

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
SAVUNMA TEKNOLOJİLERİ VE SİSTEMLERİ ANABİLİM DALI
SAVUNMA ELEKTRONİĐİ VE YAZILIMI TEZLİ YÜKSEK LİSANS
PROGRAMI**

**YERE NÜFUZ EDEN RADAR GÖRÜNTÜLERİNDE DERİN
ÖĐRENME İLE ASKERİ ANLAMDA TEHDİT OLUŐTURABİLECEK
GÖMÜLÜ ALANLARIN TESPİTİ**

HAZIRLAYAN

NIHAT ÖZSOY

YÜKSEK LİSANS TEZİ

ANKARA - 2021

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
SAVUNMA TEKNOLOJİLERİ VE SİSTEMLERİ ANABİLİM DALI
SAVUNMA ELEKTRONİĐİ VE YAZILIMI TEZLİ YÜKSEK LİSANS
PROGRAMI**

**YERE NÜFUZ EDEN RADAR GÖRÜNTÜLERİNDE DERİN
ÖĐRENME İLE ASKERİ ANLAMDA TEHDİT OLUŐTURABİLECEK
GÖMÜLÜ ALANLARIN TESPİTİ**

HAZIRLAYAN

NİHAT ÖZSOY

YÜKSEK LİSANS TEZİ

**TEZ DANIŐMANI
DR. ÖĐR. ÜYESİ MEHMET DİKMEN**

ANKARA - 2021

BAŞKENT ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Savunma Teknolojileri ve Sistemleri Anabilim Dalı Savunma Elektronik ve Yazılım Tezli Yüksek Lisans Programı çerçevesinde Nihat ÖZSOY tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans olarak kabul edilmiştir.

Tez Savunma Tarihi: 26 / 05 / 2021

Tez Adı: Yere Nüfuz Eden Radar Görüntülerinde Derin Öğrenme İle Askeri Anlamda Tehdit Oluşturabilecek Gömülü Alanların Tespiti

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)

İmza

Dr. Öğr. Üyesi Mehmet DİKMEN (Danışman)

.....

Doç. Dr. Mehmet Serdar GÜZEL (Üye)

.....

Dr. Öğr. Üyesi Selda GÜNEY (Üye)

.....

ONAY

Prof. Dr. Faruk ELALDI

Fen Bilimleri Enstitüsü Müdürü

Tarih: ... / ... /



**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS / DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih:

Öğrencinin Adı, Soyadı : Nihat ÖZSOY

Öğrencinin Numarası : 21720219

Anabilim Dalı : Savunma Teknolojileri ve Sistemleri ABD

Programı : Savunma Elektronikleri ve Yazılımı Tezli Yüksek Lisans Programı

Danışman Unvanı/Adı, Soyadı : Dr. Öğretim Üyesi Mehmet DİKMEN

Tez Başlığı : Yere Nüfuz Eden Radar Görüntülerinde Derin Öğrenme İle Askeri Anlamda Tehdit Oluşturabilecek Gömülü Alanların Tespiti

Yukarıda başlığı belirtilen Yüksek Lisans/Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 72 sayfalık kısmına ilişkin, 06/06/2021 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 0'dır. Uygulanan filtrelemeler:

Kaynakça hariç

Alıntılar hariç

Beş (5) kelimedenden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esasları”nı inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına 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.

Öğrenci İmzası :

ONAY

Tarih:

Öğrenci Danışmanı Unvan , Adı, Soyadı, İmza:

Dr.Öğr. Üyesi Mehmet DİKMEN

TEŐEKKÖRLER

Yüksek lisans eğitimin boyunca ve bu tezin hazırlanması süresince zamanını, tecrübesini ve bilgilerini paylaşarak bu tezin oluşturulmasında büyük emeđi geçen tez danışmanım Dr.Öğr. Üyesi Mehmet DİKMEN'e, desteđini her zaman yanımda hissettiđim aileme teşekkürlerimi sunarım. Çevremdeki sevgi dolu ailemin ve arkadaşlarımin desteđi olmasaydı, bu yüksek lisans tezi için harcanan tüm çabalar yeterli olmazdı. Bu nedenle annem ve babam Enise ve Nazif ÖZSOY'a, kardeşlerim Hafize ve Burak ÖZSOY'a teşekkür ederim. Tez çalışmasında yardımlarını esirgemeyen arkadaşım Öğr. Grv. Ahmet ELBİR'e ayrıca teşekkür ederim. Son olarak, değerli nişanlım Buket YILMAZ'a, beni her gün dünyanın en şanslı adamı gibi hissettirdiđi için teşekkür ederim. Bana ve yeteneklerime her zaman inandınız ve yapabileceklerimden asla şüphe etmediniz. Desteđiniz ve fedakarlıđınız olmadan bu çalışmayı tamamlayamazdım.

Haziran 2021

Nihat ÖZSOY

ÖZET

Nihat ÖZSOY

YERE NÜFUZ EDEN RADAR GÖRÜNTÜLERİNDE DERİN ÖĞRENME İLE ASKERİ ANLAMDA TEHDİT OLUŞTURABİLECEK GÖMÜLÜ ALANLARIN TESPİTİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Savunma Teknolojileri ve Sistemleri Anabilim Dalı

2021

Gömülü kara mayınlarının ve el yapımı patlayıcıların varlığı, özellikle ordular için dünyanın birçok bölgesinde ciddi bir tehdittir. Gömülü nesnelere tespit etmek ve sınıflandırmak için literatürde çeşitli teknikler önerilmiş ve geliştirilmiş olmasına rağmen, yüksek doğruluk performansı sağlayan otomatik ve kullanımı kolay sistemler hala araştırılmaktadır. Evrimsel Sinir Ağları (ESA) yakın zamanda görüntü sınıflandırma ve nesne algılama görevlerinde olağanüstü performans göstermiştir. Büyük miktarda veri ve donanım teknolojisindeki iyileşme, ESA'ndaki araştırmayı hızlandırmış ve son zamanlarda derin ESA mimarileri tanıtılmıştır. Dahası, yere nüfuz eden radar (YNR) yardımıyla gömülü nesnelere tespit için ESA da kullanılabilir hale gelmiştir. YNR, gömülü tehdit tespiti için en çok çalışılan yöntemlerden biridir. Bu tez çalışmasında kullanılan veriler araca monteli YNR sistemi kullanılarak toplanmıştır. Deneysel veri seti 8664 pozitif ve 8596 negatif YNR görüntüsünden oluşmaktadır. Bu tez çalışması, YNR verilerinde gömülü tehditlerin tespiti için yeni bir ESA mimarisi önermektedir. Önerilen ESA ile gerçekleştirilen sınıflandırmada 10 kat çapraz doğrulama kullanılmış ve ortalama yüzde 98 genel doğruluk elde edilmiştir. Önerilen ESA mimarisi literatürde bilinen farklı ESA mimarileri ile de kıyaslanmıştır. Ayrıca, filtre sayısı, optimizasyon çeşitleri, dropout oranı ve auto encoder downsampling gibi farklı parametreler ile de test edilerek önerilen mimarinin avantaj ve dezavantajları ortaya konulmuştur.

