patlayıcı cisimlerin tespit edilememesi tehlikeli sonuçlar doğurduğundan, önem arz etmektedir. İnsan hayatı söz konusu olduğundan dolayı YNR ile ilgili akademik çalışmalar genelde kara mayınları tarafına yönelmiştir. Bir kez aktif edilen bir kara mayını üzerine basılmadığı ya da başka bir yolla patlatılmadığı sürece 50 yıl kadar aktif kalabilmektedir. Bu da bize uzun yıllar önce gömülen mayınların hala tehdit oluşturduğunu göstermektedir. Literatür taramasında sırasıyla uzaktan algılama sistemleri ve kullanılan sınıflandırma yöntemleri anlatılmıştır.

2.1. Uzaktan Algılama Teknolojisi

Uzaktan algılama teknolojisi, yeryüzü hakkında bilgi almak için yeryüzü ile fiziksel bir temasta bulunmadan atmosfere ya da uzaya yerleştirilen ölçüm aletleriyle yeryüzünde bulunan nesneler hakkında bilgi alma işlemi olarak tanımlanabilir. Gömülü cisimlerin tespitinde ise bu teknoloji yakın mesafe uzaktan algılama teknolojisi olarak tanımlanmaktadır. Hemen yeryüzü üzerinde ama fiziksel olarak temas etmeden çeşitli yöntemlerle bu veriler sağlanmaktadır. Bu verileri sağlamak için bu tez kapsamında da kullanılacak olan YNR sistemine ve gömülü nesne tespitinde kullanılan diğer yöntemlere sırasıyla değinilmiştir.

2.1.1. Yere Nüfuz Eden Radar (YNR)

Yere Nüfuz Eden Radar (YNR), özellikle son yıllarda oldukça gelişmiş bir cihazdır. Buna bağlı olarak da kullanım alanlarında artış meydana gelmiştir. YNR sistemi alıcı, verici antenler ve veri toplama biriminden oluşmaktadır. Bir YNR sisteminin en temel elemanları ve işleyiş şeması Şekil 12'de gösterilmiştir. Şekilde gözükten şemada verici antene belirli bir dalga şeklinde ve frekansta sinyal gönderilir. Gömülü cisimlere çapıp dönen sinyaller ise alıcı anten tarafından alınarak sırasıyla veriler depolanır, işlenir ve bir monitör yardımıyla görüntülenir.




Şekil 12. Yere nüfuz eden radar işleyiş şeması

Yere Nüfuz Eden Radar, radar sinyallerini kullanarak toprağa gömülü nesneleri tespit etmek için kullanılır. YNR sisteminin çalışma prensibi, elektromanyetik dalgaların girişme ve yansıma karakteristiklerine bağlıdır. Gömülü cisim ve toprak arasındaki dielektrik farklılıklarından yararlanarak bu cisme çarptığında iletilen sinyaller yansıtılır ve bu yansıyan sinyaller analiz edilerek gömülü cismin türü ve konumu tespit edilmeye çalışılır. YNR'den toprağa gömülü cisimlerin tespitinde sıkça faydalanılmaktadır. Özellikle askeri alanda gömülü mayınların tespitinde diğer yöntemlere göre üstün olduğu için kullanılmaktadır. Dielektrik farklılıklarından yararlanarak nesne tespit edebildiği için çeşitli hedefleri (plastik veya metal içermeyen) tespit edebilmektedir. YNR sisteminde kullanılan frekans değeri artırılarak yani dalga boyu küçültülerek daha kaliteli bir görüntü üretmesi sağlanabilir. Ancak yüksek frekanstaki bir dalga'nın toprağa girişim yapması zayıflar ve bunun sonucu olarak daha net görüntü isterken hiç görüntü alınamayabilir. Bu durumda girişim derinliği ve görüntü kalitesi arasında bir ters orantı bulunmaktadır. Toprağın daha derinliklerinde bulunan bir cismin tespiti için daha düşük frekans kullanmak gerekmektedir ve bu da görüntü kalitesini düşürecektir. Hangi derinliğe kadar tespit yapılmak istendiğine göre frekans ve görüntü kalitesi optimize edilmelidir [17]. Hedef tespitinin zor olduğu noktalar aşağıdaki gibidir [18]:

- Hedef yüzeye çok yakın gömülüysen,
- Hedef çok küçük bir boyuta sahipse,
- Gömülü cisim ile toprak arasındaki dielektrik farklılık çok küçükse tespit zorlaşmaktadır.

Şekil 13'te toprağa gömülü olarak bulunan bir hedef, gelen-yansıyan sinyaller ve hava-toprak ortamı gösterilmiştir.



Şekil 13. Gömülü bir cisim, ortam ve sinyallerin gösterimi

Şekilde de gözüktüğü gibi gelen sinyalin bir kısmı hava-toprak geçişinden dolayı geri yansımıştır. Benzer şekilde hedeften geri yansıyan sinyalinde bir kısmı hava-toprak geçişinden geçerken, diğer kısmı toprak ortamına doğru geri yansımıştır. Bu yansımalar hava-toprak arasındaki dielektrik farklılığından kaynaklanmaktadır.

YNR sisteminin diğer yeraltı sistemlere göre avantajları olarak büyük alanları tarama becerisi, araştırma verimliliğinin yüksekliği, maliyet avantajı ve hem metal hem metal olmayan nesneleri tespit edebilmesi gösterilebilir. YNR'nin diğer sistemlere göre dezavantajları ise heterojen topraklarda yanlış tespit oranının yükselmesi, derinliğin sinyal geçirgenliği ile limitli olması ve EM dalga yayan telefon mikrodalga gibi diğer cihazlardan etkilenmesidir [19], [20].

Örnek bir YNR sistemi ve bu sistemin özellikleri aşağıda verilmiştir [21].

MALA PROEX, MALA Geosience

- Anten merkez frekansı: 100-2300MHz farklı antenler
- Zaman ekranı: 75ns
- Örnekleme frekansı: 2-400Ghz
- Her taramada örnekleme sayısı: 128-2048

2.1.2. Gömülü Nesne Tespitinde Kullanılan Diğer Yöntemler

Gömülü cisimlerin tespiti özellikle cisimlerin metal içeriklerinin azalması sebebiyle önemli bir sorun haline gelmiştir. Gömülü cisimlerdeki bu değişim metal detektörünü kullanışsız hale getirmiştir. Özellikle askeri alanda mayın içeriklerine bağlı olarak tespiti zorlaştığı için ciddi anlamda insan yaşamını tehdit eder hale gelmiştir. Gömülü cisimlerin tespiti yapabilmek için çok çeşitli yöntemler bulunmaktadır. Gömülü cisimlerdeki bu değişikliklere dayalı olarak gömülü cisim tespitini araştıran birçok yenilikçi yöntem öne çıkmaktadır. Bu yöntemler, Yere Nüfuz Eden Radar (YNR), Elektriksel Empedans Tomografisi (EET), X-ışını geri yansıması ve kızılötesi sistemler, akustik / sismik sistemler ve nötron tabanlı sistemlerdir [17]. Bu çalışmada YNR kullanılması sebebiyle gömülü nesne tespitinde kullanılan diğer yaklaşımlar Elektriksel Empedans Tomografisi (EET), X-ışını Geri Yansıması ve Kızılötesi sistemler, Akustik / sismik sistemler ve Nötron yöntemi başlıkları altında ele alınmıştır.

2.1.2.1. Elektriksel Empedans Tomografisi (EET)

EET yaklaşımı, elektrik akımını kullanarak gömülü cisim ve bulunduğu ortamın iletkenliğine göre bir çıktı oluşturur. Yüzeye yerleştirilen 2-boyutlu elektrot dizisi yardımıyla yeraltından sinyalleri toplayarak gerekli çıktıyı oluşturur. Buradan alınan çıktı gerekli işlemlerden geçirildikten sonra yeraltının iletkenlik profilini verir. Bu sistemle metal içerikli olan veya olmayan cisimlerin iletkenlik farklılıklarından kaynaklı olarak varlığı ve konum bilgisi sağlanmış olmaktadır. Avantaj olarak ucuz ve basit olmasının yanı sıra ıslak zemindeki performansı gösterilebilir. Dezavantajı ise algılayıcıların yüzeye temas halinde olması nedeniyle bunun gömülü mayının patlama riskini arttırmasıdır [17], [22].

2.1.2.2. X-ışını Geri Yansıması

X-ışını geri yansıması, daha çok tıbbi alanda bilinmekle birlikte gömülü cisimlerin tespitinde de kullanılmıştır. X-ışını geri yansıması düşük yanlış alarm oranları ve yüksek algılama olasılığı avantajları sebebiyle tercih edilmektedir. Bu sistem görüntüyü fotonları gömülü cismin içinden geçirerek oluşturur. Sistemin avantajı olarak yüksek kaliteli görüntüler oluşturmaları gösterilebilir. Ama bu sistemin kullanımı sadece toprağın hemen altındaki yani yüzeye yakın gömülü nesneler için geçerlidir. X ışınları toprağa nüfuz etme konusunda zayıftırlar. Ayrıca bu sistemler hacimli ve

ağır sistemlerdir. Bu sebeple kişiye entegre edilerek kullanılamazlar. Eğer kişi taşımasına uygun hale getirilerek küçültülürse, bu sefer de görüntüyü oluşturmak çok zaman almaktadır [17], [22].

2.1.2.3. Kızılötesi Sistemler

Kızılötesi sistemler, elektromanyetik dalgaların yayılımına bağlı olarak çalışmaktadırlar. Sıcaklığa bağlı ve bağlı olmayan iki farklı tipi vardır. Sıcaklığa bağlı yaklaşımda gömülü mayın gibi nesnelerin çevresine göre daha sıcak oldukları görülmüştür. Sıcaklığa bağlı olmayan yaklaşım ise gömülü cismin ışığı çevresine göre farklı yansıtmasına bağlıdır. Diğer sistemlere göre yüzey bozuklularından etkilenmemesi ve yüzey teması olmaması sayesinde daha avantajlıdır. Ayrıca hafif ve küçük bir sistem olması sebebiyle hızlı bir şekilde geniş alan taraması yapılmasına imkân tanır. Ancak bu sistem gömülü olan ortamın karakteristiğine bağlı olarak iyi sonuç vermektedir. Yani sınırlı geçiş koşullarında faydalı olarak çalışmaktadır [17], [22].

2.1.2.4. Akustik / Sismik Sistemler

Bu sistemler toprağa doğru ses dalgaları göndererek gömülü olan cisimden geri yansıyan titreşimi kullanır. Farklı ortam ve materyaller ses dalgalarına maruz kaldıklarında farklı titreşimler yapmaktadırlar. Bu geri yansıyan titreşimleri yakalamak için farklı sensörler bulunmaktadır. Sensör çeşitlerinden bazıları lazer Doppler titreşim ölçerleri, radarlar, ultrasonik cihazlar, mikrofonlardır. Bu sensörlerin yüzeye temas etmesi gerekmemektedir. Bu sistem tamamen fiziksel etkilere göre hareket ettiği için elektromanyetik etkiler ile ayırt eden sistemlere göre hedef sınıfında olmayan taş, metal parçalar vb. gibi materyallerde yanlış alarm oranı çok düşüktür. Ayrıca hava koşullarından etkilenmemektedirler. Donmuş yeryüzü cisimlerin fiziksel etkilerini azaltacağı için bu sistemlerin etkisini de sınırlamaktadır. Titreşim tepkisinin toprak derinliklerinden yüzeye doğru yansımaları azaldığı için sadece yüzeyin hemen altına gömülmüş nesnelerde etkili olmaktadır. Dezavantajlarından biri de sistemin yavaşlığıdır. Bu titreşimleri algılayan sensörlerin ses dalgalarının yayılım hızı sebebiyle çok hızlı yer değiştirmemeleri gerekmektedir. Örneğin 1m² bir mayın alanın taranması 2 ile 15 dk. arası sürmektedir [17], [22].

2.1.2.5. Nötron Yöntemi

Nötron yönteminde toprak nötron yayarak taranır ve yansıyan nötronların yoğunluğu ve enerjisi arasında farklardan yararlanılarak gömülü cisim tespit edilmeye çalışılır. Bu teknoloji düşük güçlü sistemler kullanılarak taşınabilir sistemler yapılmasına izin vermektedir. Bu sayede kullanan operatörün az miktarda EM yayılımına maruz kalması sağlanabilir. Nötron yaklaşımının dezavantajı, suya duyarlılığı nedeniyle özellikle nemli toprak türlerinde yanlış alarm oranının yüksek olmasıdır. Ayrıca yüzey dalgalanmaları sebebiyle sensör yüksekliğinin değişmesi de sistemi olumsuz etkilemektedir [17].

2.1.2.6. Diğer Yöntemler


Literatür taraması sonucu gömülü cisim tespiti yapan iki yöntem örnek olarak verilmiştir. J. E. Piper vd. [23]'ün çalışmasında, sentetik açıklıklı radar ile 15-50cm aralığında gömülü cisim tespiti yapabildiğini anlatmaktadır. Başka bir sistem ile yapılan çalışma [24] ise "nükleer dörtlü kutup rezonansı"dır. Bu çalışmada sistemin gömülü nesnenin kimyasal içeriğine göre tespit yapabilmekte olduğunu anlatmaktadır.

2.2. Literatürde Kullanılan Sınıflandırma Yöntemleri

YNR sistemi kullanılarak çok çeşitli tespit algoritmaları sunulmuştur. Bu algoritmalar geleneksel sınıflandırma yöntemleri ve daha yeni olarak derin öğrenme tekniklerini kullanmaktadır. Gün geçtikçe başarımları yükselen yeni yaklaşımlar ortaya çıkmaktadır. YNR'nin gömülü hedef tespiti için faydalı bulan araştırmalardan biri Yarayov vd. [25]'in çalışmasıdır. Bu araştırma YNR sistemini dielektrik ve metal cisimlerin 50cm'e kadar olan gömülü olanları için kullanılabilir olduğunu göstermiştir. Miller vd. [26]'nın çalışmasında ise toprak durumundan ve su içeriğinden etkilenmesini araştırmıştır. Bu araştırmada toprak durumunun bilinmesinin hedef tespiti için faydalı olduğu anlatılmıştır. Mayınlar ve hedef dışı yansımalar arasında ayırım yapma gereği, bir takım yöntemlerle başarılabilir. Yanlış alarm oranını düşürmek için boyut, şekil, metal içeriği gibi özelliklerin kullanılabileceğini vurgulamaktadır [27]. Hedef ile hedef dışı yansıma arasındaki ayrımı sağlamak için araştırmalar devam etmektedir.

Bu bölümde YNR hedef tespit algoritmalarından bazıları sırasıyla anlatılmıştır. Geleneksel sınıflandırma yöntemlerinden sırasıyla Gizli Markov Modeli [12], K-En Yakın Komşu [13], Spektral Öznitelikler [10] yöntemleri anlatılmıştır.

GMM yönteminde [12], YNR ile hedef tespiti için bir algoritma önerilmiş ve bu algoritmanın uygulanması için yeryüzü farklılığı için 3 farklı araziden araca monteli YNR ile veri toplanmıştır. Bu yöntemde, öncelikli olarak gömülü hedef (mayın) imzalarını oluşturmak için toplanan veriler içerisinde mayınların olduğu bölgeler Şekil 14'teki gibi kesilerek imza kütüphanesi oluşturulması sağlanmıştır.



Şekil 14. İmza oluşturulması için kullanılan yöntem [12]

İmza kütüphanesine ek olarak yanlış alarmlar yani arkaplan ve hedef dışı yansılarda toplanmıştır. Şekil 14'te gözüktüğü gibi tek bir mayın, imza için farklı kesit alanlarından faydalandığından birçok imza üretmiştir. Oluşturulan bu veriler bir ön işleme sürecinden geçirildikten sonra eğitim modeline yani GMM'ye girdi olmuştur. GMM formu $\lambda = (A, B, \pi)$ 'dir. Bu formda bulunan parametreler (2), (3) ve (4) numaralı denklemler ile tanımlanmıştır. Bu parametreler (2) için durum geçiş olasılık dağılımını, (3) için gözlem sembolü olasılığını ve (4) için başlangıç durum olasılığını tanımlamaktadır.

$$A = \{a_{i,j}\}, a_{i,j} = P(q_{t+1} = S_j | q_t = S_i) \quad (2)$$

$$B = \{b_j(k)\}, b_j(k) = P(v_k ; t | q_t = S_i) \quad (3)$$


$$\pi = \{\pi_i\}, \pi_i = P(q_1 = S_i) \quad (4)$$

Bu modelin kullanışlı olması için bu 3 ana problem çözülmelidir [28]:

- Sınıflandırma problemi
- Uygun durum dizisi bulma problemi
- Model parametrelerini belirleme problemi.

Bu problemler için gerekli analiz ve çözümler yapılarak GMM modeli YNR verileri ile kullanılabilir hale getirilmektedir. Model parametrelerini tanımlamak için, parametre tahminine yinelemeli bir yaklaşım olan Baum-Welch algoritması [29] kullanılmıştır. Bir yeryüzü ortamından alınan veriler eğitim sınıfı olarak kullanılmış, model eğitilmiş ve oluşan model diğer iki yeryüzü ortamından alınan veriler ile test edilmiştir. GMM'nin mayın ve mayın değil olarak sınıflandırma yapabildiği görülmüştür.