ANAHTAR KELİMELELER: ESA, YNR, Mayın Tespiti, Gömülü Mayın Tespiti

ABSTRACT

Nihat ÖZSOY

DETECTION OF BURIED AREAS THAT CAN CAUSE MILITARY THREAT WITH DEEP LEARNING IN GROUND PENETRATING RADAR IMAGES

Baskent University Institute of Science & Engineering

The Department of Defence Technologies and Systems

2021

The presence of buried landmines and improvised explosive devices is a serious threat in many areas around the world, especially for armies. Despite the fact that various techniques have been proposed and improved in the literature to detect and classify buried objects, automatic and easy to use systems providing high accuracy performance are still under research. Convolutional Neural Networks (CNNs) have recently shown outstanding performance on image classification and object detection tasks. The availability of large amount of data and improvement in hardware technology has accelerated the research in CNN, and in the recent times deep CNN architectures have been introduced. Moreover, CNNs are also used for the detection of buried objects with the help of ground penetrating radar (GPR). GPR is one of the most studied modalities for buried threat detection. The data used in this thesis was collected using a vehicle mounted GPR system. The experimental data set comprised of 8664 positive and 8596 negative GPR images. This study proposes a novel CNN architecture for the detection of buried threats in GPR data. In the classification performed with the proposed CNN, 10-fold cross-validation was used and an average overall accuracy of 98 percent was obtained. The proposed CNN architecture has also been compared with different CNN architectures known in the literature. In addition, the advantages and disadvantages of the proposed architecture are revealed by experimenting the architectural filter sizes, optimization types, dropout rates and auto encoder downsampling features.

KEY WORDS: CNN, GPR, Mine Detection, image recognition, Buried Object Detection

İÇİNDEKİLER

	Sayfa
TEŞEKKÜRLER	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER	iv
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
SİMGELER VE KISALTMALAR LİSTESİ	8
1.GİRİŞ	9
1.1 Problem Tanımı	9
1.2 Genel Bakış	11
1.2.1 Yere Nüfuz Eden Radar Nedir?	11
1.2.2 Mayın ve El Yapımı Patlayıcı Nedir?	15
1.2.3 Mayın ve EYP tespiti teknikleri	16
1.2.4 Alandaki ilgili Diğer Çalışmalar	22
1.2.4 Çalışmaya İten Motivasyon	25
1.3 Hedefler	25
2. Yere Nüfuz Eden Radar	26
2.1 Veri Toplama	26
2.2. Kullanılan YNR Veri Seti	27
2.2.1 YNR Görüntü Çeşitleri	28
2.2.2 YNR Verisine Uygulanan İşlemler (Anlamlandırma)	30
2.3 Daha önce YNR ile Yapılan Mayın EYP Tespit Yöntemleri	30
3. EVRİŞİMSEL SİNİR AĞLARI	32

3.1 Bileşenler ve Temel Kavramlar	32
3.2 Temel Prensipler ve Özellikleri	35
3.3 Kullanılan Mimariler	36
3.4 Kullanılan Kütüphaneler	39
4. KULLANILAN YÖNTEM	41
4.1 Önerilen Mimarinin özellikleri	41
4.2 Eğitimin Detayları	43
4.3 En Uygun Parametrelerin Bulunması	53
4.3.1 Filtre Sayısı Kıyaslanması	54
4.3.2 Dropout Oranlarının Kıyaslanması	55
4.3.3 Optimizasyon Çeşidine Göre Kıyaslanması	56
4.3.4 AutoEncoder-Downsampling Kıyaslanması	56
4.4 Sonuçlar	57
4.5 Çalışmanın Katkısı	59
4.6 Geleceğe Yönelik Çalışmalar ve Sonuç	60
KAYNAKLAR	63

TABLO LİSTESİ

	Sayfa
Tablo 1 1900'den itibaren YNR araştırmasının tarihçesi.....	14
Tablo 2 Çeşitli parametrelere göre ve sunulan mimariye göre ortalama eğitim süresi.....	44
Tablo 3 Sunulan mimarinin K-Fold performansı.....	45
Tablo 4 Sunulan mimarinin (Dropout 0.25- 0.40- 0.50 oranlı) K-Fold performansı.....	46
Tablo 5 Sunulan mimarinin (Dropout 0.25- 0.50- 0.50 oranlı) K-Fold performansı.....	47
Tablo 6 Sunulan mimarinin (Filtre Sayıları 16-64) K-Fold performansı.....	48
Tablo 7 Sunulan mimarinin (Filtre Sayıları 32-64) K-Fold performansı.....	48
Tablo 8 AlexNet mimarisinin K-Fold performansı.....	49
Tablo 9 ResNet mimarisinin K-Fold performansı.....	50
Tablo 10 VGG16 mimarisinin K-Fold performansı.....	50
Tablo 11 Sunulan mimarinin (RMSProp optimizasyon) K-Fold performansı.....	51
Tablo 12 Sunulan mimarinin (SGD optimizasyon) K-Fold performansı.....	52
Tablo 13 Autoencoder Downsampling K-Fold performansı.....	52
Tablo 14 Confusion matrix.....	53
Tablo 15 Farklı filtre sayılarının performans değerlerinin kıyaslanması.....	55
Tablo 16 Dropout oranlarının performans değerlerinin kıyaslanması.....	56
Tablo 17 Optimizasyonların performans değerlerinin kıyaslanması.....	56
Tablo 18 Autoencoder-Downsampling performans değerleri ile kıyaslanması.....	57
Tablo 19 En uygun parametreler ile oluşturulan mimarinin diğer yöntemler ile kıyaslanması	58

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1 Yere nüfuz eden radar işleyiş şeması.....	12
Şekil 2 Kara mayını örnekleri.....	15
Şekil 3 A / S kara mayını tespitinde kullanılan ana bileşenlerin basit diyagramı sistemi.....	17
Şekil 4 Akustik kara mayını görüntülerinden örnekler.....	18
Şekil 5 Geleneksel mayın yaklaşım tespit adımları.....	19
Şekil 6 Pozitif görüntü örnekleri.....	27
Şekil 7 Negatif görüntü örnekleri.....	28
Şekil 8 Hiperbol pozisyonları.....	28
Şekil 9 YNR A- tarama görüntüsü.....	28
Şekil 10 YNR B- tarama görüntüsü.....	29
Şekil 11 YNR C- tarama görüntüsü.....	29
Şekil 12 ESA mimarisi bileşenleri.....	32
Şekil 13 2D evrişim işlemi.....	33
Şekil 14 Maks havuzlama işlemi.....	34
Şekil 15 Örnek bir ESA mimarisi.....	35
Şekil 16 Yansımaları içeren radargramların tespiti.....	36
Şekil 17 Yedi farklı kategoriye gösteren derin ESA mimarilerinin taksonomisi.....	38
Şekil 18 Önerilen ESA mimarisi.....	42
Şekil 19 Mayın EYP tespiti için kullanılan 10lu çapraz doğrulama prosedürünün şekli.....	43
Şekil 20 Dropout sinir ağı modeli.....	55

SİMGELER VE KISALTMALAR LİSTESİ

ESA	Evrişimsel Sinir Ağı
YNR	Yere Nüfuz Eden Radar
CNN	Convolutional Neural Network
GPR	Ground Penetrating Radar
GCS	Ground Control System
EYP	El Yapımı Patlayıcı
AT	Anti-Tank
AP	Anti-Personel
FLIR	İleriye Bakan Kızılötesi
TNA	Termal Nötron Aktivasyonu
QR	Dörtlü Rezonans
A/S	Akustik Sismik Teknik
EET	Elektriksel Empedans Tomografisi
GTA	Gömülü Tehdit Algılama
EM	Elektromanyetik Dalga
MUSIC	Çoklu Sinyal Sınıflandırması
ESPRIT	Dönel Değişmezlik Teknikleri ile Sinyal Parametrelerinin Tahmini
root-MUSIC	MUSIC'in Polinom Versiyonları
FFT	Hızlı Fourier dönüşümünü
K-NN	K – En Yakın Komşular
HMM	Gizli Markov Modelleri
ReLU	Rectified Linear Unit
MLP	Çok Katmanlı Perceptron
GEOM	Geometrik Özellik FOWA ROCA Algoritması
EYS	Enerji Yoğunluğu Spektrumu
KHT	Kenar Histogram Tanımlayıcı
MOUSİ	Maksimum Olabilirlik Uyarlanabilir Sinir Sistemi
ANFIS	Uyarlamalı Nöro-Bulanık Çıkarsama Sistemidir
FIS	Bulanık Çıkarım Sistemi
ÇYBS	Çok Ölçekli Yönlü Bilateral Süzgeç
KS	Komşuluk süzgeci
FDTD	Zaman Bölgesinde Sonlu Farklar
MBA	Morfolojik Bileşen Analizi
HUK	Hiyerarşik Uzman Karışımı
TP	True Positives
TN	True Negatives
FN	False Negatives
FP	False Positives

9.GİRİŞ

1.1 Problem Tanımı

Kara mayınları ve el yapımı patlayıcılar (EYP), antipersonel mayınlar, diğer mayın türleri, misket bombası kalıntıları ve diğer EYPler, siviller ve ordular için ciddi ve devam eden bir tehdidi temsil etmektedir. Kara mayınlarından kaynaklanan zayıat rakamları kesin olarak bilinmemekle birlikte 2019'da en az 5.554 mayın / EYP zayıatı kaydedildi: 2.170 kişi öldü, 3.357 kişi yaralandı ve 27 yaralı için hayatta kalma durumu bilinmiyor. 2019 toplamı, 2018'de kaydedilen 6,897 mayın / EYP zayıatından bir düşüş göstermesine rağmen, 2013'te belirlenen en düşük yıllık 3,457 zayıattan % 60 daha yüksektir. 2019'da mayın ve EYPden kaynaklı çocuk kaybı, yaşının bilindiği tüm sivil kayıpların % 43'ünü oluşturmaktadır. Afganistan, Bosnahersek, Kamboçya, Hırvatistan, Etiyopya, Irak, Tayland, Türkiye, Ukrayna ve Yemen olmak üzere bu 10 devlette kitlesel antipersonel mayın kirliliğinin 100 km² var olduğuna inanılmaktadır [1]. Bu nedenle, kara mayınlarının ve el yapımı patlayıcıların (EYP) tespiti, ordular ve ülkeler için büyük öneme sahiptir. Yere nüfuz eden radar, gömülü tehdit tespiti için en iyi çalışılmış ve başarılı yöntemlerden biridir [2]. Gömülü tehditlerin otomatik tespiti, YNR'nin hem metal hem de metal olmayan yeraltı nesnelere tespit etme kabiliyeti nedeniyle aktif bir araştırma alanıdır. Bu sistemlerin oldukça başarılı olduğu gösterilmesine rağmen, tespit problemi hala zor bir problemdir. Bileşik tespit sorunları, çok çeşitli çevresel koşullar ve kara mayını imzalarıdır. Bu çeşitlilik göz önüne alındığında, çok yönlü algılama algoritmaları istenmektedir.