K-NN yöntemini anlatan çalışmada [13], YNR verileri üzerinde öznelik çıkarımı için kenar histogram (EHD) tanımlayıcılarını kullanmakta ve sınıflandırma için K-NN algoritmasını uygulamaktadır. EHD, bir görüntüdeki piksel değişikliklerinin frekansını ve yönünü temsil eden bir tekniktir. Bir resim içinde tespit edilen kenarlar EHD tarafından dikey, yatay, 45° yükseliş, 45° düşüş ve izotropik olarak beş kategoriye ayrılmıştır. EHD, bu kenar karakterizasyonlarının her birinin diğerlerini bastırdığı beş histogram içerir. Bu histogramlardan örnekler içeren bir görüntü Şekil 15'te gösterilmiştir.



Şekil 15. EHD ile gömülü cisim imzaları

Şekil 15'te de gözüktüğü üzere gömülü düzgün yüzeyli bir cismin sahip olduğu hiperbolik şekil ve kenar öznitelikleri hedef tespiti için çok önemlidir. 3B bir görüntü alınıp bu görüntüden kesitler alınır ve ortaya çıkan sonuç üzerinde 4 farklı kategoride (yatay, dikey, 45 yükseliş, 45 düşüş) kenar sınıflandırması yapılır. Belirli bir yöndeki kenar piksel yoğunluğu, belirlenen bir eşiği aşarsa, ilgili piksel o yönde bir kenar pikseli olarak tanımlanır. Aksi takdirde, izotropik bir piksel olarak kabul edilir. Özetle bir K-NN yöntemi EHD öznitelik çıkarıcı ile aşağıdaki işlemleri sırayla uygulayarak hedef ayrımı yapmaktadır:

1. B-Tarama bir YNR görüntüsünde kenar yoğunlukları hesaplanır.
2. Görüntülerdeki kenar formları belirlenir.
3. KNN öznitelikleri bulunur.
4. Sınıflandırma değeri hesaplanır. Bu değer (5) ve (6) nolu denklemdeki gibi hesaplanır.

$$\text{Conf}(S_T) = \left(p \frac{\sum_{k=1}^K u^M(S_T^k) \times \frac{1}{\text{dist}(S_T, S_T^k)}}{\sum_{k=1}^K 1/\text{dist}(S_T, S_T^k)} \right)^{1/2} \quad (5)$$

$$u^M(R_i) = \frac{1/\text{dist}(R_i, R_i^M)}{1/\text{dist}(R_i, R_i^M) + 1/\text{dist}(R_i, R_i^C)} \quad (6)$$

Denklemler de bulunan bilinmeyenlerden R_i^M seçilen örnek R_i noktasına en yakın gömülü hedefi gösterirken R_i^C noktası ise en yakın hedef dışı yansımayı göstermektedir. Dist komutu ile bunlar arasındaki mesafe ölçülmektedir. Test verisi S_T ile gösterilmekte ve K prototip verisi ile bu veri arasındaki mesafeler $S_T^1 \dots S_T^K$ ile gösterilmektedir. Ön görüntüleme sınıflandırma değeri ise p ile temsil edilmektedir. Bu yöntemle hedef tespitini başarıyla yapabildiği görülmüştür.

Spektral Öznitelikler [10] yöntemi, diğer yöntemlerden farklı olarak hedef karakteristiklerine frekans ekseninde bakarak sınıflandırma yapar. Spektral özellik, ön tarayıcı tarafından bildirilen bir alarmin enerji yoğunluk spektrumundan (EYS)

elde edilir. EYS'nin tahmininde dört adım vardır: önişleme, doğrusal olmayan yumuşatma, beyazlatma ve ortalama. Önişleme adımında veriyi daha iyi görüntülemek için yer yansımalarını kaldırma işlemi yapılır. Beyazlatma aşaması, arka plan spektrumunda eşitleme yapar ve böylece tahmini EYS bir alarmin gerçek spektral özelliklerini yansıtır. Arka planın ortalama ve standart sapması her bir kesit alanı için tahmin edilir ve her bir frekans endeksi için ortalama ve standart sapma hesaplanır. Spektral beyazlatma işlemi (7) nolu denklem ile yapılmaktadır.

$$\tilde{D}(x, y, k_z) = \left(\frac{D(x, y, k_z) - m(x, k_z)}{\sigma(x, k_z)} \right) \quad (7)$$

Denklem (7)'da bulunan değişkenlerin açıklamaları aşağıdaki gibidir:

- $D(x, y, k_z)$ verinin (x, y) konumundaki derinlik boyunca Fourier dönüşümünü,
- k_z frekans indeksini,
- $m(x, k_z)$; $D(x, y, k_z)$ değerinin ortalamasını,
- $\sigma(x, k_z)$; $D(x, y, k_z)$ değerinin standart sapmasını,
- $\tilde{D}(x, y, k_z)$ ise normalize edilmiş $D(x, y, k_z)$ değerini vermektedir.


Bu işlemler sonrasında, ortalaması çıkarıldıktan sonra değeri etkin değerinden (RMS-Root Mean Square) küçük değerleri 0'a çekerek boyut keskinlik işlemi uygulanır.

Şekil 16'da da gözüktüğü üzere iki farklı gömülü cismin spektral tepe noktaları 1,2 ile 2 GHz arasında oluşmuştur. 6 GHz ile gösterilen eksen 10 alt banda bölünerek 600Mhz'lik bantlar oluşturulur. Bu değerler her alt bandın altında kalan EYS değerlerinin toplamı alınarak Q değişkeni ile gösterilir. Q, bu değerleri içeren 10 sütundan oluşan bir vektördür. Bu çalışmada spektral öznitelikler kullanılarak yapılan sınıflandırma işlemi denklem (8) ile gösterilmiştir. Bu değer elde edilen spektral öznitelikler ile ön görüntüleyici değerlerinin (p) birleştirilmiş halidir.

$$\text{Conf} = (\log(W^T Q + 1) + k)(p - p_{\min}) \quad (8)$$

Denklem (8)'de log() işlemi spektral sınıflandırma işleminin dinamik aralığını azaltır. Spektral sınıflandırma değeri düşükken k=1,5 seçilerek ön-görüntüleyici değerinin

daha baskın olması sağlanır. p_{min} olarak gösterilen ön-görüntüleyici sınıflandırma eşik değeri, ön-görüntüleyici sınıflandırma değerinden çıkarılarak '0' tabanlı bir ön-görüntüleyici sınıflandırma değeri oluşturulur.



Şekil 16. İki farklı düşük oranda metal içeren gömülü cisim EYS'si [10]

Buraya kadar anlatılanlar YNR verileri üzerinde uygulanan geleneksel sınıflandırma yöntemleridir. Derin öğrenme algoritmalarının literatürdeki başarısından dolayı YNR verileri ile bu alandaki çalışma az olmakla birlikte gömülü hedef tespitini derin öğrenme algoritmaları kullanarak uygulayan çalışmalardan bahsedilmiştir. Derin öğrenme yöntemlerinin gelecek vaat eden gelişmeleri üzerine bu bölümde tezin amacı doğrultusunda farklı çalışmalar anlatılmıştır.

Geleneksel makine öğrenmesinde, genelde lineer sınıflandırıcı kullanılmaktadır. Hesaplanan ağırlıklı öznitelik eleman toplamları belli bir eşik değeri üzerinde kalırsa ilgili sınıfa atanacak şekilde sınıflandırılmaktadır. Derin öğrenme ise sahip olduğu çok katmanlı sinir ağı yapısı sayesinde bir öznitelik çıkarımına gerek duymadan kendi kendine sınıflandırıcıyı öğrenebilmektedir. Öznitelik çıkarımının zor olduğu problemlerin çözümünde, günümüzde kullanılan daha yüksek işlem yeteneğine sahip bir makine öğrenmesi tekniğidir. Derin öğrenme yöntemlerini ele alan bahsedilecek ilk araştırma [30], gömülü cisimlerin tespiti için YNR B-tarama gömülü boru görüntülerinin analizine dayanan bir çalışmadır. Önerilen yaklaşım, ESA'ların

kullanımına dayanmakta ve tamamen otomatik olmaktadır. Bu yaklaşımda, sadece sentetik yani gprMax programı ile eğitilen bir model ile gerçek veriler test edilirse başarımlar oranı %83 çıkmaktadır. Eğer gerçek yeryüzü ortamından toplanan veriler eğitim seti içine küçük miktarlarda yani 1 adetten 5 adede kadar eklendiğinde başarımlar oranının %95 seviyelerine kadar çıktığı gözlemlenmiştir. Gerçek YNR verileri ile yapılan doğrulama, sistemin doğruluk oranının %95 olduğunu ve görüntü ön işleme gerekliliğini ortaya koymaktadır. Bu çalışmadaki deneysel sonuçlar, ESA'nın prensip olarak tamamen sentetik verilerden başlayarak eğitilebileceği fikrini doğrulamıştır. Yine bu çalışmada derin öğrenmenin vurgulanan diğer bir avantajı ise bir görev eğitimi için gerçek verilere ihtiyacımız olmamasıdır. Çünkü bu çalışmada, gprMax programı üretilen veriler üzerinde eğitim sağlanmış olup, bu modelin doğrulaması gerçek YNR görüntüleri üzerinde yapılmıştır.

Derin öğrenme yöntemi üzerinde yapılan bir başka çalışma [31] ise ön işleme sürecinin etkisini ve model başarımlar oranlarını ele almıştır. YNR verileri genellikle gömülü hedefin haricinde hedef dışı yansımalar ve gürültüler içermektedir. Hedef dışı yansımalar, karmaşıklık yaratan istenmeyen herhangi bir yansımayı temsil etmektedir. Radar sinyali, dolayısıyla YNR verilerini yorumlamak daha zor hale gelmektedir. Gürültünün ağırlıklı olarak diğer radyo dalgası yayıcı cihazlar (cep telefonları, radyo vb.) yüzünden veri toplama sırasında oluştuğunu söylemektedir. Ham görüntüdeki bilgiler doğru bir şekilde kullanılabilmek için istenmeyen sinyalleri ve yer yansımalarını kaldırmak için ön işleme gerekmektedir. Bu anlatılan çalışmanın iki temel amacı bulunmaktadır. Bu amaçlar, önerilen algoritmalar ile gömülü nesnenin varlığını ve yerini doğru olarak tespit edebilmektir. Sunulan görüntü işleme teknikleri ile bu temel amaçlar daha etkili hale getirilmeye çalışılmıştır. Bu makalede görüntü ön işleme adımları aşağıdaki gibidir.

1. Hedef Dışı Yansıma Kaldırma: Bu işlem denklem (9) ile ortalama kaldırma işlemi uygulanarak yapılmaktadır. Bu işlem kernel pencere tanımlama yöntemi ile her bölge için ayrı ayrı yapılmaktadır.

$$g(x, y) = f(x, y) - \frac{1}{M} \sum_{j=-m/2}^{i=m/2} f(x + i, y) \quad (9)$$

Denkleimde gösterilen M tüm verideki pixel sayısını m ise alınan penceredeki pixel sayısını göstermektedir.

2. Gürültü Azaltma: Görüntüyü daha kaliteli hale getirmek ve gürültü azaltmak için kullanılmaktadır. Amacı ham veriden arka planı çıkarmaktır. Giriş verisini yumuşatmak için Gaussian filtre kullanılmıştır. Bu filtre denklem (10) ile gösterilmiştir.

$$g(x,y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \quad (10)$$


3. Yer Yansıması Kaldırma: Bu işlem adımı hedef dışı yansıma kaldırma yöntemi ile uygulanmıştır.

Bu çalışma, iki katmandan oluşan bir ileri besleme yapısında 1200 giriş bağlantısı ve bir çıkış bağlantısı olan bir sinir ağı yapısı önermiş ve başarılı sonuçlar göstermiştir.

Derin öğrenmeye geçildiğinde ESA literatüründe son zamanlarda yapılan bir bulgu ise ağın erken safhalarında öğrendiği filtrelerin genellikle çok genel (ör. kenarlar veya renkler) olmasıdır. Simonyan vd. [32]'nin çalışmasında bulunan bir ağın filtreleri, farklı bir görevdeki bir ağın eğitim başlatılması için kullanılmış ve performansın yükselmesine fayda sağladığı gözlenmiştir. Ayrıca yine bu çalışma kapsamında, veri kümesinin boyutu artırılmış ve verilerin farklı kombinasyonlarıyla birlikte veri kümesini genişletilmiştir. Örneğin, doğal görüntülerde, nesneler döndürülmüş veya farklı aydınlık ölçeklerinde görünebilmektedir. Bu nedenle, veri kümesine döndürülmüş ve ölçeklendirilmiş yamalar ekleme yönteminin, sınıflandırma performansını artırdığını göstermiştir.

Çok görevli öğrenme üzerine YNR verilerinde bir çalışma ortaya çıkmamış olmakla birlikte, farklı yöntemlerle farklı alanlarda çalışmalar yapılmıştır. Derin öğrenme modelleri üzerinde şimdiye kadar uygulanmış olan yöntemlerden bazıları sırasıyla anlatılmıştır. Long vd. [33]'ün çalışmasında, evrimsel katmanların birleşik olarak paylaşılmasını ve sadece tamamen bağlı katmanların göreve özel olarak atanmasını önermektedir. Bu yöntem, derin ilişkili ağ olarak isimlendirilmektedir. Bu sayede model başarımında iyileşme sağlandığı görülmüştür.


Birleşik parametre paylaşım yöntemlerinden bir başkası ise tam uyumlu öznelik paylaşımıdır. Bu yöntem farklı katmanlarda benzer görevler arasında ortaklama yapmayı önermekte ve dinamik olarak sırayla daha genel katmanlara giderken benzer görevler arası ortak katmanlar oluşturmaktadır. Benzerlik oranları düşük olan görevler arasında karmaşık parametre paylaşımlarına sebep olup başarımı düşürmesini engellemektedir. Farklı görevler için tek bir ilk katman bulunmaktadır. Birbiriyle ilişkili olan görevlere göre ikinci katmanda ayırım başlamaktadır. Daha özel özneliklerin öğrenildiği son katmanlara doğru bütün görevler ayrılmaktadır. Bu çalışmanın bir yapısı Şekil 17’de gösterilmiştir. Her katmanda farklı görev kümeleri arasında parametre paylaşımı yaptığı için bu yapıya dinamik çok görevli paylaşım denilmektedir [34].



Şekil 17. Tam uyumlu öznelik paylaşım yapısı

Son olarak bu tez kapsamında da üretilen veri kümesi üzerine bir benzerini uygulanan ve uygularken referans olarak kullanılan çapraz dikiş yöntemi anlatılmıştır. Misra vd. [35]’in çalışmasında, mevcut çok görevli öğrenme mimarilerinin birden fazla görevin olduğu modeli ortak olarak eğittiği ve genelleme yapmadığını söylemektedir. Çapraz dikiş yöntemi yaklaşımı, görevlerin ne olduğundan bağımsız, iki farklı eğitilmiş modelin en uygun kombinasyonunu vermektedir. Böylece görevlerin tek olarak mı daha iyi eğitildiği ya da paylaşımlı olarak mı daha iyi eğitildiğinden bağımsız olarak en iyi sonucu vermektedir. Bu yöntem iki ayrı görev modeli kullanılarak ve ayrık parametre paylaşımı yapılarak uygulanmaktadır. İki farklı görev parametreleri belli lineer katsayılarla birbirleri ile

toplanarak ara bir katman oluşturulmaktadır. Önerilen yöntem mimarisi Şekil 18’de gösterilmiştir [35].



E: Evrişim katmanı, T: Toparlama katmanı, TB: Tamamen bağlı katmanı

Şekil 18. Çapraz dikiş yöntemi mimarisi [35]

Şekle göre aynı görüntü iki farklı görev modeline girdi oluşturmıştır. Giriş verisi, birinci evrişim ve toparlama katmanlarından geçtikten sonra oluşan çıktılar α katsayılarının bulunduğu bir çapraz dikiş birimi ile lineer bir işleme girerek iki görevden veriler ortaklanmıştır. Ortaklanan bu çıktı, ikinci evrişim katmanının girişi olmuştur. Tüm toparlama ve tamamen bağlı katmanlarına çapraz dikiş birimi eklenmiş ve anlatılan işlem son katmana kadar yapılmıştır. Yapılan bu yöntem ile sınıflandırma başarımında artış gözlenmiştir. Tez çalışmasında kapsamında bu görevler, hedef ve toprak türü tespiti olarak düşünülmüştür. Çapraz dikiş yöntemi, başarımın tek görevli modelde elde edilen başarımın altına inmediği birçok görevli model mimarisi olduğu için tercih edilmiştir. Görevler ayrık olarak eğitilmiş ve sonrasında eğitilmiş olan modellerin öğrendikleri ortaklanmıştır. Bu ortaklamadan daha iyi bir sonuç elde edilemediğinde, yöntem tek görevli eğitimin daha başarılı olduğuna karar vermiştir.