YNR, mayın tespiti de dahil olmak üzere birçok sivil ve askeri uygulamada kullanılan, müdahaleci olmayan ve tahribatsız bir algılama yöntemidir [3]. Yere nüfuz eden radar cisimlerin tespiti, sınıflandırılması uygulamalarında sık kullanılan tespit aracıdır. YNR, hedeflerin topraktaki elektriksel iletkenlik farklılıklarından kaynaklı bir sonuç oluşturmaktadır. Aynı şekilde sahip olup farklı materyallerden oluşan cisimlerin

sınıflandırılması, özellikle benzer elektriksel iletkenliklerde YNR kullanan personel için zor bir problemdir. Hedef dışındaki cisimlerden kaynaklı yansımalar, yani gürültüler, bu zorluğun katlanarak artmasına neden olmaktadır. Kara mayınlarının ve EYP'lerin tespiti için, YNR sistemi gömülü hedefler tarafından sergilenen elektriksel homojensizlikleri algılamak için elektromanyetik dalgaları iletmektedir.

Hedef yansımalara ek olarak, anten dizisi tarafından yer yüzeyinden radar dönüşleri ve yüzey altı toprak katmanları da alınır [4]. YNR verilerindeki hedef nesnelere tanımlama geliştirmek için sinyal işleme ve görüntü oluşturma teknikleri yaygın olarak kullanılmaktadır [5]. Ancak YNR verilerindeki yer altı nesnelere tanımlama için deneysel yargılara ihtiyaç duyulduğundan, YNR verilerini yorumlamak için yüksek eğitimli uzman kişilere ihtiyaç duyulmaktadır. Ortamda birçok deneysel gürültü ve çevresel karmaşıklık bulunmaktadır [6]. Ayrıca, YNR verilerinin tamamının bir analist ile çıplak, manuel olarak taranması zaman alıcı ve güçtür. Bu nedenle, hızlı ve doğru otomatik YNR veri yorumlama teknikleri geliştirilmiştir.

Gömülü nesnelere, bir GPR B-tarama görüntüsünde bir hiperbol veya ters çevrilmiş bir U-şekli (hiperbol), yer altı nesnelere tespit etmek için YNR veri yorumlamasının anahtarı tespit edilerek tam olarak belirlenebilir. Bu nedenle, otomatik hiperbol tespiti için birçok çalışma yapılmıştır [7]. Literatürde gömülü nesnelere tespit etmek ve sınıflandırmak için çeşitli teknikler önerilmiş ve geliştirilmiş olmasına rağmen, yüksek doğruluk performansı sağlayan otomatik ve kullanımı kolay sistemler hala araştırma aşamasındadır. Bu amaçla ; gizli Markov modelleri [8], yeni nesne algılama algoritmaları, Adaptive boosting algoritmaları [9,10,11], Hough dönüşümü kullanılarak GPR görüntülerinin analizi [12] gibi bazı modeller önerilmiştir. Ancak son yıllarda, derin öğrenme yöntemlerinin, özellikle Evrişimli Sinir Ağlarının (ESA) hızlı gelişimi, görüntü sınıflandırma ve nesne algılama görevleri üzerine yeni çözümler sunmaktadır. Büyük miktarda verinin mevcudiyeti ve donanım teknolojisindeki gelişmeler, derin öğrenmedeki araştırmaları hızlandırmış ve son zamanlarda derinlemesine birçok ESA mimarisi rapor edilmiştir. Sınıflandırmada, öznel çıkarımının zor olması ve bu alanda bilgi sahibi olunması gerektirmesi nedeniyle, Evrişimli Sinir Ağları (ESA) ve aktarım öğrenmesi kullanılan bir derin öğrenme modeli sunmuştur. Aktarım öğrenmesi, daha önce çok sayıda veriden derin öğrenme yöntemi ile elde edilen bilgilerin mevcut modele aktarılmasıdır. Böylelikle önceden eğitilmiş modellerin çok sayıda

veriden elde ettiği genel öznitelikler (ör. şekil, boyut), çalışılan derin öğrenme modeline aktarılmaktadır, az sayıda veri olmasına rağmen iyi bir sınıflandırma başarımı elde edilmesi hedeflenmiştir.

Bu tez çalışmasında, gömülü tehditlerin GPR verilerini kullanarak tespiti için ESA mimarilerinin geliştirilmesi amaçlanmıştır. Bu amaçla, GPR B taramalarının (yani, dikey yeraltı dilimlerinin 2B görüntüleri) analizini kullanarak ve ayrıca farklı ESA mimarilerini test ederek kara mayını tespiti için yeni bir ESA mimarisi önerilmiştir.


1.2 Genel Bakış

1.2.1 Yere Nüfuz Eden Radar Nedir?

Yeraltındaki malzemeleri, nesnelere keşfetmeye yönelik tahribatsız teknikler son zamanlarda devletler tarafından büyük ilgi görmektedir. Özellikle özel kuruluşlar bunu gaz arama, boru lokalizasyonu, jeoloji ve arkeoloji gibi yaygın alanlarda uygulamaktadır. Yere Nüfuz Eden Radar (YNR), özellikle son yıllarda oldukça gelişmiş bir cihazdır. Buna bağlı olarak da kullanım alanlarında artış meydana gelmiştir.

Yere nüfuz eden radar (YNR), inşaat çalışmalarında, patlamamış mühimmat tespiti, kara mayını tespiti, boru hattı tespiti gibi altyapı değerlendirmeleriyle ilgili birçok uygulamada kullanılan çok yaygın bir tahribatsız yüzey altı görüntüleme aracıdır [13]. Ayrıca çığ kurbanlarının tespiti, toprak nem değerlendirmesi, sıvı kirliliği tespiti, toprak kirliliği ölçümü, köprü tahliyesi muayenesi, nesne algılama, bu uygulamalarda odaklanan hedeflerdir. YNR platformları, farklı işletim ortamları arasında hızlı geçiş yapabildiğinden son derece önemlidir. Bununla birlikte, birkaç algılama algoritmasının performansının işletim ortamına bağlı olarak değiştiği de bulunmuştur. YNR tabanlı kara mayını tespit uygulamaları için, çevresel faktörleri karakterize eden fizik tabanlı özelliklerden veya benzer algoritma güvenlikleriyle gözlemler kümelendirilerek çıkarılabilir. Nesne tespiti için aynı derecede önemli olan, gömülü nesne karakterizasyonu veya başka bir deyişle gömülü nesnenin özelliklerini bulmaktır. Bu özellikler şunları içerir: nesne lokalizasyonu, nesne derinliği algılama, nesne şekli tanımlama, nesne boyutu tahmini, nesne malzeme tanıma ve

sınıflandırma. YNR sistemi alıcı, verici antenler ve veri toplama biriminden oluşmaktadır. Bir YNR sisteminin en temel unsurları ve çalışma şeması Şekil 1’de gösterilmiştir. Şekilde gözüken şemada verici antenden belirli bir dalga şeklinde ve frekansta sinyal gönderilir. Gömülü nesnelere çarpıp dönen sinyaller ise alıcı anten tarafından alınarak sırasıyla veriler depolanır, işlenir ve bir ekran yardımıyla görüntülenir [14].