3. DERİN ÖĞRENME: EVRİŞİMSEL SİNİR AĞI


Derin öğrenme algoritmaları özellikle son yıllarda oldukça popüler hale gelmiştir. Şimdiye kadar geleneksel yani öznitelik çıkarımlı sınıflandırma algoritmalarının kullanıldığı her alanda derin öğrenmenin avantajlarından faydalanmak için çalışmalar devam etmektedir. Bu avantajlara geleneksel sınıflandırma algoritmalarına göre bakmak daha uygundur. Geleneksel sınıflandırma yöntemleri, YNR verilerinden öncelikli olarak öznitelik çıkarmaktadır [36]. Fakat öznitelik çıkarımı alan bilgisi gerektirmekte ve vakit almaktadır [37]. Derin öğrenme öznitelik çıkarımı gerektirmediğinden bu sorunu çözmektedir. Bu avantajının yanı sıra yapısı gereği çok yoğun parametre ve veri içermekte bu yüzden fazla işlem gücü gerektirmektedir. Günümüzde gelişen bilgisayar teknolojisi sayesinde işlem gücü artmış, işlem gücü gerektiren uygulamalar daha kısa sürede yapılmaya başlanmıştır. Bu gelişme derin öğrenme algoritmaları kullanılmasının önündeki engeli kaldırmıştır. Derin öğrenmenin özel bir mimarisi olan Evrişimsel Sinir Ağları (ESA), 1958 yılında algılayıcı algoritması ile başlayan bir geçmişe dayanmaktadır [38]. Bir ESA'nın nasıl çalıştığını daha iyi anlayabilmek adına algılayıcı algoritması incelenmelidir. Bölüm 3.1'de algılayıcı anlatılmıştır.

3.1. Algılayıcı

Rosenblatt, insanların öğrenme yeteneğini taklit ederek bir algılayıcı tasarlamıştır. Bu çalışmada bir nöron modellenmiş olup, girdi matrisi ile çarpılacak olan bir ağırlık matrisi ve sonuca eklenecek olan bir sapma değeri tanımlanmıştır. Algılayıcı algoritması lineer bir sınıflandırıcıdır. Algılayıcı denklemi (11)'te verilmiştir. Algılayıcı yapısı Şekil 19'da verilmiştir.

$$f = \sum_i w_i x_i + b \quad (11)$$


(11) numaralı denklem ve Şekil 19'da gösterilen x , girdi matrisini; w , ağırlık matrisini; b , sapma değerini; f , sınıflandırma sonucu çıktısı ve i ise kaç tane girdi olduğunu göstermektedir.



Şekil 19. Algılayıcı yapısı

3.2. Sinir Ağları


Tek algılayıcı sisteminin zorlu problemlerin çözümünde yeterli olmaması anlaşıldığında, sinir ağları adı verilen çoklu algılayıcı sistemler, diğer adıyla çok-katmanlı algılayıcılar tasarlanmıştır. Sinir ağları katmanlar vasıtasıyla düzenlenmektedir. Girdi, çıktı katmanları ve ayrıca gizli katmanlar ile sinir ağının boyutu artmakta ve karmaşıklaşmaktadır [39]. Çok katmanlı bir sinir ağı yapısı Şekil 20’de gösterilmiştir. Gizli katmanlar ilerleyen bölümlerde anlatılmıştır.



Şekil 20. Çok katmanlı bir sinir ağı yapısı

3.3. Evrişimsel Sinir Ağları

Evrişimsel sinir ağları özelleştirilmiş bir derin öğrenme modelidir. Sinir ağları girdi olarak verilen görüntüde oluşacak olan bozulma ve kaymalarla başa çıkamamaktadır. Bu sorunla başa çıkmak için LeCun tarafından ESA geliştirilmiştir. ESA'lar içerdikleri evrişimsel katman sayesinde bölgesel olarak öznitelikleri öğrenmekte bu sayede girdide oluşacak olan bozulmalardan etkilenmemektedir [40]. Şekil 21'de bir YNR verisinin giriş yaptığı ESA yapısı ve temel katmanları gösterilmiştir.



E: Evrişim katmanı, T: Toparlama katmanı, TB: Tamamen bağlı katmanı
SM: Softmax katmanı

Şekil 21. Örnek bir evrişimsel sinir ağı yapısı

Şekilde de gösterilen ESA yapısı, temel olarak evrişimsel, aktivasyon, toparlama ve tamamen bağlı katmanlarından oluşmaktadır. Bu katmanlardan evrişimsel ve tamamen bağlı katmanlarında öğrenilebilen parametreleri mevcuttur. Bu parametreler, algılayıcı yapısında olduğu gibi ağırlık parametresi olarak isimlendirilmektedir. Farklı özniteliklerin öğrenimi için bir ESA birkaç evrişimsel katmandan oluşmalıdır. İlk katman köşe algılama, renk ayrımı gibi daha genel öznitelikler öğrenirken sonraki katmanlar o probleme özel öznitelikler öğrenmektedir. ESA temel katmanları sırasıyla anlatılmıştır.

3.3.1. Evrişimsel Katman

Bu katmanda ağırlık ve sapma matrisi olarak adlandırdığımız öğrenilebilir parametreler mevcuttur. Girdi sağlayan veri, evrişimsel katmandan geçirilerek bu katmanın çıkış verisini üretmektedir. Bu katmanın boyutları (12)'de temsili olarak f ile gösterilmiştir. İşlemler sonucu oluşan çıktı y ile gösterilmiş olup, bu sonucun matematiksel ifadesi (13)'de verilmiştir [41].

$$x \in \mathbb{R}^{H \times W \times D}, f \in \mathbb{R}^{H' \times W' \times D \times D'}, y \in \mathbb{R}^{H'' \times W'' \times D''} \quad (12)$$

$$y_{i''j''d''} = b_{d''} + \sum_{i'=1}^{H'} \sum_{j'=1}^{W'} \sum_{d'=1}^D f_{i'j'd'} \times x_{i''+i'-1, j''+j'-1, d'+d''} \quad (13)$$

Bu denklemlerdeki ifadelerden x giriş verisini, f çok katmanlı ağırlık matrislerinin birleşimini, b sapma miktarını ifade eder. H, W, D ifadeleri ise sırasıyla satır, sütun, derinlik boyutlarına karşılık gelir. Değişkenler üzerinde bulunan ' ' ve '' ifadeleri sırasıyla o değişkenin f ya da y boyutlarında olduğunu göstermektedir.

Evrişim 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 (13)'de verilen denklemin düzenlenmiş hali (14)'de verilmiştir [41].

$$y_{i''j''d''} = b_{d''} + \sum_{i'=1}^{H'} \sum_{j'=1}^{W'} \sum_{d'=1}^D f_{i'j'd'} \times x_{S_h(i''-1)+i'-P_h^-, S_w(j''-1)+j'-P_w^-, d'+d''} \quad (14)$$

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.

3.3.2. Aktivasyon Katmanı

Sinir ağlarında kullanılan çeşitli aktivasyon katmanları bulunmaktadır. En bilinenleri Sigmoid, Tanh, ReLU (Rectification linear units – Doğrultulmuş lineer birim), Softmax katmanlarıdır. Bu tez kapsamında da kullanılan ve ReLU ve Softmax katmanları sırasıyla anlatılmıştır. ReLU katmanı, evrişimsel katmandan sonra uygulanmakta ve belli bir değerle mevcut değerler arasında karşılaştırma yaparak büyük olan değerleri seçmektedir. Bu belirlenen değer altındaki tüm veriler o değere çekilmektedir. Genelde bu eşik değeri "0" olarak belirlenmektedir. Bu katmanın işleyişi (15) numaralı denklem ile gösterilmiştir [41].

$$y = \max(0, x_{ijd}) \quad (15)$$

(15) numaralı denklemde bulunan i, j ve d ifadeleri 3 boyutlu bir matristeki konumunu göstermektedir.

Softmax katmanı ise sinir ağlarında sınıflandırma katmanı olarak kullanılmakta ve son katman olarak yer almaktadır. Son katmanda bulunan sınıfları olasılıksal olarak düzenlemek için kullanılmaktadır. Sınıflandırma için bulunan değerleri toplamı '1' olacak şekilde yeniden yapılandırmaktadır. Bu sayede hangi sınıfa yüzde kaç ihtimalle karar verildiği belirlenmektedir. Softmax katmanı (16) numaralı denklem ile gösterilmiştir.

$$y = \frac{e^{x_i}}{\sum_{j=0}^k e^{x_j}}; i = 0, 1, 2, \dots k \quad (16)$$

(16) numaralı denklemde k ifadesi sınıflandırma sonucu son katmandaki sınıf sayısını, i ifadesi hangi sınıf değeri için işlem yapıldığı ve y ifadesi seçilen x_i için sınıf olasılığını vermektedir.

3.3.3. Toparlama Katmanı

Matris boyutunu küçültmek için uygulanan bu katman çözünürlük düşürerek parametre sayısını azaltır ve aşırı öğrenme ihtimalini düşürür. Her iki evrimsel katman arasına konulmakta olup, aşamalı olarak parametre sayısını düşürerek işlem yükünü hafifletmektedir. ESA'larda maksimum ve ortalama toplama katmanları görülmektedir. Sıklıkla kullanılan maksimum toplama katmanı denklem (17)'de gösterilmiştir [41].


$$y_{i''j''d} = \max_{1 \leq i' \leq H', 1 \leq j' \leq W'} x_{i''+i'-1, j''+j'-1, d} \quad (17)$$

Denklemde gösterilen maksimum toplama işlemi, ilgili matrisin $H' \times W'$ boyutlarında alınan parçası üzerinden matris içinde kalan elemanların en büyüğünü seçer.

Ortalama toparlama katmanı denklem (18)'de verilmiştir. Bu denklemde ise alınan parça içinde kalan elemanların ortalaması alınmaktadır.

$$y_{i''j''d} = \frac{1}{W'H'} \sum_{1 \leq i' \leq H', 1 \leq j' \leq W'} x_{i''+i'-1, j''+j'-1, d} \quad (18)$$

Şekil 22'de bir toparlama katmanının işleyişi gösterilmiştir. Bu gösterimde maksimum toparlama katmanı uygulanmış olup $H' \times W'$ boyutları 2×2 belirlenmiş ve kaydırma miktarı (S_h) 2 olarak seçilmiştir.



Şekil 22. Toparlama katmanı işleyişi

Evrışimsel ve toparlama İşlemleri sonucu oluşan çıkış matrisinin boyutlarını hesaplamak için (19) kullanılabilir.

$$H'' = 1 + \left\lfloor \frac{H - H' + P_h^- + P_h^+}{S_h} \right\rfloor \quad (19)$$

Bu işlemi bir örnekle açıklamak gerekirse kullanmış olduğumuz veriler ve ilgili katmanlar göz önüne alınarak, 227×227 boyutlu bir YNR verisi 11×11 boyutlu 12 derinliğinde 4 kaydırmaya sahip bir katmandan geçirildiğinde denklem (19)'deki hesap ile (20) numaralı denklemdeki sonuç elde edilmektedir.

$$H'' = 1 + \frac{227 - 11 + 0 + 0}{4} = 55 \quad (20)$$

Bu işlemde de gözüktüğü üzere YNR giriş verisinin bir evrışimsel katmandan geçmesi sonucu 55x55x12 boyutlu bir çıktı oluşmaktadır.

3.3.4. Tamamen Bağlı

Bu katmana girdi olarak verilecek olan matris ile ağırlık matris boyutları tam olarak örtüşmektedir ve bu katman uygulandıktan sonra çıkış matrisinin satır ve sütun sayısı 1'e eşit olmaktadır. Bu katmana tamamen bağlı katman denilmektedir. Bu katman, ESA'nın son katmanı olabileceği gibi daha önceki katmanlarda olabilmektedir [42], [43].

3.4. Aktarım Öğrenmesi

Derin öğrenmede çok büyük veri kümeleri ile sıfırdan bir sınıflandırıcı eğitmek çok yüksek işlem gücü gerektirmektedir. Bunun yerine büyük bir veri kümesi ile önceden eğitilmiş olan bir derin öğrenme sınıflandırıcısının öznitelik çıkarıcı ve bazı sınıflandırıcı katmanları kullanılarak ilgili ağırlık verileri veya katmanlarda ayarlama yapılarak yeni veri kümemize uygun hale getirme işlemine "Aktarım Öğrenmesi" denmektedir. Aktarım öğrenmesi senaryolarından temel olan "Sabit Öznitelik Çıkarıcı" ve "Hassas Ayar" yöntemi sırasıyla anlatılmıştır [42], [44].

Sabit öznitelik çıkarıcı yöntemi, daha önce eğitilmiş olan bir evrışimsel sinir ağının son tamamen bağlı katmanı yani sınıflandırıcı katmanı çıkarılarak diğer tüm katmanlar olduğu gibi alınması işlemidir. Sadece son katman yeni veri kümesine göre eğitilir.

Aktarım öğrenmesi senaryolarının 2.si olarak hassas ayar yöntemi ele alınmıştır. Sabit öznitelik çıkarıcı yöntemden farklı olarak tamamen bağlı katmanından önceki katmanlarda da ağırlık verileri eğitilmektedir. Bu ağırlık verileri, geri yayılım yöntemi ile hatayı azaltarak mevcut veri kümesine uygun hale getirilmeye çalışılmaktadır. Tüm katmanlardaki ağırlık verilerinde düzeltme yapılabileceği gibi ilk katmanlardaki parametreler sabit tutulabilir. Bunun nedeni ilk katmanlarda öğrenilen öznitelik çıkarımının çok genel (ör. köşe algılama, renk ayırt etme vs.) olmasıdır. Sonraki katmanlar ise daha özel öznitelikleri öğrenmektedir. Bu sebeple son seviyelerdeki katmanlarda hassas ayar yapmak tercih edilmektedir.

Aktarım öğrenmesi için bu ana yöntemlerden hangisinin nasıl seçileceğine karar vermek gerekmektedir. Bunun için birçok etken olmasına rağmen bu etkenlerden önemli olan ikisi, yani yeni veri kümesinin boyutu ve eğitim için kullanılmış olan veri kümesine benzerliği incelenmiştir. Bu iki farklı etken için 4 farklı ihtimal bulunmaktadır. Bu ihtimaller ve açıklamaları aşağıda verilmiştir [42].

- **Küçük yeni veri kümesi ve asıl olana benzer:** Veri kümesindeki örneklerin azlığı sebebiyle aşırı öğrenmenin önüne geçmek için hassas ayar işleminden kaçınılmalıdır. Benzer olması sayesinde yüksek seviye öznelilikler asıl olana benzeyecektir. Bu nedenle doğrusal sınıflandırma uygun gözükmemektedir.
- **Büyük yeni veri kümesi ve asıl olana benzer:** Veri kümemizin büyük olması sebebiyle aşırı öğrenme sorunu endişesine kapılmadan hassas ayar işlemi uygulanabilir.
- **Küçük yeni veri kümesi ve asıl olandan farklı:** Veri kümesi küçüklüğünden dolayı doğrusal sınıflandırma uygun gözükmemekte ancak asıl olandan farklı olması sebebiyle SVM sınıflandırıcı daha iyi sonuç verebilir.
- **Büyük yeni veri kümesi ve asıl olandan farklı:** Zaten elimizde yeterli miktarda veri olduğu düşünüldüğünde ve farklı olmasından kaynaklı olarak mevcut altyapı yeterince iyi sonuç vermeyeceğinden tüm sinir ağına hassas ayar yöntemi uygulanabilir.

Maddelerde söz edilen “asıl olan” ifadesi ile önceden eğitilmiş olan modelin veri kümesi tanımlanmaktadır. Aktarım yapılacak veri kümesi ile önceden eğitilmiş olan modelin veri kümesi benzer olduğunda “asıl olana benzer”; farklı olduğunda ise “asıl olandan farklı” ifadesi kullanılmıştır.

3.5. Çok Görevli Öğrenme


Çok görevli öğrenme, birden fazla görev modelinin aynı anda eğitildiği bir sınıflandırma yöntemidir. Bu yöntem ile sınıflandırma başarımının, görevlerin ayrık olarak eğitilmesine göre arttığı görülmüştür [45], [46]. Çok görevli öğrenmenin temel amacı ilişkili görevlerde alana özel bilgileri kullanarak ortaklama başarımını arttırmaktır [46]. Çok görevli öğrenme, makine öğrenmesinin farklı uygulama alanlarında başarıyla kullanılmaktadır. Doğal dil işleme [47], konuşma tanıma [48] bilgisayarla görü [49] bunlardan bazılarıdır. Bu öğrenme yöntemi kaynaklarda farklı

isimlerle de bulunmakta; katılımlı öğrenme ve yardımcı görev ile öğrenme, çok görevli öğrenmenin farklı deyişleridir. Çok görevli öğrenme, ilişkili iki farklı görevin öğrendiği parametreler birbirleriyle belirli şekillerde paylaşılarak başarımlarını yükseltmeyi amaçlamaktadır. Mevcut temel görev modelimizin başarımlarını geliştirmesi için ek olarak yazılacak bir kayıp fonksiyonu ile farklı iki görevin birbirine yardımcı olması sağlanabilir [50].

Bu öğrenme yöntemi, insan öğrenmesi üzerinde bir şeyleri öğrenirken farklı, benzer ve ilişkili görevlerin o yeni görevi öğrenmemize faydalı olması olarak düşünülebilir.

Derin öğrenme için kullanılan temel olarak iki farklı çok görevli öğrenme yöntemi bulunmaktadır. Bunlar “Birleşik (Hard)” ve “Ayrık (Soft)” parametre paylaşımıdır.

- **Birleşik Parametre Paylaşımı:** Bu paylaşım türünde genelleştirilebilen katmanlar birden fazla görev için ortaklanır ve son kayıp fonksiyonlarının bulunduğu katmanlar özelleştirilir. Hard parametre paylaşımı aşırı öğrenme riskini azaltmaktadır. Öğrenilen yardımcı görev sayısı arttıkça aşırı öğrenme riski azalmaktadır [51]. Bu paylaşımın yapısı bu çalışmadaki görevler kullanılarak Şekil 23’te gösterilmiştir.



Şekil 23. Derin öğrenme ağlarında birleşik parametre paylaşımı

- **Ayrık Parametre Paylaşımı:** Bu yapıda ise her ayrı görev kendi modeline ve kendi parametrelerine sahiptir. Görevler arası parametreler düzenlenmeye çalışılarak başarımda iyileşme sağlamaya çalışılır. Tez kapsamındaki görevler kullanılarak bu yapı Şekil 24'te verilmiştir.



Bu tez çalışmasında da ESA modeli üzerinde ayrık parametre paylaşımı uygulanarak başarımda iyileştirme yapılmaya çalışılmıştır.

4. YNR VERİ KÜMESİNİN OLUŞTURULMASI

Yere gömülü olarak bulunan hedef veya hedef olmayan veriler, YNR sensör sistemi kullanılarak toplanmanın zorluğu ve maliyeti sebebiyle gprMax programı kullanılarak üretilmiştir. GprMax, zaman döneminde sonlu farklar (FDTD) yöntemini kullanarak elektromanyetik dalga yayılım benzetimi yapan açık kaynaklı bir yazılımdır. İlk olarak 1996 yılında ortaya çıkan bu program YNR sayısal modellemesini yapmaktadır. Günümüz bilgisayar teknolojisinin vermiş olduğu avantajlar ile şu anda çok karışık ve detaylı FDTD modelleri çözebilmektedir. Bu yazılım 3B Maxwell denklemlerini çözebilmek için Yee algoritmasını kullanmaktadır. Bu yazılım girdi dosyası olarak Amerikan Standart Kodlama Sistemi (ASCII) ile herhangi bir yazı düzenleyecisinde yazılmış bir dosya kabul eder. Girdi dosyasının her satırında hash karakteri (#) ile başlaması durumunda yazılım bu satırı işleme alır. Hash karakteri dışında herhangi başka bir karakterle başlayan bir satır olursa bu satır yazılım tarafından ihmal edilir. Yanlış bir komut girildiğinde yazılım hata mesajı verecektir. Yazılan komutlarda birden fazla parametre varsa parametreleri ayırmak için aralarında boşluk kullanılır [52].

4.1. YNR Modellemesi

Tüm elektromanyetik problemlerinde Maxwell denklemleri tanımlanmaktadır. Gprmax yazılımı, problemi FDTD yöntemini kullanarak çözmektedir. Bu denklemler, temel elektromanyetik alan nicelikleri ve kaynaklarına bağımlılıklarına arasındaki ilişkiyi gösteren birinci dereceden kısmi türev denklemleridir [52].


Herhangi bir hedef veya hedeflerin YNR tepkisinin benzetimini taklit etmek için, maxwell denklemlerinin problemin geometrisine ve başlangıç koşullarına bağlı olarak çözülmesi gerekir. YNR probleminin doğası, onu bir başlangıç değeri açık sınır problemi olarak sınıflandırmaktadır. Bunun anlamı, bir çözüm elde etmek için YNR verici anteninin uyartılması gibi bir başlangıç durumu tanımlamak gerektiğidir. Problemin geometrisinin sınırları ve elektromanyetik alanların önceden belirlenmiş bir değeri nasıl alabileceği belirsizdir [52].

FDTD modelinin uzaysal Δx , Δy ve Δz adım aralıkları ve zamansal Δt basamakları ne kadar küçük olursa problemin gerçek haline o kadar yakın olmaktadır. Bununla birlikte, bilgisayarların sınırlı miktarda depolama ve sonlu işleme hızı olması nedeniyle, ayrıklaştırma adımlarının değerleri her zaman sonlu olmalıdır.

Dolayısıyla FDTD modeli asıl problemin ayrık halini temsil eder ve sınırlı boyuttadır. Bu ayrık FDTD ızgarasının yapı taşı, FDTD yöntemine öncülük eden Kane Yee'den alıntılanan Yee hücresidir [53]. Eğik yapıdaki cisimler bu yapı ile kolayca tanımlanabilir ancak eğimli kısımlar merdiven şeklinde bir yapıda olmaktadır.

4.1.1. GprMax Koordinat Sistemi

GprMax orjini sol alt köşe (0,0,0) olacak şekilde sağ taraflı bir kartezyen koordinat sistemi kullanmaktadır. Bu çalışmada benzetim çalışmaları 2B olarak yapıldığı için orjin noktası (0,0) olarak düşünülmelidir. Bir YNR ortamı tanımlanmak istediğinde bu FDTD hücrelerine bölünerek yapılır ve bu her hücrenin uzunluğu 2B bir ortam için Δx ve Δy olarak tanımlanır. Şekil 25'te koordinat sistemi gösterilmiştir.



Şekil 25. GprMax koordinat sistemi

4.1.2. GprMax ile YNR Modelleme

YNR modellemesi için GprMax programı üzerinde önemli olan ve dikkat edilmesi gereken iki madde bulunmaktadır [52]:

- Adım Aralığı
- Sönümleyen Sınır Koşulları (ABC)

Bu iki madde daha detaylı olarak aşağıda sırasıyla açıklanmıştır.

4.1.2.1. Adım Aralığı

Doğru bir adım aralığı seçmek istenen çözünürlük, verici antenin darbe sıklık bileşeni ve hedef boyutu gibi değişkenlere bağlıdır. Model'deki tüm hedeflerin yeterli çözünürlüğe sahip olması gerektiği bir kısıt olarak gösterilebilir. Örnek olarak bir silindirin çapını birkaç tane adımda tasvir edecek olursak, o şekil çokta silindire benzemeyecektir [52]. Adım aralığını etkileyen bir diğer önemli faktör, sayısal olarak indüklenen dağılım ile ilgili hatalardır. Bu hata aşağıdaki kurala uyulursa minimum düzeyde tutulabilir [54], [55]:

Adım aralığı YNR ortamında bulunan en küçük dalga boyundan en az 10 kat küçük olmalıdır. Denklem (21)'da gösterilmiştir.

$$\Delta l \leq \frac{\lambda}{10} \quad (21)$$


50x60x0.2 cm boyutunda bir YNR modeli tanımlanmıştır. 3B bir model olarak gözükmese de z eksenini boyunca sadece bir hücre bulunması nedeniyle 2B olarak tanımlanabilir. (22) numaralı denklemin sonucuna göre adım aralığı en fazla 0.0045m seçilmelidir. Kullanılan en küçük hedefin yarıçapı da dikkate alınarak 0.002m seçilmiştir.

$$\Delta l = \frac{\lambda}{10} = \frac{c}{10f\sqrt{\epsilon_r\mu_r}} = \frac{3 \times 10^8}{15 \times 10^9 \times \sqrt{20 \times 1}} \cong 0.0045m \quad (22)$$

(22) numaralı denklemde c ışık hızı, f kullanılan dalganın merkez frekansı, ϵ_r bağıl elektriksel geçirgenliği ve μ_r bağıl manyetik geçirgenliği göstermektedir.

4.1.2.2. Sönümleyen Sınır Koşulu

Modellenen alanın antenlerden ve hedeflerden sonlu bir mesafede kesilip, burada elektromanyetik alanların değerlerinin doğrudan uygulanan sayısal yöntemle hesaplanamayacağı yerler vardır ki, bu YNR modellemesindeki en zorlu konulardan biridir. Bundan dolayı, Sönümleyen Sınır Koşulu (ABC – Absorbing Boundary Condition) olarak bilinen yaklaşık bir model sınırlandırma için yeterli bir mesafede uygulanır ve bu nedenle hesaplama alanını sınırlar. Bu ABC'nin rolü, ona çarpan dalgaları sönümleyerek sınırsız bir alanı taklit etmektir. ABC'ler tarafından sınırlandırılan hesaplama alanı verici, alıcı antenler ve hedefler gibi modelin tüm önemli özelliklerini içermektedir. Şekil 26 modellenecek problem ile gerçek FDTD modellemeli alan arasındaki bu temel farkı göstermektedir [52].



Şekil 26. ABC ile sınırlandırılmış bir YNR modellemesi [52]

Noktalı çizgi ile gösterilen alan ABC'yi tanımlamaktadır. Gerçek sonsuz bir alan yerine ABC ile sınırlandırılan bir alan kullanılmış ve gerçek ortam ile model arasındaki fark gösterilmiştir. GprMax programında kullanılan ABC'ler önemli yapay yansımalar olmaması için YNR ortamı içerisinde bulunan tüm kaynak (verici anten) ve hedefler bu sınırlardan en az 15-20 hücre uzağa yerleştirilmelidir. Bu hücrelerde alıcı ve verici anten noktaları belirlenebilmesine rağmen, bu işlem gerçek bir YNR modellenmesinden uzak olmaktadır. Bu mesafe ne kadar çok olursa sonuç o kadar iyi olmaktadır [52].

4.1.3. GprMax Girdi Dosyası Komutları

Girdi dosyası bir YNR modellemesi için gerekli olan tüm bilgiyi içermektedir. Girdi dosyasının içeriğinde bulunan genel hatları ile bir komut satırı aşağıda gösterilmiştir [52]:

#komut_ismi: parametre1 parametre2...

Girdi dosyasında bulunan parametre birimleri (SI) aşağıdaki gibidir [52]:

- Tüm adım aralığı, model boyutu ve koordinatla alakalı tüm parametreler Metre,
- Frekans tabanlı tüm parametreler Hertz,
- Benzetim zamanı, zaman penceresi gibi parametreler Saniye cinsinden ifade edilmiştir.

Şekil 27'de örnek bir GprMax girdi dosyası verilmiştir. Gerekli açıklamalar ve kullanılan komutlar hakkında bilgi bu şekil içinde bulunmaktadır. Hash karakteri (#)

ile başlamayan satırlar program tarafından işlenmemektedir. Bu satırlar açıklama için kullanılmıştır.

```
Gömülü hedef tespiti için örnek bir girdi dosyası
-----
--- #domain komutu YNR modellemesi yapılan alanı sırasıyla
--- x,y,z boyutlarında temsil eder.
#domain: 0.500 0.600 0.002
--- Modeldeki adım aralığını sırasıyla x,y,z yönlerinde temsil eder.
--- bu adım aralıkları en çok En küçük dalga boyu/10 olmalıdır.
#dx_dy_dz: 0.002 0.002 0.002
---- x eksenindeki her bir hücre sütünü için geçecek süreyi ifade eder.
#time_window: 10e-9
-----
--- Farklı türden materyallerin manyetik alandaki bazı özellikleri
--- #material komutu ile tanımlanmıştır.
--- Bu parametreler sırasıyla Dielektrik Saibiti (Er), İlektenlik ( $\sigma$ )
--- Manyetik Geçirgenlik ( $\mu_r$ ), Manyetik Kayıp( $\sigma^*$ ) 'tır.
#material: 80.0 0.5 1.0 0.0 fresh_water
#material: 6 0 1 0 half_space
#material: 6.0 0.001 1.0 0.0 concrete
#material: 8.0 0.01 1.0 0.0 damp_sand
#material: 3.0 0.00001 2.0 0.01 dry_sand
#material: 20.0 0.1 1.0 0.0 wet_sand
#material: 6.0 0.01 1.0 0.0 plastic
#material: 2.0 0.01 2.0 15 asphalt_dry
#material: 10000.0 5600000.0 1.0 0.0 copper
-----
--- Bu bölüm antenler hakkında bilgi içerir.
--- #waveform komutu verici anten tarafından basılan darbe sinyalinin
--- bilgisi verilmiştir. Sırasıyla dalga şekli, maksimum genlik skalası
--- ve dalganın merkez frekansı verilmiştir.
#waveform: ricker 1 1.5e9 my_ricker
--- #hertzian_dipole: Verici antenin başlangıç konumu
#hertzian_dipole: z 0.08 0.5 0 my_ricker
--- #rx: Alıcı antenin başlangıç konumu
#rx: 0.12 0.5 0
--- #src_steps ve #rx_steps antenlerin adım aralıklarını tanımlar.
#src_steps: 0.01 0 0
#rx_steps: 0.01 0 0
-----
--- Bu kısımda toprağın bulunduğu alan ve içine gömülü olan cisim tanımlanır.
--- #box: Toprak bulunan alanı tanımlar.
#box: 0 0 0 0.5 0.5 0.002 dry_sand
--- #cylinder: Hedefi tanımlar.
#cylinder: 0.25 0.40 0 0.25 0.40 0.002 0.005 copper
-----
--- Gömülü cismin nasıl gözüktüğünü incelemek için .vti uzantılı bir dosya
--- üreten komut satırıdır.
#geometry_view: 0 0 0 0.5 0.6 0.002 0.002 0.002 0.002 cylinder n
```

Şekil 27. Örnek bir GprMax girdi dosyası ve açıklamaları

Hedef ve hedef-dışı sınıfı için gprMax girdi dosyalarından bazıları örnek olarak Şekil 28, Şekil 29 ve Şekil 30'da verilmiştir.

```
#domain: 0.500 0.600 0.002
#dx_dy_dz: 0.002 0.002 0.002
#time_window: 10e-9

#material: 3.0 0.00001 2.0 0.01 dry_sand
#material: 6.0 0.01 1.0 0.0 plastic

#waveform: ricker 1 1.5e9 my_ricker
#hertzian_dipole: z 0.08 0.5 0 my_ricker
#rx: 0.12 0.5 0
#src_steps: 0.01 0 0
#rx_steps: 0.01 0 0

#box: 0 0 0 0.5 0.5 0.002 dry_sand
#cylinder: 0.15 0.25 0 0.15 0.25 0.002 0.005 plastic
```

Şekil 28. Kuru toprağa gömülü plastik telin gprMax girdi dosyası

```
#domain: 0.500 0.600 0.002
#dx_dy_dz: 0.002 0.002 0.002
#time_window: 10e-9

#material: 3.0 0.00001 2.0 0.01 dry_sand
#material: 2.0 0.01 2.0 15 asphalt_dry

#waveform: ricker 1 1.5e9 my_ricker
#hertzian_dipole: z 0.08 0.5 0 my_ricker
#rx: 0.12 0.5 0
#src_steps: 0.01 0 0
#rx_steps: 0.01 0 0

#box: 0 0 0 0.5 0.5 0.002 dry_sand
#cylinder: 0.33 0.32 0 0.33 0.32 0.002 0.005 asphalt_dry
```

Şekil 29. Kuru toprağa gömülü asfalt telin gprMax girdi dosyası

```

#domain: 0.500 0.600 0.002
#dx_dy_dz: 0.002 0.002 0.002
#time_window: 12e-9

#material: 6.0 0.001 1.0 0.0 concrete
#material: 3.0 0.00001 2.0 0.01 dry_sand

#waveform: ricker 1 1.5e9 my_ricker
#hertzian_dipole: z 0.08 0.5 0 my_ricker
#rx: 0.12 0.5 0
#src_steps: 0.01 0 0
#rx_steps: 0.01 0 0

#box: 0 0 0 0.5 0.5 0.002 dry_sand
#fractal_box: 0.21 0.23 0 0.26 0.28 0.002 1.5 1 1 1 concrete myfbox
#add_surface_roughness: 0.21 0.23 0 0.21 0.28 0.002 1.5 1 1 0.19 0.23 myfbox
#add_surface_roughness: 0.26 0.23 0 0.26 0.28 0.002 1.5 1 1 0.24 0.28 myfbox
#add_surface_roughness: 0.21 0.23 0 0.26 0.23 0.002 1.5 1 1 0.21 0.25 myfbox
#add_surface_roughness: 0.21 0.28 0 0.26 0.28 0.002 1.5 1 1 0.26 0.30 myfbox

```

Şekil 30. Kuru toprağa gömülü beton bozuk yüzeyli cismin gprMax girdi dosyası

Girdi dosyalarında bulunan ve Şekil 6'da gözüken parametreler ve açıklamaları Çizelge 4'te verilmiştir.