Şekil 1 Yere nüfuz eden radar işleyiş şeması

Uygulama türlerine göre yer altı görüntülemesi için uygun bir sensör kullanılması gerekmektedir. Yere Nüfuz Eden Radar (YNR), yüksek frekanslı elektromanyetik dalgalar kullanılarak yüzey altı haritalama için yaygınlaşmaktadır. Gömülü nesnelere doğrulukla tespit edilmesi operatörler için zor bir problemdir. Gömülü nesnelere tespitinde geleneksel bir tespit yöntemi olarak metal dedektörler (mayın dedektörleri) kullanılmaktadır. Ancak bu yöntem ile sadece metal içerikli malzemeler tespit edilebilmektedir. Günümüzde, insan hayatı ve ordular için tehdit oluşturan gömülü nesnelere genellikle plastikten yapılmaktadır ve çok az metal bileşen içermektedir. Gömülü nesne içeriklerinde meydana gelen değişim, metal dedektörlerinin gömülü hedefler için işlevsiz kalmasına neden olmuştur. Metal içermeyen veya daha çok plastik madde karışımı ile oluşturulan az miktardaki metal içeriğe sahip olan cisimlerin tespiti için YNR geliştirilmiştir. YNR, yeraltındaki gömülü cisimleri tespit etmek

ve sınıflandırmak için kullanılan bir radar olarak tanımlanmaktadır. Yere Nüfuz Eden Radar, radar sinyallerini kullanarak toprağa gömülü nesnelere 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 ve EYPLerin tespitinde diğer yöntemlere göre üstün olduğu için kullanılmaktadır. Dielektrik farklılıklarından yararlanarak nesne tespit edilebildiği için çeşitli hedefleri (plastik veya metal içermeyen) tespit edebilmektedir. Yapılan çalışmalardan elde edilen sonuçlarda sismik yöntemlerde kullanılan tekniklerin işlenmesi ile 10 – 20 m derinliğe ulaşıldığı görülmüştür. YNR ile zemine yakın (40 metre) gömülü nesnelere aranması yapılmaktadır. Ayrıca YNR sisteminde kullanılan frekans değeri artırılarak yani dalga boyu küçültülerek daha kaliteli bir görüntü üretmesi sağlanabilir. Ancak yüksek frekanstaki bir dalganın 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 [15]. Son zamanlarda, bir elektromanyetik indüksiyon sensörü ile kombinasyon halinde kullanılan el tipi YNRler ile tehlikeli bölgeyi tarama sürecinin otomatikleştirilmesinde ilerleme kaydedilmiştir. Bu sistemler, çeşitli dış ortamlarda binlerce kara mayını karşılaşmasında kapsamlı bir şekilde test edilmiştir.

Araçlarda kullanılan dizi tabanlı YNR sistemleri, mayın dedektörlerinden daha iyi performans gösterdiği çalışmalarda kanıtlanmıştır. Bunun nedeni genellikle radar sinyal dönüşlerinin genellikle zeminden gelen gürültü, dağınıklık ve hatta radarın kendisinden kaynaklanan önemli ölçüde bozulmuş olmasıdır ve sinyal dönüşünün enerjisi bir mayından dönmüş olsa bile, farklı olabilir. YNRda bu bozulmaları önlemek çeşitli yöntemler kullanılmıştır. Dalgacıklar ve Kalman filtreleri, alt uzay yöntemleri, polinomlarla eşleştirme dahil olmak üzere bu etkileri ortadan kaldırmak için sinyalin ön işlenmesi, optimum kaydırılmış ve ölçeklenmiş referans vektörlerinin çıkarılması, kaydırma, ölçek metodolojisinin uyarlanabilir uzantıları gibi yöntemler kullanılmaktadır [16].

1900'den günümüze kadar olan YNR arařtırmalarının gemiři Tablo 1'de gösterilmektedir [17].


Tablo 1 1900'den İtibaren YNR Arařtırmasının Tarihesi

Tarih	Yapılan Arařtırma
1900-1950	Yüzey üzerinde radyo dalgaları yayımlanıyor.
1950-1955	İlk kez, radyo dalgası sinyallerini kullanarak yeraltının özelliklerini ölçmeye alışma
1955-1960	Radyo frekansının yeraltına girebileceğine dair göstergeler
1960-1965	Buzda ses ıkararak radyo yankısı geliştirme
1965-1970	Kömür ve tuz gibi diğerk malzemelerin kullanımına ek olarak buz radyosu yankı sondaj etkinliğı devam etti.
1970-1975	Yer yüzeyindeki antenlerin dalga alanlarını anlama.
1975-1980	YNR kullanılarak ilk sonuçlar sunuldu.
1980-1985	“Georadar” Japon OYO Şirketi tarafından geliştirilmiş ve düşük frekanslı radarlar tanıtılmıştır.
1985-1990	YNR'nin artılarını ve eksilerini daha iyi anlama
1990-1995	Dijital veri işleme ve 2D sayısal simülasyon gibi birçok YNR geliřtirmesinin ortaya ıkmasıyla YNR ilerlemedeki en yüksek zirve. Ayrıca YNR toplantıları yapılmaya başlandı.
1995-2000	Bilgisayarların evrimi nedeniyle 3 boyutlu sayısal modelleme geliřimi.
2000- günümüz	YNR ürünleri sofistike, istikrarlı, güvenilir ve tekrarlanabilir hale geliyor. Ayrıca, YNR verilerini işlemek için birçok teknik ve algoritma geliştirilmektedir.