Çizelge 4. GprMax benzetim parametreleri

İsim	Değer	Birim	Açıklama
x	500	mm	Benzetim x eksen
y	600	mm	Benzetim y eksen
z	2	mm	Benzetim z eksen
dx	2	mm	Yee hücre uzunlukları x eksen
dy	2	mm	Yee hücre uzunlukları y eksen
dz	2	mm	Yee hücre uzunlukları z eksen
t	10	ns	Zaman ekranı uzunluğu
f_c	1.5	GHz	Radar sinyali merkez frekansı
r	5	mm	Gömülü tel yarıçapı
x_{TX}	(80, 500, 0)	mm	Verici antenin başlangıç konumu (hertzian dipole)
x_{RX}	(120, 500, 0)	mm	Alıcı antenin başlangıç konumu (rx)
Δx_{TX}	(10, 0, 0)	mm	Verici anten adım aralığı (src_steps)
Δx_{RX}	(10, 0, 0)	mm	Alıcı anten adım aralığı (rx_steps)
y_k	500	mm	Kum alanı y eksen boyutu
y_h	100	mm	Hava alanı y eksen boyutu

4.1.4. Gömülü Nesnelerin EM özellikleri

Maxwell denklemleri yansıyan ve yayılan sinyallerin EM etkileşimini elektrik (E) ve manyetik (H) alan cinsinden tanımlar [56]. Yeraltındaki bir cisim ile toprağın arasındaki elektriksel geçirgenlik (ϵ), manyetik geçirgenlik (μ) ve elektriksel iletkenlik (σ) gibi EM özellik farklılıkları, gönderilen dalganın toprak içinde hangi hızla ne kadar ilerleyeceğini ve cisimden ne kadarının yansıtacağını belirler [57]. Gömülü nesnelerin tespitinde önemli EM özellikler olarak sırasıyla ϵ , μ ve σ aşağıda anlatılmıştır [58], [59].

Bir maddenin manyetik geçirgenlik (μ), manyetik alan mıknatıslanma yeteneğini tanımlar ve manyetik kutuplanması metre başına Henries (H/m) cinsinden ölçülür.

Serbest uzayda manyetik geçirgenlik (μ_0),

$$\mu_0 \approx 1.256 \times 10^{-6} \text{ (H/m)} \quad (23)$$

ve bir malzemenin bağıl manyetik geçirgenliği (μ_r),

$$\mu_r = \frac{\mu}{\mu_0} \quad (24)$$

olarak tanımlanır.

Elektriksel Geçirgenlik (ϵ), maddenin metre başına Farad (F/m) cinsinden ölçülen ve bir EM alan tarafından indüklenen bir elektrik yükünü depolama ve iletme kabiliyetini tanımlar.

Serbest uzayda elektriksel geçirgenlik (ϵ_0)

$$\epsilon_0 = \frac{1}{\mu_0 c^2} \approx 8.854 \times 10^{-12} \text{ (F/m)} \quad (25)$$

ve bir malzemenin bağıl elektriksel geçirgenliği (ϵ_r),

$$\epsilon_r = \frac{\epsilon}{\epsilon_0} \quad (26)$$

olarak tanımlanır.

Elektriksel İletkenlik (σ), EM dalgaların elektriksel kısmının elektrik iletim kabiliyetini gösterir ve metre başına Siemens (S/m) ile ölçülür. Toprak cinsi açısından

düşünülecek olursa toprak iletkenliği ne kadar düşük olursa EM dalga toprak içinde o kadar derinlere ilerleyebilir. Kullanılan materyallerin EM özellikleri Çizelge 5'te verilmiştir.

Çizelge 5. Kullanılan materyallerin EM özellikleri

Materyal	ϵ_r	σ	μ_r
Kuru Toprak	3	0.00001	2.0
Nemli Toprak	8	0.01	1.0
Islak Toprak	20	0.1	1.0
Bakır	10000	5600000	1
Beton	6	0.001	1
Asfalt	2	0.01	2
Plastik	6	0.01	1

4.2. Ön İşleme

GprMax, girdi olarak verilen *.in formatında verilen dosyaları işleyerek *.out formatında çıktıları oluşturmaktadır. *.out dosya formatı, girdi dosya ismi ile aynı ismi taşımaktadır [52]. A-Tarama verileri sadece bir iz gösterdiği için tek bir girdi dosyasına karşılık tek bir çıktı dosyası oluşmaktadır. B-Tarama verisinde ise taranan alanın büyüklüğüne ve adım aralığına bağlı olarak çok sayıda çıktı dosyası oluşmaktadır. Bu çıktıların her biri her iz için A-Tarama verisini oluşturmaktadır. Bu çıktı dosyalarını birleştirmek için gprMax yazılımında tanımlı olan “outputfiles_merge.py” isminde bir eklenti bulunmaktadır ve aşağıdaki komut dizini ile kontrol edilmektedir.

```
python -m tools.outputfiles_merge girdi_dosyası_ismi
```

Bu komut aynı zamanda kullanıcıya ayrık olarak oluşturduğu *.out uzantılı dosyaları (A-tarama verileri) silme seçeneğini sunar.

Çıktı dosyası, HDF5 (Hierarchical Data Format, version 5) isimli büyük çaptaki sayısal verileri düzenlemek ve depolamak için tasarlanmış olan bir formatı kullanmaktadır. Bu dosya formatını okumak için çok sayıda program bulunmaktadır. Kullanıcı, ihtiyacı olan veriye, *.out çıktı dosyasının aşağıdaki bazı örnekleri verilen görüntüleme yazılımlarıyla ulaşabilmektedir [60]:

- Data Visualizer for O-Matrix
- EnSight - Extreme Visualization Software
- HDF Explorer
- IDL-HDF5 Interface
- Igor Pro
- MAQbox
- Mathematica
- NI-HWS
- O-Matrix
- PV-WAVE
- SYSTEMA / THERMICA
- Tecplot
- THESEUS-FE
- MATLAB

MATLAB, bu amaç için tasarlanmamış olsa bile yüksek seviye hesaplama dili sayesinde, HDF5 formatında bir dosyayı okuyup, işleyebilme yeteneğine sahiptir.

Bu tez çalışmasında, *.out dosya uzantılı veriler, MATLAB üzerinde ön işleme süreçlerinden geçirilerek derin öğrenme algoritmamıza girecek olan nihai girdileri oluşturmaktadır.

GprMax programı, *.out uzantılı benzetim çıktısına ek olarak oluşturduğumuz modelin toprağın içinde hangi konuma nasıl bir nesne gömdüğümüzü görüntülemek için *.vti isimli bir geometri çıktısı oluşturur. Bu çıktıyı oluşturmak için girdi dosyasının sonuna “#geometry_view” ile başlayan bir kod satırı yazılmalıdır.


```
#geometry_view: f1 f2 f3 f4 f5 f6 f7 f8 f9 dosya1
```

f1 f2 f3 sol alt koordinatları, f4 f5 f6 sağ üst koordinatları, f7 f8 f9 adım aralıklarını

dosya1 oluşturulacak geometri çıktısı ismini ifade etmektedir. Geometri görünümü ayrıca PML bölgelerinin ve modeldeki herhangi bir kaynağın ve alıcının konumunu gösterir [52].

Geometri çıktısını görüntülemek için çok sayıda ücretsiz program bulunmaktadır. Bunlar biri olan “Paraview” açık kaynak bir görüntüleme yazılımıdır [52], [61], [62].


Paraview programı kullanılarak geometri çıktısı görüntüleme adımları Şekil 31’de maddeler halinde gösterilmiştir. *Gprmax_info.py* komut dosyasını Paraview’de makro olarak eklemek için dosyayı Macros-> Add new makro menüsünden seçin. Daha sonra Şekil 31’de 4 numaralı adımda gösterildiği gibi araç çubuğunda bir kısayol düğmesi olarak görünecektir. Sadece bunu bir kez yapmanız yeterlidir, makro gelecekte kullanılmak üzere Paraview’de tutulacaktır [52], [61].



Şekil 31. *.vti dosya formatını Paraview ile görüntüleme işlemi

Sonuçta Şekil 32 (a)'daki görüntü elde edilmiştir. Şekilde gömülü nesne, toprak, kaynak ve alıcı antenler ve PML bölge gösterilmiştir.

Gprmax programından alınan çıktı sırasıyla arka plan çıkarma ve beyazlatma işlemlerine tabi tutulmuştur. Sonuç olarak oluşan benzetim Şekil 32 (b)'de gösterilmiştir. Arka plan çıkarma işlemi hava-toprak geçişinden kaynaklı yansımaları ve istenmeyen yansımaları kaldırırken, beyazlatma işlemi hiperbolün kollarına doğru yani toprak derinliklerine doğru azalan sinyal seviye farklılıklarını düzeltmektedir.



(a) Toprağa gömülmüş 1cm çapındaki telin paraview model görüntüsü



(b) Toprağa gömülmüş 1cm çapındaki telin gprmax programı ile B-tarama EM yayılım benzetimi (ön işlem görmüş)


Şekil 32. GprMax YNR modeli sonuçları

Gömülü nesnenin oluşturduğumuz girdi dosyası ile nerede oluştuğunu görüntülendikten sonra bu modelin manyetik benzetimi için gprMax programı ile çıktı dosyası oluşturulur. Bu çıktıya ön işleme adımları olarak sırasıyla arka plan çıkarma ve beyazlatma işlemi uygulanmaktadır.

4.2.1. Yer Yansıması Kaldırma

Oluşturulan YNR benzetiminde ham çıktıda istenmeyen sinyaller oluşmaktadır. Bu istenmeyen sinyaller hava-toprak geçişinden kaynaklı olan ve diğer istenmeyen ikincil yansımalar olarak görülebilir. Bunlardan bizim için en büyük problem yer yansımasıdır. İncelenen kaynaklarda yer yansıması çözümü için birkaç yöntem

önerilmiştir. Bu yöntemlerden bazıları Ortalama çıkarma, SVD (Singular Value Decomposition), PCA (Principal Component Analysis), ICA (Independent Component Analysis)'dır [63]. Literatürde yer yansıması kaldırma işlemi farklı adlarla da anılmaktadır. “Anten karakteristiği ve hava-toprak geçişi kaldırma”, “hedef dışı yansıma azaltma” ve “saç kesimi” bunlardan bazılarıdır. Saç kesimi yöntemi özellikle YNR görüntülerinde yüzeye yakın cisimler bulunması nedeniyle hedef olan görüntünün kaybolmasına neden olduğundan faydalı olmamaktadır. Görüntü işlemede ise yer yansıması kaldırma yöntemi arka plan çıkarma olarak da bilinmektedir [64]. GprMax programının çıktısı olarak elde ettiğimiz ham çıktıyı diğer ön işlem adımlarından önce en önemli problem olan yer yansımasını ESA için faydalı bir girdi sağlaması adına kaldırılmalıdır. Bu yansıma hava-toprak geçişinden kaynaklanmakta ve bu geçişteki problem hava-toprak arasındaki dielektrik farklılıklardan ortaya çıkmaktadır. Hava-toprak geçişinden kaynaklı olan sinyaller hava-toprak arasındaki dielektrik farklılığın toprak ile gömülü nesne arasındaki dielektrik farklılığa göre çok yüksek olmasından dolayı daha baskın bir sinyal olarak gözükmemektedir. Bu baskın sinyal, gömülü hedefin sinyal seviyesi olarak ihmal edilmesine neden olabilir. Bu istenmeyen sinyallerden kurtulmak için kullandığımız veriler için ikincil yansımalar düşünüldüğünde en etkili ve basit yöntem arka plan çıkarma işlemidir. Bu yöntemde aynı toprak türünde cisim gömülü değilken alınan gprMax çıktısı elde edilen ham gprMax çıktısından çıkarılarak arka plan çıkarma işlemi tamamlanmıştır. Arka plan çıkarma yöntemi ile cisim gömülü değilken oluşan tüm istenmeyen sinyallerden arındırılmış bir görüntü elde edilmiştir. Şekil 33'te ham gprMax çıktısı ve yer yansıması kaldırma işleminden sonraki görüntüler verilmiştir.



Şekil 33. Yer yansıması kaldırma işlemi

4.2.2. Beyazlatma

Gömülü nesnelerin görüntülenmesinde oluşan bir başka problem ise toprak derinliklerine gittikçe azalan sinyal genlikleridir. Bu da görüntüde aşağılara doğru inildikçe netliğin azalmasına sebep olmaktadır. Toprak ya da yeryüzü derinliklerine inildikçe verici antenden yayılan sinyal seviyesinin azalması nedeniyle gömülü cismin görüntüsü ile derinliği arasında ters orantı bulunmaktadır. Ayrıca Şekil 33'te da gözüktüğü üzere gömülü bir cismin gprMax benzetimi sonucu görüntüde oluşan hiperbol şeklinin kollarına doğru sinyal seviyesi azalmaktadır. Bu azalmanın sebebi de aynıdır. Bu çıktıları derinlikten bağımsız hale getirmek ve farklı derinliklere gömülü cisimlerin sinyal kayıplarını engellemek adına beyazlatma işlemi uygulanmaktadır. Bu çıktıları beyazlatma işlemi uygulandığında derinlik kaynaklı bozulmalara çözüm olduğu görülmüştür. Beyazlatma işleminin sınıflandırma başarımı üzerine olumlu etkileri bulunmaktadır [65]. Gader vd. [66]'nın çalışmasında, adaptif beyazlatma yöntemiyle gprMax çıktısı üzerinde yer yansıması kaldırıldıktan sonra derinliğe bağlı olarak belirlenen satır sayısı kadar pencereler alınmaktadır. Bu derinlik bağımlı olarak yapılan beyazlatma işlemine adaptif beyazlatma denmektedir. Bu çalışma kapsamında her bir görüntü tek bir pencere olarak düşünülmüş olup, tek işlemde beyazlatma işlemi yapılmıştır. Bu işlem, temel olarak PCA'ya dayanmaktadır. PCA işlemi asıl olarak boyut azaltmak için yapılmaktadır. Buradaki yapı ise derinlik ekseninden bağımsız hale getirmektedir. Beyazlatma işlemi aşağıdaki adımlardan oluşmaktadır [42].


- GprMax çıktısının ortalama değeri ham veriden ya da yer yansıması kaldırılmış olan veriden çıkartılarak orijin merkezli bir veri elde edilir.
- Sıfır merkezli verinin Matlab üzerinden `cov( )` komutu ile kovaryans matrisi bulunur. Bu matris boyutlar arasındaki ilişkiyi içermektedir.
- Özdeğer ve özvektör hesaplanır.
- Son olarak beyazlatma işlemi uygulanmış olan matris (27)'deki denklem ile elde edilir [66].

$$X = X*V*diag(1./(diag(D)+\beta).^{(1/2)})*V' \quad (27)$$

Denklemden gözükürken X değeri yer yansıması kaldırılmış ve orijine çekilmiş gprMax çıktısını, D ve V sırasıyla; X değerinin köşegen özdeğer ve özvektörünü gösterir.

Ayrıca denklemde beyazlatma faktörü olan β bölümünün alt tarafının '0' olmaması için eklenmiştir. Denemeler sonucu β sayısı '10' olarak seçilmiştir.

Beyazlatma işlem sonucu elde edilen sonuç Şekil 34'te gösterilmiştir. Bu şekil üzerinde beyazlatma işleminin istediğimiz yönde başarılı olduğu görülebilmektedir. Şekil 34 (a) kısmında hiperbol kollarına doğru azalan sinyal seviyesinin (b) kısmında olmadığı buna bağlı olarak derinlik etkisinin ortadan kaldırıldığı görülebilmektedir.



(a) Yer yansıması kaldırılmış çıktı

(b) Beyazlatma işlemi sonucu çıktı

Şekil 34. Beyazlatma işlemi

5. DERİN ÖĞRENME YÖNTEMİ İLE GÖMÜLÜ HEDEF TESPİTİ

Bu tez kapsamında oluşturulan ESA'lar, hedef tespiti yapabilmek amacıyla Matlab üzerinde ve matconvnet altyapısı kullanılarak oluşturulmuştur. Matconvnet, bilgisayarla görü uygulamalarında ESA oluşturmaya yardımcı bir MATLAB aracıdır [41]. Bu çalışma kapsamında, üretilen veri kümelerini kullanan bir ESA model mimarisi önerilmiştir. Bir ESA eğitim ve doğrulama verileri kullanılarak eğitilmiştir. Matconvnet çatısı altında oluşturulan 3 evrişim ve 3 toparlama katmanına sahip derin öğrenme modeli Şekil 35 ve Çizelge 6'da gösterilmiştir.



Şekil 35.Önerilen ESA model mimarisi genel yapısı


Oluşturulan iki farklı veri kümesinden biri hedef ve hedef-dışı olarak tespit eden ESA'ya girdi yaparken diğer veri kümesi gömülü olan cismin hangi toprak türüne gömülü olduğunu tespit eden modele girdi oluşturmuştur. 227x227x1 boyutlarda bir ön işleme adımları uygulanmış gprMax çıktısının girdi yaptığı model, sonuç olarak 1x1x2 boyutunda hedef veya hedef-dışı olarak sonuç vermektedir. Eğer toprak türü ayrımı yapan veri kümesi kullanılacak olursa da önerilen modeldeki son tamamen bağlı katmanı kuru, nemli veya ıslak toprak olarak karar verdiğinden 1x1x3 boyutunda sonuç vermektedir. Hangi sonuç daha büyükse sınıflandırıcı o sınıf lehine karar vermektedir. Çizelge 6, Şekil 35'in boyutlarını açıklamaktadır. Çizelge 6'da her katmanda bulunan filtrelerin boyutları, derinlikleri, bu filtrelerin veriye uygulanırken ne kadarlık bir kaydırma ile uygulanacağı ve giriş verisine '0' ekleme miktarı gösterilmiştir.

Çizelge 6.Önerilen model mimarisi: ESA

Katman	Evrişim	Toparlama	Evrişim	Toparlama	Evrişim	Toparlama	tb*
Parça	11x11	3x3	5x5	2x2	4x4	2x2	1x1
Derinlik	12	12	64	64	64	64	2
Kaydırma	4	2	2	2	2	2	1
“0” ekleme	-	-	-	-	-	-	-

* Tamamen Bağlı

Önerilen mimari sonucu eğitilen ESA’da 227x227x1 boyutunda bir YNR verisinin derin öğrenme modeli ileri besleme aşında ilerleyişi Şekil 36’da gösterilmiştir. Bu şekilde 227x227x1’lik bir YNR verisinin 11x11 boyutlu derinlik miktarı 12 olan bir evrişim katmanından 4 kaydırma miktarı uygulanarak geçtiğinde 55x55x12’lik bir çıktı oluşturmaktadır. Çıktı boyutunun nasıl hesaplandığı denklem (19) ile gösterilmiştir.



Şekil 36. Önerilen derin öğrenme mimarisi modeli katmanları ve geçişi

ESA model başarımını geliştirme yöntemlerinden biri aktarım öğrenmesidir. Yeni bir ESA eğitirken, çok sayıda veri gerektiğinden dolayı oluşturulan veri kümesi ile yüksek başarıım oranı elde edilememektedir. YNR verisi üretmenin zorluğu göz önüne alındığında ve başarıım oranını iyileştirmek istendiği için aktarım öğrenmesi yöntemi ile daha önceden eğitilmiş bir model mevcut mimariye entegre edilmiştir. Bu aktarım için imagenet resimleri ile eğitilen “matconvnet-vgg-f” seçilmiştir. “matconvnet-vgg-f” imagenet resimleri (~14 milyon resim) ile 1000 ayrı kategoride

eğitilmiş olan bir ESA'dır. Bu ESA'nın ilk 2 evrişimsel katmanını içeren ilk 6 katman (toparlama ve aktivasyon katmanları ile birlikte) sabitlenerek ESA eğitilmiştir. Aktarım öğrenmesi yöntemi, hedef ve toprak türü tespit görevleri için ayrı ayrı uygulanmıştır. Böylece daha geniş bir veri kümesinden elde edilen köşe algılama, renk vb. gibi genel sınıflandırma öznelitliklerini ayırt etmek için oluşturulan ilk katmanların etkisi incelenmiştir. İlk 2 evrişimsel katman alınarak bu katmanların yeni modele girdisi öğrenme katsayıları 0 tutularak sağlanmıştır. Yani bu katmanlardaki filtreler (ağırlık matrisleri) yeni eğitim sırasında güncellenmeyecek mevcut halleri ile kalmıştır. Bu şekilde hedef tespit modelinin sınıflandırma başarımında artış gözlenmiştir. Detaylı bir şekilde Çizelge 7'de açıklanmıştır.

Çizelge 7.Önerilen model mimarisi: aktarım öğrenmesi

Katman	Evrişim **	Toparlama	Evrişim **	Toparlama	Evrişim	Toparlama	tb*
Parça	11x11	3x3	5x5	3x3	7x7	3x3	1x1
Derinlik	64	64	256	256	64	64	64
Kaydırma	4	2	1	2	3	2	2
“0” ekleme	-	-	2	-	-	-	-

* Tamamen Bağlı


** Sabitlenen katman (Öğrenme oranları 0 olarak ayarlanmıştır.)

5.1. Çok Görevli Öğrenme Yöntemi Detayları

Başarım arttırmak için farklı bir yöntem de çok görevli öğrenmedir. Bu tez çalışması içinde bu yöntemi uygularken başarım oranlarını iyileştirme adına bir “çok görevli öğrenme” modeli sunulmuştur. Önerilen çok görevli öğrenme modeline girdi olması adına iki tek görev, yani hedef tespiti ve gömülü bulunan toprak cinsi görevleri ayrı ayrı modellenerek eğitilmiştir. Daha sonra bu ayrı görevler belli bir katsayı kullanarak ortaklanmıştır. İki farklı görevden alınan katmanların öğrenme katsayıları sıfırlanarak dondurulmuştur. Buradaki amaç tek görevlerde bulunan ağırlık matrisleri ile değişiklik yapmadan yardımcı olarak bulunan toprak türü görevinin ana görevimiz olan hedef tespiti görevine katkı sağlayıp sağlamadığını incelemektir.


Bu işlemin gerçekten fayda sağlayıp sağlamayacağını denemek için hedef ve toprak türü görevinin ağırlık matrisleri farklı oranlarda toplanarak hedef tespitinde iyileştirme sağlayıp sağlamadığı incelenmiştir. Bu incelemenin sonucu Şekil 37'de

gösterilmiştir. Şekilde ESA modellerinden hedef türü tespiti için ağırlık matrisleri α sayısı ile çarpılmış ve toprak türü görevi ağırlık matrisleri $1-\alpha$ sayısı ile çarpılarak toplanmıştır. Kesikli çizgi ile hedef görevinin tek başına sınıflandırma başarımı yani %74 gösterilmektedir. Çok görevli öğrenme yöntemi ile α değerinin 0,982 seçildiği noktada başarımlar %80,83 ile en üst seviyeye ulaşmaktadır. Bu grafik bu yöntemin ESA ile uygulanması için motivasyon oluşturmıştır.



Şekil 37. Çok görevli öğrenme ile hedef tespit görevi başarımı

α değerinin deneme ile bulunması ile başarımın belirli bir değerde arttığı görülmüştür. Bu α değerinin ESA modeli ile eğitilerek, bu değerin otomatik olarak öğrenilmesi istenmiş ve bu yöntem için çapraz dikiş methodu kullanılmıştır. Bu method, ana görev ile yardımcı görevi belirli bir katsayı ile birleştirmektedir. Detaylı gösterim Şekil 38'de gösterilmiştir. Turuncu ile gösterilen kutular evrişim katmanları ve mavi ile gösterilen kutular da toparlama katmanlarıdır.



Şekil 38. Çarpaz dikiş yöntemi işleyiş şeması

Her evrişimsel katman sonrası eklenen bu çarpaz dikiş birimleri, hedef tespit görevini α katsayısı ile ve toprak türü görevini $(1 - \alpha)$ katsayısı ile çarparak toplamaktadır. Çıkan sonuç bir sonraki katman olan toparlama katmanına ya da modelde bulunan gizli katmanlardan birine girdi olmaktadır. Çarpaz dikiş birimi modelde her evrişimsel katman çıkışına eklenmiştir. Aktarım öğrenmesi sonucu her iki veri kümesi için de ilk 2 evrişim katmanı önceden eğitilmiş bir modelden alınarak sabitlendiğinden, bu sabitlenen katmanların çok görevli öğrenme yapısında bir katkısı bulunmamaktadır. Etkin olarak sadece veri kümesine özel olarak eğitilen 3. evrişimsel katman bir fayda sağlamaktadır. Buradaki mantığı matematiksel bir işlem olarak göstermek adına A (hedef tespit görevi) ve B (toprak türü belirleme görevi) olarak iki farklı görev tanımlayalım. Bu iki görev ayrı ayrı eğitilmiş ve modelleri oluşturulmuştur. Bu iki farklı görevi birleştirecek bir ara birim önerilmiştir. Bu birim her evrişim katmanı sonrası oluşan çıktıların doğrusal bir birleşimini sağlamaktadır. Bu ifade denklem (28)'de gösterilmiştir.

$$[\tilde{x}] = [\alpha \quad (1 - \alpha)] \begin{bmatrix} x_A \\ x_B \end{bmatrix} \quad (28)$$

Bu denklemde bulunan x_A ifadesi çarpaz dikiş birimi öncesi A görevinin evrişimsel katman sonucunu ve $\tilde{x}$ ifadesi ise bu çarpaz dikiş birim işlemi sonucu çıktıyı

göstermektedir. Bu çıktı bir sonraki A ve B görevlerinin katmanları için girdi oluşturmaktadır. Eğer bu α değeri 1 seçilirse A görevi tek başına seçilmiş ve yardımcı olan B görevinin etkisi sıfırlanmış olmaktadır. Önerilen çok görevli öğrenme yapısında yardımcı görevden küçük oranlarda faydalanılması düşünülmüştür. Bu mantık çerçevesinde α başlangıç değeri 0,9 gibi görev tarafına doğru seçilirse başarımlar artışı sağladığı gözlemlenmiştir. Bu katsayı eğer çok uzak seçilirse ve öğrenme katsayısı da küçükse genel minimuma ulaşması için çok fazla deneme gerekmektedir. Bu ödünleştirmelere dikkat edilerek hedef bulma görevimizle ilişkili yardımcı bir görev seçilmesi gerekliliği bulunmaktadır. Tez kapsamında bu yardımcı görev toprak türünü belirleme olarak seçilmiştir.

Derin öğrenme mimarilerinde modelin eğitilmesine göre öğrenim gören katmanlarda bulunan ağırlık matrislerinin eğitilmesi gerekmektedir. Önerilen yöntem için oluşturulan katman, ileri besleme ağında matematiksel olarak denklem (28)'de tanımlanmıştır. Öğrenilebilen parametreler yani ağırlık matrisinin eğitilmesi için, bir geri yayılım katmanı oluşturulması gerekmektedir. Gradyan tabanlı geri yayılım yöntemi için formül, bu ileri besleme katmanının kısmi türevidir. Geri yayılımın temel amacı, sınıflandırma hatasını en aza indirecek şekilde parametreleri güncellemek ve gradyanların çıkıştan girişe yayılım ile verimli bir şekilde hesaplanabilmesidir [67]. Bu katman yapısı özellikle karmaşık sinir ağı yapılarında kullanılmaktadır. Çapraz dikiş biriminin geri yayılım işlemi hem girdi matrisine hem de öğrenmesini istediğimiz α değişkenine göre türevlenerek denklem (29) ve (30)'te tanımlanmıştır.

$$\frac{\partial L}{\partial x} = [\alpha \quad (1 - \alpha)] \begin{bmatrix} \frac{\partial L}{\partial \tilde{x}_A} \\ \frac{\partial L}{\partial \tilde{x}_B} \end{bmatrix} \quad (29)$$

$$\frac{\partial L}{\partial \alpha} = \frac{\partial L}{\partial \tilde{x}_A} x_A - \frac{\partial L}{\partial \tilde{x}_B} x_B \quad (30)$$


Denklemlerde bulunan L ifadesi geri yayılım işlemi aşamasındaki kayıp fonksiyonunu tanımlamaktadır. Bu denklemlerde çıkış katmanından arada kalan gizli katmanlara ve gizli katmanlardan giriş katmanına kadar ağırlık matrisinde olan değişiklikler hesaplanmaktadır. Bu değişime bağlı olarak öğrenilebilen veriler

güncellenmektedir. Bu güncellemeyi türevin '0' olduğu yani hatanın en az olduğu yere kadar yapmaya devam etmektedir.

Bu yöntemin daha önce anlatılan farklı kaynaklarda görsel imgeler üzerine çalışmaları bulunmakla birlikte, YNR üzerinde bu yöntemi deneyen bir çalışmaya rastlanmamıştır. Önerilen çapraz-dikiş yöntemi, Misra vd. [35]'in çalışmasından referansla üretilmiştir.

5.2. Evrişimsel Sinir Ağı Ne Öğrendi?

Derin öğrenme mimarilerinin ne öğrendiğini incelemek oldukça zor bir problemdir. Ne öğrendiğini yorumlamak için birkaç yöntem bulunmaktadır. Geliştirilen bu yöntemler, öznitelikleri nasıl öğrendiğini anlamak için geliştirilmiştir [42]. Oluşturduğumuz modeli iyileştirmek ve daha karmaşık veriler ile doğru sonuç vermesini sağlamak için bu yorumlamaya ihtiyaç bulunmaktadır [68]. 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. Öğrenilen öznitelikleri anlamlandırmak için gömülü bir telin eğitilmiş katmanlardan geçişi Şekil 39'da gösterilmiştir.



Şekil 39. Bir verinin öğrenilen modelden geçişi

Özellikle toparlama katmanının sadece boyut küçültme odaklı olduğu düşünüldüğünde aktivasyon katmanında negatif değerlerin 0'a çekilmesi hedefin arka plandan ayrılmasına yardımcı olmuştur. Şekil 39'daki ilk toparlama katmanında bu etki görülmektedir. Toprak olarak gözüken arka planları siyah piksele yaklaştırır ve asıl olan hedef bölgesini beyaz olarak göstermektedir. Buradan hareketle evrimsel katmanın tek başına sınıflandırma sağlayamayacağını söylenebilir [69]. İkinci toparlama katmanında da beyaz piksellerin hedefin olduğu bölgeye yoğunlaştığını ve daha önce bahsedilen hiperbol şekli korunarak arkaplane göre zıtlık oluşturduğu görülmektedir. Son evrimsel katmanda 3x3 boyutunda olan piksellerin farklı değerlerde oluşması farklı dielektrik materyalleri öğrenmesi olarak yorumlanabilir. Son aktivasyon işlemi sonrası toparlama katmanında gözüken gri matrisler bu filtreye takılan yani negatif değerli matrislerdir. Eğitilen sınıflandırıcı %63 ihtimalle girdinin hedef olduğunu söylemektedir.

5.3. Çalışma Detayları, Deneysel Sonuçlar, Başarımlar ve Limitler


Bu tez çalışması kapsamında, gömülü hedef ve hedefin gömülü bulunduğu toprak türü derin öğrenme algoritmalarıyla tespit edilmeye çalışılmıştır. Bu çalışmaya ek olarak ise öğrenilen ESA üzerinde aktarım öğrenmesi ve çok görevli öğrenme yöntemleri kullanılarak başarımların artırılması hedef alınmıştır.

Gömülü hedef tespit algoritmasında, sonuç katmanında (1x1x2) boyutlu bir ESA modeli kullanılarak veriler sınıflandırılmıştır. Böylece farklı dielektrik sabitine sahip cisimler hedef ya da hedef-dışı olarak sınıflandırılmıştır. Toprak cinsi belirleme algoritmasında ise, sonuç katmanında (1x1x3) boyutlu bir ESA modeli kullanılarak toprak türlerine göre sınıflandırılmıştır. Böylece farklı dielektrik sabitine sahip toprak türleri kuru, nemli veya ıslak toprak olarak sınıflandırılmıştır. Bu sınıflandırmalar Çizelge 6'da verilen model ile gerçekleştirilmiştir.


Eğitilen ESA modellerinin başarımlarını arttırmak için aktarım öğrenmesi ve çok görevli öğrenme yöntemleri kullanılmıştır. Üretilen YNR veri kümesinin kısıtlı olması sebebiyle, aktarım öğrenmesi bir ESA modeli eğitilmiştir. Daha önceden çok sayıda veri ile eğitilmiş olan bir modelden alınan katmanların öğrenme oranları sıfırlanarak, sadece yeni eklenen katmanların eğitilmesi sağlanmıştır. Bu modele ilişkin detaylar Çizelge 7'de verilmiştir. Çok görevli öğrenme yöntemi ile ikinci bir görev modelinin, bu durumda toprak türü tespiti olmakta, hedef tespiti görevinin başarımına olumlu

katkısı incelenmiştir. Çok görevli öğrenme için çapraz dikiş yöntemi kullanılmış olup, çapraz dikiş yöntemi içinde bulunan katsayı değişkeni için bir başlangıç değeri atamak gerekmekte, bu değer ulaşılacak noktaya olan uzaklığı ile öğrenim oranı arasında bir orantı bulunmaktadır. Bu nokta ile öğrenme katsayısı arasında bir ödünleşim mevcuttur. Ulaşılacak olan noktaya ne kadar yakınsa öğrenme katsayısı o kadar küçük olabilir. Nokta uzakken eğer öğrenme katsayısı küçük seçilirse yerel minimuma ulaşılacağı için başarımlar oranlarında yükselme elde edilemeyebilir. Bu seçime çıkan başarımlar oranlarına göre eğitim sırasında karar verilmiştir. Bilgisayar işlem gücü dikkate alındığında bu süreleri minimize etmek için öğrenme katsayısını yükselterek daha az deneme ve belli bir hassasiyetle gerekli sonuçlara ulaşılmıştır. Önerilen çapraz dikiş yöntemi için öğrenme oranı denemeler sonucu '100' seçilmiştir.