1.2.2 Mayın ve El Yapımı Patlayıcı Nedir?

Kara mayınları ve el yapımı patlayıcılar (EYP) olarak üzerlerine basılan insanları öldürmek veya sakatlamak veya üzerlerinden geçen araçları etkisiz hale getirmek için tasarlanmıştır, bu nedenle kara mayınları ve EYPnin tespiti çok daha tehlikelidir. Günümüzde yeni kara mayınları ve EYPler çok az metal içerdiğinden, bunları bir metal dedektörü ile tespit etmek mümkün değildir.

Kara mayınları genellikle metal, plastik ve hatta tahta kasaya gömülüdür ve farklı şekil ve boyutlarda olabilirler. Şekil 2’de, dört çeşit anti-tank (AT) ve anti-personel (AP) kara mayını gösterilmektedir.



Şekil 2 Kara mayını örnekleri.

Şekil 2’deki kara mayınları soldan sağa kara mayınları soldan sağa, VS1.6 plastik AT mayını, PMD6 ahşap AP mayını, VS50 plastik AP mayını ve M14 plastik AP mayınıdır. Bu kara mayınları yeryüzünün hemen yüzeyine yerleştirilebilir veya farklı derinlikte yeraltına gömülebilir, genellikle anti-personel kara mayınları için zeminin hemen altına ve tanksavar kara mayınları için 16 inç'e kadar olabilir. Ayrıca kara mayınlarının yerleştirildiği bölgenin iklimi ve jeo-grafik durumu çok karmaşık olabilir. Tüm bu faktörler, tespitin verimliliğini sınırlayabilir ve üstesinden gelinmesi gereken zorluklardır.

Bu nedenle, verimli bir kara mayını algılama sistemi, hangi boyut, şekil, gömme derinliği, kasa tipi ve patlayıcı imzası olursa olsun, çeşitli türlerdeki kara mayınlarını, güvenlik açısından iyi bir mesafeden tespit etme kapasitesine sahip olmalıdır. Sistem, kara mayınlarını arka plandaki karmaşadan ayırt edebilmeli ve çok düşük yanlış alarm oranı, kabul edilebilir çalışma hızı ve makul bir maliyetle görüntüleme kapasitesi ile oldukça hassas bir tespit sonucu sağlamalıdır. Tüm bu zorlu gereksinimleri karşılamak gerçekten zordur. Ancak şimdiye kadar bu sorunları çözmek için birçok teknoloji ve algılama sensörü geliştirilmiştir. İleriye Bakan Kızılötesi (FLIR), Termal Nötron Aktivasyonu (TNA), Dörtlü Rezonans (QR), Görünür Dalgaboyu Kameraları, Akustik algılama sistemi, Yere Nüfuz Eden Radar (YNR) [18], lazer algılama ve nüfuz eden radyasyon yeni alanlardan bazılarıdır. Çeşitli uygulamalarda kullanılan mayın algılama teknolojileri, metal dedektörü gibi bazı geleneksel sensörler metal kasalı kara mayını tespiti için çok yararlı olabilir. Bununla birlikte, özellikle savaş bölgeleri gibi metal dağınıklığı olan alanlarda ortaya çıkan yanlış alarm oranı son derece yüksek olabilir, ayrıca arka planda çok fazla metal bulunan ortamlarda zorluk yaşanır [18]. Dahası, ne yazık ki tüm kara mayınları ve EYPler metal kasalı değildir, bu nedenle başka tespit tekniklerine ihtiyaç vardır.