ESA modellerinin eğitilmesi sırasında ortaya çıkan öğrenme eğrileri Şekil 40'da verilmiştir. Hedef ve toprak türü tespiti için eğitilen ESA'ların öğrenme eğrileri sırasıyla Şekil 40 (a) ve (b)'de, aktarım öğrenmesi uygulanmış öğrenme eğrileri, hedef ve toprak türü tespiti için sırasıyla Şekil 40 (c) ve (d)'de gösterilmiştir. Çok görevli öğrenme eğrisi ise Şekil 40 (e)'de verilmiştir. Öğrenme eğrileri her eğitim tekrarlanması sonucu farklılık göstermektedir. X ekseninde eğitim sırasında öğrenilebilen parametrelerin kaç kere güncellendiğinin sayısı, y ekseninde ise bu güncellemeler sonucu oluşan hedef veya toprak türü tespitinin hata oranları verilmiştir. Şekilde bulunan her grafikte, doğrulama verileri için öğrenme eğrileri mevcuttur. Aktarım öğrenmesi uygulandığında hata oranlarının eğitim ve doğrulama verileri için azaldığı görülmüştür. Hedef tespiti için hata oranı %28'den %25 seviyesine, toprak türü tespiti için ise %20'den %15 seviyesine düşmüştür. Çok görevli öğrenmenin başarımlarını seçilen kaynak görevlere bağlı olduğu için hata oranını grafiklerden bağımsız değerlendirmek gerekmektedir. Seçilen hedef tespit hata oranının ikinci güncellemeden itibaren doğrulama verilerinde azaldığı görülmüştür. İkinci güncelleme sonrası modelin öğrendiği gözlemlendiği için '5' tekrar yeterli bulunmuştur. Kaynak olarak seçilen hedef tespit görevinin başarımlar %77,50 iken, çok görevli öğrenme sonucu başarımlar %79,17 seviyesine çıkmıştır. Farklı seçilen kaynak görevler ile çok görevli öğrenme sonuçları Çizelge 8'de verilmiştir.




(a) Hedef tespit görevi




(b) Toprak türü tespit görevi



(c) Hedef: aktarım öğrenmesi



(d) Toprak: aktarım öğrenmesi



(e) Hedef: çok görevli öğrenme

Şekil 40. Eğitim sonucu öğrenme eğrileri


Oluşturulan ESA modeli temel alınarak buraya kadar anlatılan derin öğrenme geliştirme yöntemleri tez kapsamında tanımlanan veri kümesine uygulanmıştır. Şekil 40'da verilen öğrenme eğrileri doğrulama verilerinin başarımını göstermektedir. Eğitilen ESA modellerinin test verileri üzerindeki başarımları Çizelge 8'de verilmiştir.

Çizelge 8. Deneysel sonuçlar


Görev: Öğrenme Türü	Başarım Oranı (%)	Standart Sapma	Kaynak Görev		α
			Hedef	Toprak	
Hedef: ESA	74,08	0,45	-	-	-
Hedef: Aktarım	77,44	2,18	-	-	-
Toprak: ESA	58,60	2,78	-	-	-
Toprak: Aktarım	76,92	1,98	-	-	-
Yılmaz: ESA	91,50	1,51			
Yılmaz: Aktarım	91,70	1,49			
Hedef: Çok Görevli I	79,17	-	77,50	76,92	0,7682
Hedef: Çok Görevli II	80,00	-	80,00	76,92	1
Hedef: Çok Görevli III	76,67	-	75,00	76,92	0,8705

Çizelgede uygulanan farklı görevlere ve yöntemlere ait bilgiler ve sonuçlar gösterilmiştir. Hedef ve toprak türü tespit görevinde 25 deneme sonucu oluşan başarımların ortalaması ve bunların standart sapmaları gösterilmiştir. Mevcut modele aktarım öğrenmesi uygulanmış ve aynı sonuçlar aktarım öğrenmesi için de verilmiştir. Çok görevli öğrenme için hem hedef hem de toprak türü tespit görevinden kaynak modeller gerekmektedir. Kaynak olarak alınan modellerin başarımları kaynak görev başlığı altında verilmiştir. Çok görevli öğrenme yöntemi, 3 kez farklı kaynak hedef modeli ile tekrarlanmış ve başarımları sırasıyla çok görevli öğrenme I-II ve III satırlarında verilmiştir. Bu başarımlara ulaşırken eğitilen α değeri son sütunda 3 ayrı deneme için verilmiştir. α değeri 0,99 başlangıç değeri ile eğitime başlanmıştır. Farklı kaynak modellere göre eğitilmiş α değerleri sırasıyla 0,7682, 1 ve 0,8705 olarak model tarafından öğrenilmiştir.

Sonuçlardan da anlaşıldığı üzere temel model mimarisini geliştirmek için uygulanan iki farklı yöntemde hedef tespiti konusunda başarımlar artışı sağlamıştır. Bu tez çalışması kapsamında, daha önce bir başka yayında görülmeyen YNR üzerine çok görevli öğrenme yönteminin de seçilen kaynak modele bağımlı olarak başarımlar arttırmaya faydalı olduğu görülmüştür. Ancak bu başarımlar artışı sınırlı düzeydedir. Önerdiğimiz bu çok görevli model için 3 farklı eğitim denemesi sonucu oluşan kaynak hedef modeli kullanılmıştır. Her denemede model farklı bir ESA üretmektedir. Bu sebeple farklı denemeler sonucu oluşan modeller kullanılarak önerilen yöntem test edilmiştir. Bu denemelerin ikisinde (çok görevli öğrenme I ve çok görevli öğrenme III) hedef tespitinde artış gözlemlenmiştir. 2. denemede (çok görevli öğrenme II) ise modelin toprak türü görevi ile yapabileceği daha iyi bir lineer birleşim bulunmamaktadır. Bu sebeple hedef sınıfı görevi tek başına seçilmiştir. Aktarım öğrenmesinin başarımlar artışı daha yüksek oranda olmakla beraber çok görevli öğrenme yöntemi de başarımlar artışına olumlu katkı sağlamıştır. Tez kapsamında üretilen verilerde gömülü bulunan farklı materyallerdeki tellerin yansımalarının birbirine çok yakın olması sebebiyle doğru ve yanlış olarak sınıflandırılan verilerin nelerden etkilendiğini yorumlamak zordur. Çok görevli öğrenme sonucu doğru ve yanlış olarak sınıflandırılan verilerden örnekler sırasıyla Şekil 41 ve Şekil 42’de verilmiştir.




(a) Hedef sınıfında doğru sınıflandırılanlar




(b) Hedef-dışı sınıfında doğru sınıflandırılanlar

Şekil 41. Tez kapsamında üretilen verilerde doğru sınıflandırma örnekleri



(a) Hedef sınıfında yanlış sınıflandırılanlar



(b) Hedef-dışı sınıfında yanlış sınıflandırılanlar


Şekil 42. Tez kapsamında üretilen verilerde yanlış sınıflandırma örnekleri

Aktarım ve çok görevli öğrenme yöntemlerini uygulanması sırasında model mimarilerinin dışında derin öğrenme parametrelerinin sabit tutulmasına dikkat edilmiştir. Bunun sonucunda da sadece geliştirilen yöntemlerin etkisi analiz edilmiştir. Seçilen parametreler Çizelge 9'da verilmiş ve çizelgede evrişim katmanında bulunan ağırlık matrisinin ve sapma değerinin öğrenme katsayıları ve ağırlık güncelleme değerleri verilmiştir. Bu parametreler evrişim katmanında bulunan öğrenilebilen parametrelerin her güncellemede hangi oranlar ile güncelleneceğini göstermektedir.


Çizelge 9. Sabit tutulan parametreler

Evrişim veya tamamen bağlı katmanı	w (Ağırlık matrisi)	b (Sapma Değeri)
Öğrenme katsayıları	1	2
Ağırlık güncelleme (WeightDecay)	1	0

Ayrıca Yılmaz [16]'nın verileri içinde derin öğrenme ve aktarım öğrenmesi uygulanmış ve sonuçları Çizelge 8'de verilmiştir. Bu verilerinden test sonucu doğru olarak sınıflandırılan verilerden örnekler Şekil 43'te ve yanlış olarak sınıflandırılan verilerden örnekler Şekil 44'te verilmiştir.




(a) Hedef sınıfında doğru sınıflandırılanlar




(b) Hedef-dışı sınıfında doğru sınıflandırılanlar

Şekil 43. Yılmaz'ın verilerinde doğru sınıflandırma örnekleri

Doğru olarak sınıflandırılan verilerde hedef sınıfında gömülü telin belirgin olduğu, hedef-dışı sınıfında ise hedef özelliğine sahip bir yansıma bulunmadığı gözükmemektedir.



(a) Hedef sınıfında yanlış sınıflandırılanlar



(b) Hedef-dışı sınıfında yanlış sınıflandırılanlar

Şekil 44. Yılmaz'ın verilerinde yanlış sınıflandırma örnekleri

Şekilde yanlış sınıflandırma yapılan veriler incelendiğinde hedef sınıfındaki yanlış sınıflandırılan verilerde gömülü telin imzasının çok belirgin olmadığı görülmektedir. Hedef-dışı sınıfında ise gömülü bulunan tel dışındaki parazit cisimlerin güçlü yansımaları yüzünden hedef benzeri imzalar oluşturduğu gözükmemektedir. Bu sorunlu görüntüler yanlış sınıflandırmaya sebep olmuştur.

6. SONUÇLAR

Son yıllarda, derin öğrenmenin üstün performans göstermesi ve gömülü cisimlerin tespiti için YNR kullanımının yaygınlaşması, bu alandaki çalışmaların artmasını sağlamıştır. YNR görüntüleriyle hedef tespitin doğru olarak yapılabilmesi özellikle insan hayatını tehdit eden uygulamalarda büyük avantaj sağlarken, gürültü seviyesinde gömülü hedef olarak bulunan cisimler hedef tespiti uygulamalarında tehlikeli sorunlara yol açmaktadır. Gömülü cisimlerin arkaplan, hedef dışı yansıma ve gürültülerden arındırılması, hedef tespitini kolaylaştırmış ve mevcut veri kümesinin faydalı olarak kullanılmasını sağlamıştır. Ön işleme yöntemlerinin gömülü olarak bulunan cisimlerin ayırt edilmesini daha mümkün kıldığı ve literatür taramasında da anlatılan yöntemlerden referansla sınıflandırmaya yardımcı olduğu görülmüştür.

Bölüm 6'da YNR görüntüleri üzerine bu çalışma kapsamında derin öğrenme, aktarım öğrenmesi ve çok görevli öğrenme yöntemleri anlatılmıştır. Bu tez kapsamında, YNR verileri gprMax programı ile üretilmiştir. Bu veriler iki farklı görev modeli için sınıflara ayrılmıştır. İlk görev modeli hedef ve hedef-dışı olarak iki sınıfa ayrılmış ve temel görev modelini oluşturmuştur. Temel görev modeli, hedef tespit görevi olarak adlandırılmıştır. İkinci görev modeli ise toprak türü tespiti görevi olarak isimlendirilmiş ve kuru, nemli ve ıslak toprak olarak üç ayrı sınıfa ayrılmıştır. Bu verilerle 3 evrişim, 3 toparlama ve 1 tamamen bağlı katmana sahip bir ESA eğitilmiştir. Her eğitim sonucu başarımların değerleri farklı çıktığından dolayı her görev için eğitim 25 kere tekrarlanmıştır. Hedef tespit görevi için 25 tekrar denemenin ortalama başarımları %74,08 çıkmıştır. Toprak türü görevi için ise sınıflandırma başarımları %58,60 çıkmıştır. Bir ESA'nın eğitimi için mevcut veri kümesinin boyutu yeterli olmamaktadır. Bu zaafiyeti ortadan kaldırmak amacıyla, önceden eğitilmiş bir model ("matconvnet-vgg-f"), mevcut ESA'ya entegre edilerek aktarım öğrenmesi yapılmış ve hedef tespit görevindeki başarımlar %77,44'e çıkmıştır. Toprak türü görevi için ise başarımlar %76,92 seviyesine çıkmıştır. Aktarım öğrenmesiyle daha önceden çok sayıda veri ile eğitilen bir modelin öznetelik çıkarımının daha başarılı olduğu, hedef ve toprak türü modelimize entegre edilerek görülmüştür. Aktarım öğrenmesi ile iyileşen model başarımlarını yükseltmek için çok görevli öğrenme kullanılmıştır. Hedef tespit görevinin, dielektrik farklılıklardan faydalandığı ve gömülü bulunan cismin materyaline bağlı olarak bazı toprak türlerinde hedef tespitinin zorlaştığı

görülmüştür. Toprak türü görevinin öğrendiği özniteliklerin, hedef tespitiye yardımcı olması amacıyla çok görevli öğrenme yöntemi uygulanmış ve hedef tespit görevinde başarımlar artışı görülmüştür. Bu başarımlar artışı alınan kaynak modellere göre farklılık göstermektedir. 3 farklı denemede; aktarım öğrenmesi sonucu %77,50 olan başarımlar %79,17'ye çıkmış, %80 olan başarımlar aynı kalmış, %75 olan başarımlar ise %76,67'ye çıkmıştır. Çok görevli öğrenmeye girdi oluşturan kaynak modellere göre başarımların değiştiği görülmüştür. Derin öğrenme sonucu, 33 adet veri yanlış olarak sınıflandırılmıştır. Hedef sınıfında 10 adet veri yanlış olarak sınıflandırılmıştır. Aktarım öğrenmesi sonucu, mevcut veri kümesi ile öğrenilemeyen bazı öznitelikler öğrenilmiştir. Bu sayede hedef sınıfındaki yanlış olarak sınıflandırılan 6 adet verinin doğru olarak sınıflandırılması sağlanmıştır. Çok görevli öğrenme yöntemi ile aktarım öğrenmesi sonucu yanlış sınıflandırılan 4 veriden 2'si çok görevli öğrenme ile doğru olarak sınıflandırılmıştır. Ayrıca, Yılmaz'ın verileri ile yapılan testlerde derin öğrenme yönteminde %91,5 başarımlar elde edilmiştir. Aktarım öğrenmesi ile başarımlar oranı %91,7 seviyesine çıkmıştır. Yılmaz'ın verileri için derin öğrenmenin aktarım öğrenmesi kullanılmadan yeterli olduğu söylenebilir.

Uygulanan yöntemlerin başarımlarını ölçebilmek için ESA'da kullandığımız değişken parametreler (filtre boyutları, öğrenme oranları vs.) sabit tutularak sadece bu yöntemlerin etkisi görülmüştür. Toprak türü görev modelinin öğrendikleri hedef sınıfında toprak türü sebebiyle tespiti zorlaşan gömülü cisimlerin tespit edilebilmesine fayda sağlamıştır. Çok görevli öğrenmenin başarımlar artışı sağlayamadığı durumlarda α 'yı '1' olarak belirlemiş ve en iyi başarımların hedef sınıfında olduğunu göstermiştir. Gerçek dünyadaki nesneleri tespit etmek için uygulanan derin öğrenme yöntemlerinin ve bunları geliştirmek için tasarlanmış olan yöntemlerin, YNR verilerinde bulunan gömülü cisimleri tespit etmede de etkili olduğu görülmüştür.

Gelecek çalışmalarda, tez kapsamında anlatılan yöntemlerin gerçek YNR verileri kullanılarak geliştirilmesi ve gerçek bir veri kümesinin getireceği farklılıklar incelenebilir. Bu yöntemlere ek olarak saha ortamında alınacak olan yani elimizde mevcut olmayan bir yeryüzü ortamından birkaç YNR verisinin eğitim verilerimize eklenerek modelimizde iyileştirme yapıp yapmadığı konusu değerlendirilebilir. Bu yöntem literatürde alan uyumlaması olarak geçmektedir.