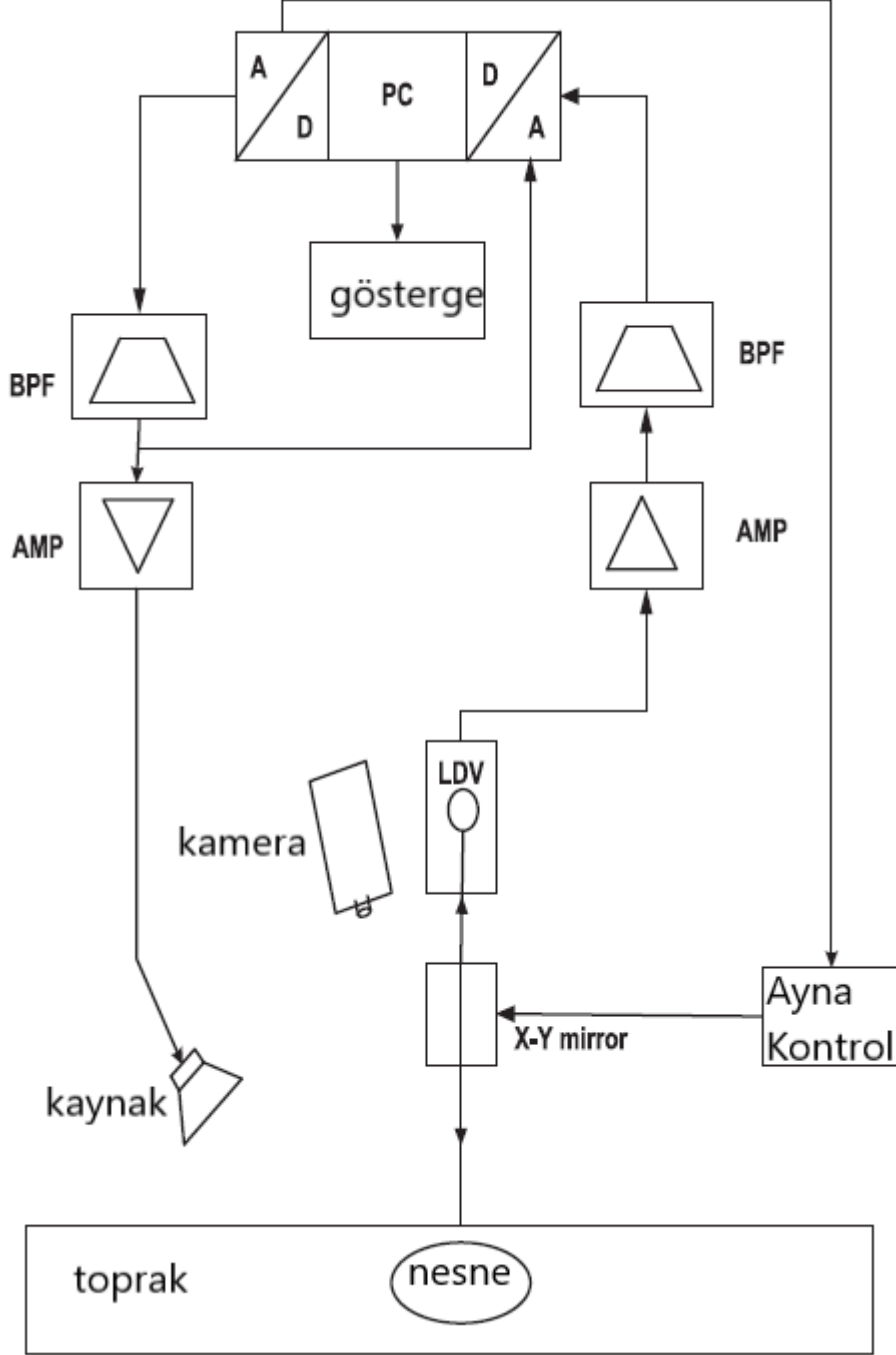
1.2.3 Mayın ve EYP tespiti teknikleri

Tarihsel olarak kara mayını ve diğer patlayıcı tehditler elektromanyetik indüksiyon sensörleri kullanılarak temizlenmiştir.


- Akustik Sismik Teknik (A/S)

Metalik olmayan kara mayınlarının tespiti, geleneksel yere nüfuz eden radar (YNR) teknikleri kullanılmadan gerçekleştirilmesi zorlu bir görevdir. Bu sorunu çözmek için akustik dalgalar verimli bir şekilde kullanılabilir. Xiang ve Sabatier, A / S bağlantısı kullanarak AP kara mayını tespiti üzerine deneysel bir çalışma yürütmüştür [19,20]. Bir iletim alt sistemi ve bir alıcı alt sistemden oluşan yeni bir A / S kara mayını algılama sistemi sundular. İletim alt sistemi, test edilen alana akustik veya sismik dalgalar üretir ve alıcı alt sistem, alanın mekanik özelliklerindeki değişiklikleri algılar. İletim alt sistemi, akustik hoparlörlerden veya elektrodinamik çalkalayıcılardan oluşabilir. Alıcı alt sistem, mikrofonlar, jeofonlar / assele

ometreler veya bir Lazer Doppler Vibrometre içerebilir. Elde edilen akustik sinyallerden, test edilen alan için bir görüntü oluşturulabilir. Şekil 3 gömülü nesnelerin A / S algılama tekniğinde kullanılan ana bileşenlerin blok diyagramını göstermektedir [19,20]. Bu teknikle elde edilen kara mayını görüntülerine örnekler Şekil 4'te gösterilmektedir.



Şekil 3 A / S kara mayını tespitinde kullanılan ana bileşenlerin basit diyagramı sistemi



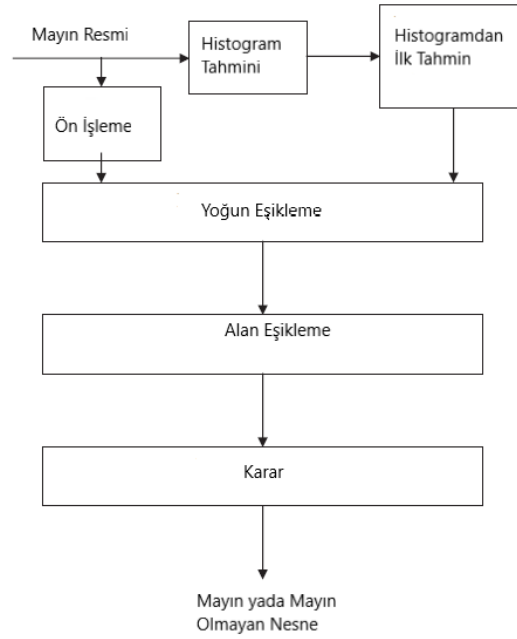
Şekil 4 Akustik kara mayını görüntülerinden örnekler.

- YNR Tespit Sistemi

1.2.1 başlığı altında açıklanmıştır.

- Görüntülerden Kara Mayını Tespiti İçin Geleneksel Yaklaşımlar

Bir görüntüdeki kara mayınının tespiti, koyu arka planı ortadan kaldırmak için belirli bir eşikle ile sağlanabilir. Bu işlem arka planı ortadan kaldırmaya yardımcı olur ve yalnızca nesnelere bırakır. Ardından, istenmeyen küçük alan yığınlarını ortadan kaldırma ile tespiti beklenen nesnelere belirli bir eşik ile ortaya çıkarılmasıyla sonuçlanır. Morfolojik işlemlerin kullanımı gibi bir ön işleme adımı, eşiklemeden önce gerekli olmaktadır [21,22]. Şekil 5'te, geleneksel bir kara mayını tespit yaklaşımının blok diyagramı gösterilmektedir.



Şekil 5 Geleneksel mayın yaklaşım tespit adımları

Geometrik bilgilere dayalı geleneksel kara mayını tespitinin bazı sınırlamaları vardır. Yoğunluk eşikleme işlemi, tüm istenmeyen gürültü veya karmaşayı görüntülerden kaldırmayabilir. Alan eşikleme işlemi, bir görüntüden diğerine farklılık gösterebilen ve yanlış alarmlara veya kaçırılmış kara mayınlarına yol açan belirli eşikler gerektirir. Ön işleme olmadan, kara mayınlarının tespit olasılığı yaklaşık % 90'dır. Morfolojik ön işleme, küçük bir yanlış alarm olasılığı ile bu algılama olasılığını yaklaşık % 97'ye çıkarabilir, ancak tüm bu olasılıklar herhangi bir gürültü türü olmaması durumundadır [21,22].

▪ Metal Detektör

Metal dedektörü, mayın tespiti için en çok kullanılan yakın mesafe algılama sistemlerinden biridir. Bununla birlikte, anti-personel (AP) kara mayınları artık daha çok metalle değil, plastik ve diğer metal olmayan elementlerle üretilmektedir. Günümüzde mevcut olan metal algılama tabanlı sistemler, metal kalıntılarla kirlenmiş bir alanda minimum metal içeriğine sahip plastik kara mayınlarını verimli bir şekilde algılayamamaktadır [23].