KAYNAKLAR

- [1] L. P. Leon, J. D. Young, and J. J. Daniels, "Ground Penetrating Radar as a Subsurface Environmental Sensing Tool," *Proceedings IEEE*, vol. 82, no. 12, pp. 1802–1822, **1994**.
- [2] J. N. Wilson, P. Gader, S. Member, W.-H. Lee, H. Frigui, and K. C. Ho, "A Large-Scale Systematic Evaluation of Algorithms Using Ground-Penetrating Radar for Landmine Detection and Discrimination," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 8, pp. 2560–2572, **2007**.
- [3] Q. Zhu and L. M. Collins, "Application of feature extraction methods for landmine detection using the Wichmann/Niitek ground-penetrating radar," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 1, pp. 81–85, **2005**.
- [4] S. E. Yuksel, J. Bolton, and P. D. Gader, "Landmine Detection With Multiple Instance Hidden Markov Models," *IEEE International Workshop on Machine Learning for Signal Processing*, Santander, pp. 1–6, **2012**.
- [5] R. J. Stanley, P. D. Gader, and K. C. Ho, "Feature and decision level sensor fusion of electromagnetic induction and ground penetrating radar sensors for landmine detection with hand-held units," *Information Fusion*, vol. 3, no. 3, pp. 215–223, **2002**.
- [6] S. Vitebskiy and L. Carin, "Resonances of perfectly conducting wires and bodies of revolution buried in a lossy dispersive half-space," *IEEE Transactions Antennas Propagation*, vol. 44, no. 12, pp. 1575–1583, **1996**.
- [7] M. Dogan, S. Gumus, and G. Turhan-Sayan, "Detection of conducting and dielectric objects buried under a layer of asphalt or concrete using simulated ground penetrating radar signals," in *2017 International Conference on Electromagnetics in Advanced Applications (ICEAA)*, pp. 1535–1538, **2017**.
- [8] B. Baydar, G. B. Akar, S. E. Yüksel, and S. Öztürk, "Fusion of KLMS and blob based pre-screener for buried landmine detection using ground penetrating radar," *SPIE Defence and Security*, Baltimore, USA vol. 9823, p. 98231D–9823–7, **2016**.
- [9] E. Pasolli, F. Melgani, and M. Donelli, "Automatic analysis of GPR images: A

- pattern-recognition approach,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 7, pp. 2206–2217, **2009**.
- [10] K. C. Ho, L. Carin, P. D. Gader, and J. N. Wilson, “An Investigation of Using the Spectral Characteristics From Ground Penetrating Radar for Landmine / Clutter Discrimination,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 46, no. 4, pp. 1177–1191, **2008**.
- [11] J. N. Wilson, P. Gader, W.-H. Lee, H. Frigui, and K. C. Ho, “A Large-Scale Systematic Evaluation of Algorithms Using Ground-Penetrating Radar for Landmine Detection and Discrimination,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 8, pp. 2560–2572, **2007**.
- [12] P. D. Gader, M. Mystkowski, and Y. Z. Y. Zhao, “Landmine detection with ground penetrating radar using hidden Markov models,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 6, pp. 1231–1244, **2001**.
- [13] H. Frigui and P. Gader, “Detection and discrimination of land mines in ground-penetrating radar based on edge histogram descriptors and a possibilistic K-nearest neighbor classifier,” *IEEE Transactions on Fuzzy Systems*, vol. 17, no. 1, pp. 185–199, **2009**.
- [14] D. Potin, P. Vanheeghe, E. Duflos, and M. Davy, “An abrupt change detection algorithm for buried landmines localization,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, no. 2, pp. 260–272, **2006**.
- [15] D. S. Armağan Şahinkaya, S. A. Bechteler, M. Ertuğrul, and A. S. Türk, “Dielektrik Cisimlerin Tespiti için Geniş Frekans Bantlı Yere Nüfuz Eden Radar Tasarımı,” **2004**.
- [16] U. Yılmaz, “*Buried Wire Detection Using Ground Penetrating Radars*, ” Masters Thesis, Middle East Technical University, Ankara, Turkey, **2017**.
- [17] Nagashree R. N. and Aswini N., “Approaches of Buried Object Detection Technology,” *International Journal of Wireless and Microwave Technology*, vol. 4, no. 2, pp. 31–37, **2014**.
- [18] D. J. Daniels, “Surface-penetrating radar,” *Electronic Communication Engineering Journal*, vol. 8, no. 4, pp. 165–182, **1996**.
- [19] F. Abujarad, G. Nadim, and A. Omar, “Clutter reduction and detection of

- landmine objects in ground penetrating radar data using singular value decomposition (SVD)," in *Proceedings of the 3rd International Workshop on Advanced Ground Penetrating Radar, IWAGPR* vol.2005, pp. 37–41, **2005**.
- [20] F. Abujarad, "Ground Penetrating Radar Signal Processing For Landmine Detection," PhD Thesis, **2007**.
- [21] "MALA Ground Penetrating Radar, Professional Explorer, [online] Available at: <http://www.malagpr.com.au/professional-explorer.html> [Accessed 9 Mar. 2018]," **2018**.
- [22] L. Robledo, M. Carrasco, and D. Mery, "A Survey of Land Mine Detection Technology," *International Journal of Remote Sensing*, vol. 30, no. 9, pp. 2399–2410, **2009**.
- [23] J. E. Piper, K. W. Commander, E. I. Thorsos, and K. L. Williams, "Detection of Buried Targets Using a Synthetic Aperture Sonar," vol. 27, no. 3, pp. 495–504, **2002**.
- [24] A. N. Garroway *et al.*, "Remote sensing by nuclear quadrupole resonance," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 6, pp. 1108–1118, **2001**.
- [25] A. G. Yarovoy, P. Van Genderen, and L. P. Ligthart, "Ground penetrating impulse radar for landmine detection," *International conference on ground penetrating radar(8 ; Gold Coast, Australia ; 2000-05-23)*. pp. 856–860, **2000**.
- [26] T. W. Miller, B. Borchers, J. M. H. Hendrickx, S.-H. Hong, L. W. Dekker, and C. J. Ritsema, "Effects of soil physical properties on GPR for landmine detection," *Fifth International Symposium Technology Mine Problem*, p. 10 p., **2002**.
- [27] N. F. & S. W. R. Chignell, H. Dabis, "The radar requirements for detecting anti-personnel mines, " *Proceedings SPIE 4084, Eighth International Conference on Ground Penetrating Radar*, vol. 4084, no. 1, pp. 861–866, **2000**.
- [28] L. R. Rabiner, "A tutorial on hidden Markov models and selected applications in speech recognition," *Proceedings IEEE*, vol. 77, no. 2, pp. 257–286, **1989**.
- [29] L. E. Baum, T. Petrie, G. Soules, and N. Weiss, "A Maximization Technique

Occurring in the Statistical Analysis of Probabilistic Functions of Markov Chains,” *The Annals of Mathematical Statistics.*, vol. 41, no. 1, pp. 164–171, **1970**.

- [30] S. Lameri, F. Lombardi, P. Bestagini, M. Lualdi, and S. Tubaro, “Landmine Detection from GPR Data Using Convolutional Neural Networks,” *25th European Signal Processings Conference*, pp. 538–542, **2017**.
- [31] 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*, pp. 1–6, **2013**.
- [32] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” *International Conference on Learning Representations*, pp. 1–14, **2015**.
- [33] M. Long and J. Wang, “Learning Multiple Tasks with Deep Relationship Networks,” *arXiv:1506.02117*, pp. 1–9, **2015**.
- [34] Y. U. Lu San Diego, A. Kumar, S. Zhai, Y. Cheng, T. Javidi, and R. Feris, “Fully-adaptive Feature Sharing in Multi-Task Networks with Applications in Person Attribute Classification,” *arXiv:1611.05377*, **2016**.
- [35] I. Misra, A. Shrivastava, A. Gupta, and M. Hebert, “Cross-stitch Networks for Multi-task Learning,” *arXiv:1604.03539*, **2016**.
- [36] S. E. Yuksel, J. Bolton, and P. Gader, “Multiple-Instance Hidden Markov Models With Applications to Landmine Detection,” *IEEE Transactions on Geoscience and Remote Sensing* vol. 53, no. 12, pp. 6766–6775, **2015**.
- [37] S. E. Yuksel and P. D. 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**.
- [38] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in the brain.,” *Psychological Review*, vol. 65, no. 6, pp. 386–408, **1958**.
- [39] G. Sperl *et al.*, “Person Classification with Convolutional Neural Networks,”

MSc Thesis, **2016**.

- [40] Y. LeCun *et al.*, “Backpropagation Applied to Handwritten Zip Code Recognition,” *Neural Computation*, vol. 1, no. 4, pp. 541–551, **1989**.
- [41] A. Vedaldi and K. Lenc, “MatConvNet Convolutional Neural Networks for MATLAB, *Proceeding. of the ACM International Conference on Multimedia*” **2016**.
- [42] A. Karpathy, “Convolutional Neural Networks for Visual Recognition,” *Stanford CS class CS231n notes*, [Online]. Available: <http://cs231n.github.io/transfer-learning/>. [Accessed: 01-Oct-2017], **2017**.
- [43] E. Aydin and S. E. Yuksel, “Buried target detection with ground penetrating radar using deep learning method,” in *2017 25th Signal Processing and Communications Applications Conference (SIU)*, pp. 1–4, **2017**.
- [44] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, “How transferable are features in deep neural networks?,” *Advances in Neural Information Processing Systems* 27, pp 3320-3328, **2014**.
- [45] J. Baxter, “A Model of Inductive Bias Learning,” *Journal of Artificial Intelligence Research*, vol. 12, p. 149, **2000**.
- [46] R. Caruana, “Multitask Learning,” *Machine Learning*, vol. 28, no. 1, pp. 41–75, **1997**.
- [47] R. Collobert and J. Weston, “A unified architecture for natural language processing,” in *Proceedings of the 25th international conference on Machine learning - ICML '08*, pp. 160–167, **2008**.
- [48] L. Deng, G. Hinton, and B. Kingsbury, “New types of deep neural network learning for speech recognition and related applications: an overview,” in *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 8599–8603, **2013**.
- [49] R. Girshick, “Fast R-CNN,” in *Proceedings of the IEEE International Conference on Computer Vision*, vol. 2015 International, pp. 1440–1448, **2015**.
- [50] S. Ruder, “An Overview of Multi-Task Learning in Deep Neural Networks”,

arXiv preprint arXiv:1706.05098, **2017**.

- [51] J. Baxter, "A Bayesian/information theoretic model of learning to learn via multiple task sampling," *Machine Learning*, vol. 28, pp. 7–39, **1997**.
- [52] C. Warren, A. Giannopoulos, and I. Giannakis, "gprMax: Open source software to simulate electromagnetic wave propagation for Ground Penetrating Radar," *Computer Physics Communications*, vol. 209, pp. 163–170, **2016**.
- [53] K. S. Yee, "Numerical solution of initial boundary value problems involving Maxwell's equations in isotropic media," *IEEE Transactions on Antennas Propagations*, vol. 14, no. 3, pp. 302–307, **1966**.
- [54] R. J. Kunz, K. S., & Luebbers, *The finite difference time domain method for electromagnetics*. CRC press, **1993**.
- [55] A. Giannopoulos, "The Investigation of Transmission-Line Matrix and Finite-Difference Time-Domain Methods for the Forward Problem of Ground Probing Radar By Antonios Giannopoulos," *PhD thesis*, pp. 0–13, March **1997**.
- [56] D. Huston, P. Fuhr, K. Maser, and W. Weedon, "Nondestructive Testing of Reinforced Concrete Bridges Using Radar Imaging Techniques," *The New England Transportation Consortium Report*, **2002**.
- [57] A. P. Annan, "Ground Penetrating Radar Principles, Procedure & Applications," *Ground Penetrating Radar Theory Applications*, **2003**.
- [58] H. M. Jol, *Ground penetrating radar: theory and applications*. **2009**.
- [59] L. B. Conyers, *Ground-penetrating Radar for Archaeology*. Walnut Creek, California; Altamira Press, **2004**.
- [60] "The HDF Group. Hierarchical Data Format, version 5," [Online]. Available: <https://www.hdfgroup.org/HDF5/>. [Accessed: 25-Nov-2017], **1997**.
- [61] J. Ahrens, B. Geveci, and C. Law, "ParaView: An end-user tool for large-data visualization," in *Visualization Handbook*, pp. 717–731, **2005**.
- [62] U. Ayachit, "The ParaView Guide: A Parallel Visualization Application," *Kitware*. **2015**.
- [63] D. Establishment, R. Dehradun, and C. Engineering, "Study of Background

- Subtraction for Ground Penetrating Radar,” *2015 National Conference on Recent Advances in Electronics & Computer Engineering (RAECE)*, Roorkee, pp. 101–105, **2015**.
- [64] S. Tjora, E. Eide, and L. Lundheim, “Evaluation of Methods for Ground Bounce Removal in GPR Utility Mapping,” *Tenth International Conference on Ground Penetrating Radar*, p. 4, **2004**.
- [65] L. Liu, P. Liu, E. A. Clancy, E. Scheme, K. B. Englehart, and U. S. A. Ma, “Signal Whitening Preprocessing for Improved Classification Accuracies in Myoelectric Control,” *2011 IEEE 37th Annual Northeast Bioengineering Conference (NEBEC)*, Troy, NY, pp. 3–4, **2011**.
- [66] P. Gader, W. H. Lee, and J. N. Wilson, “Detecting landmines with ground-penetrating radar using feature-based rules, order statistics, and adaptive whitening,” *IEEE Transactions on Geoscience Remote Sensing*, vol. 42, no. 11, pp. 2522–2534, **2004**.
- [67] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient Based Learning Applied to Document Recognition,” *Proceedings IEEE*, vol. 86, no. 11, pp. 2278–2324, **1998**.
- [68] N. Mousavi, H. Siqueira, P. Barros, B. Fernandes, and S. Wermter, “Understanding how deep neural networks learn face expressions,” in *Proceedings of the International Joint Conference on Neural Networks*, vol. 2016–October, pp. 227–234, **2016**.
- [69] M. D. Zeiler and R. Fergus, “Visualizing and understanding convolutional networks,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 8689 LNCS, no. Part 1, pp. 818–833, **2014**.

EKLER

EK-1

SIU 2017 Bildirisi

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 öznelilikleri ve bu öznelilikleri 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 öznelilikler öğrendiği incelenmiştir. Bildiride sunulan ilk sonuçlar, derin öğrenmenin öznelilik 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. Giriş

YNR, yüksek frekanslı elektromanyetik (EM) dalgalar kullanarak yeraltı haritalaması için kullanılan bir araçtır. Gömülü nesneleri 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 nesnelerin 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 problemidir [2]. Gömülü nesnelerin 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 öznelilik çıkarmaktadır [3]. Fakat öznelilik çıkarımı alan bilgisi gerektirmekte ve vakit almaktadır [4]. Bu sebeple, derin öğrenme algoritmalarının öznelilik çıkarımı için özel bir bilgi gerektirmemesi ve öznelilik 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 çıktıların 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 SİNİR 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 güncellenmiş hali (3)'te verilmiştir. Denklemde bulunan P_h^* ve P_w^* sırasıyla sütuna ve satıra '0' ekleme S_h ve S_w ise dikey ve yatay yöndeki kaydırılmaları 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 işlemden 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 denklem aktivasyon fonksiyonlarından olan "Düzeltilmiş Doğrusal Birimi" hesaplar.

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

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.

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

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




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 dalgalara 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 1'deki bir model önerilmiştir.


TABLO I. MODEL MIMARISI

Katman	Evrşim	Toparlama	Evrşim	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 1'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 silindireler 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 başarımları oranı %100 olarak çıkmıştır.

E. Evrişimsel Sinir Ağı Ne Öğrendi?

Evrişimsel Sinir Ağı'nın ne öğrendiğini yorumlamak için birkaç yöntem bulunmaktadır. Geliştirilen bu yöntemler, öznetelikleri 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 toparlama katmanları arasında bulunan grup düzgeleme ve aktivasyon katmanları gösterilmemiştir. Özellikle toparlama katmanının sadece boyut küçültme odaklı olduğu düşünüldüğünde aktivasyon katmanında negatif değerlerin 0'a çekilmesi hedefin arka planı ayırılmasına yardımcı olmuştur. Şekil 4'teki ilk toparlama 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 toparlama katmanında da beyaz piksellerin hedefin olduğu bölgeye yoğunlaştığını ve daha önce bahsedilen hiperbol şeklinin korunmaya çalışıldığını görebiliriz. Son aktivasyon işlemi sonrası toparlama 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 öznetelikler yorumlanmıştır. Derin öğrenme yöntemlerinde yüksek başarımları oranı önemli olmakla birlikte burada öznetelik 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.

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı : Enver AYDIN
Doğum Yeri : İSTANBUL
Medeni Hali : Bekar
E-posta : enver_1991@hotmail.com
Adresi : Serhat Mah. 1292. Sk. Botanik-2 Sitesi D/10
Yenimahalle/ ANKARA

Eğitim

Lise : Pertevniyal Lisesi
Lisans : Hacettepe Üniversitesi, Elektrik ve Elektronik Mühendisliği

Yabancı Dil ve Düzeyi

İngilizce : İyi

İş Deneyimi

Aselsan A.Ş., Savunma Sistem Teknolojileri Sektör Başkanlığı, Güç ve Kontrol Sistemleri Elektronik Tasarım Müdürlüğü (2015-Devam Ediyor)

Deneyim Alanları

Gömülü sistemler, gömülü yazılımlar, görüntü işleme, mikrodenetleyiciler, güç kartı tasarımı, güç giriş koruma devreleri

Tezden Üretilmiş Projeler ve Bütçesi

-

Tezden Üretilmiş Yayınlar

E.Aydın and S. E.Yüksel, " Buried Target Detection with Ground Penetrating Radar Using Deep Learning Method," 2017 25th Signal Processing and Communication Applications Conference (SIU), Antalya 2017, pp. 1-4.

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

25th Signal Processing and Communication Applications Conference (SIU), Antalya 2017



HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 12/03/2018

Tez Başlığı / Konusu: Yere Nüfuz Eden Radar Verilerinde Tel Tespiti İçin Aktarım ve Çok Görevli Öğrenme Yöntemleri.

Yukarıda başlığı/konusu gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç kısımlarından oluşan toplam 75 sayfalık kısmına ilişkin, 12/03/2018 tarihinde ~~sahem~~/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 1'tür.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar dâhil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Tarih ve İmza

12/03/2018

Adı Soyadı: Enver AYDIN

Öğrenci No: N14125231

Anabilim Dalı: Elektrik ve Elektronik Mühendisliği

Programı: Yüksek Lisans

Statüsü: ☒ Y.Lisans ☐ Doktora ☐ Bütünleşik Dr.

DANIŞMAN ONAYI

UYGUNDUR.

Yrd.Doc.Dr. Seriha Eser Yüksel

(Unvan, Ad Soyad, İmza)