- Elde Taşınan Çift Sensörler

Geçtiğimiz 10 yıl boyunca, kara mayını tespitinde kullanılan YNR'nin gelişimi, laboratuvar koşullarından ve test alanlarından gerçek mayın tarlalarına doğru gelişti. Günümüzde, mayın dedektörü ve YNR'yi birleştiren ikili sensör teknolojisini kullanan sistemler, canlı mayın tarlalarında gösterilecek küçük metal parçalara karşı gelişmiş tespit olanağı sağlamıştır. Çok sayıda üretilmeye başlamıştır. Bu tür sistemler hem mayın dedektörü hem de YNR ile çalışır ve sinyal işleme ve kullanıcı arayüzü bakımından farklılık gösterirler [23].

- İleriye Bakan Kızılötesi (FLIR)

İleriye dönük kızılötesi (FLIR) sistemler, bir kara mayınının hemen üzerindeki toprağın çevreleyen topraktan biraz farklı bir oranda ısındığı ve soğuduğu durumdan yararlanmaya çalışır [23]. Adından da anlaşılacağı gibi, doğrudan sistemin altındaki kara mayınlarını tespit etmek yerine, sensörün önündeki kara mayınlarını tespit edebiliyor. FLIR, kara mayınlarının veya bunların üstündeki toprağın görüntüsünü oluşturabilir, böylece kısa sürede geniş bir alanı kaplayabilir. Amaç mayın alanını belirlemek olduğunda, bu teknoloji en uygun olanıdır. Ancak bu sistemin dezavantajı, toprak ve maden termal denge durumundayken uygulanamamasıdır. Diğer sistemlere göre yüzey bozuklarından 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. Başka bir deyişle, sınırlı geçiş koşullarında faydalı olarak çalışmaktadır.

- Termal Nötron Aktivasyonu (TNA)

Termal nötron aktivasyonu (TNA) kara mayınlarının patlayıcı imzasını doğrudan tespit edebilir. TNA, tüm patlayıcıların bir bileşeni olan nitrojenden nötronla aktive edilen gama ışınlarının tespiti prensibi üzerinde çalışır. Termal nötron yakalamayı takiben azot, sahada karşılaşılmaması muhtemel hemen hemen tüm diğer gama ışınlarından daha yüksek bir enerji olan karakteristik bir gama ışını yayar. 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 [24].

- Dörtlü Rezonans (QR)

Dörtlü rezonans (QR) sensörleri, kara mayınlarının patlayıcı imzasını doğrudan tespit edebilir. QR, özellikle patlayıcı bileşikleri (örneğin RDX ve TNT) hedefleyen bir radyo frekansında bir manyetik alan darbesi kullanır [24].

- Görünür Dalgaboyu Kameraları

Görünür dalga boyu kameralarındaki otonom sistem, insan gözünün zar zor görebildiği anda, dünyanın hemen yüzeyine yerleştirilmiş anti-tank kara mayınlarını tespit edebilir. Ya da mayınlar gömüldüğünde bile, mayınların yeni kazı ve aşınmış kazı yeri kamera sistemi ile fark edilebilir. Tespit, kara mayınının hareketinin çevreleyen toprağın hareketinden farklı olduğu ilkesine dayanır, çünkü kara mayını belirli bir şekilde yankılanan sert bir yapı içerir [18].

- Lazer Algılama ve Nüfuz Eden Radyasyon

Lazer algılama, lazer enerjisi tarafından ayırt edilmesinde toprağın yansımaları ve polarizasyonundaki farkı kullanır. Ancak bu, büyük bir lazer gücü ve karmaşık bir veri yorumlama süreci [25] gerektirir, bu da bu sistemin uygulanmasını kolay hale getirmez. X veya gama ışınları şeklindeki fotonlar, ortamın elektron yoğunluğuna ve dolayısıyla kütle yoğunluğuna bağlı bir olasılıkla atomik elektronlarla tutarsız bir şekilde çarpışır. Dağınık fotonlar detektöre geri dönerken, daha fazla saçılma veya soğurma yoluyla uzaklaştırılırlar. Foto absorpsiyon olasılığı büyük ölçüde atom numarasına bağlıdır. Madenin ve toprağın atom numarası ve yoğunluğu arasındaki fark, birincisinin tanımlanmasını sağlar. Campbell ve Jacobs'un [26] x-ışını geri saçılma sisteminin özü budur.

- Elektriksel Empedans Tomografisi (EET)

EET yaklaşımı, elektrik akımını kullanarak gömülü cisim ve bulunduğu ortamın iletkenliğine göre bir çıktı oluşturur. Yüzeğe 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 mayın/EYP patlama riskini arttırmasıdır [27]-[32].

- 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 oluşturması gösterilebilir. Ama bu sistemin kullanımı sadece toprağın hemen altındaki yani yüzeye yakın gömülü nesnelere için geçerlidir. X ışınları toprağa nüfuz etme konusunda zayıftır. Ayrıca bu sistemler hacimli ve ağır sistemlerdir. Bu sebeple kişiye entegre edilerek kullanılamazlar. Eğer kişi taşımaya uygun hale getirilerek küçültülürse, bu sefer de görüntüyü oluşturmak çok zaman almaktadır [27]-[32].

1.2.4 Alandaki ilgili Diğer Çalışmalar

YNR tabanlı GTA için literatürde çok çeşitli GTA algoritmaları önerilmiştir. Örneğin, YNR tabanlı GTA algoritmaları, istatistik [16] [33], bilgisayarla görme [34] - [36] ve makine öğrenimi [9][37] [48] gibi çok çeşitli alanlardan teknikler kullanmıştır. Modern algoritmaların sistematik karşılaştırmaları nadirdir ve bu nedenle hangi algoritmaların ve daha genel olarak hangi işleme uygulamalarının en iyi olduğunu ayırt etmek zor olabilir.

Gömülü cisimlerde ve özellikle mayına benzeyen hedeflerin tespitinde yapılan çalışmalarda önerilen metotlardan biri de negatif olmayan matris ayrıştırma (NOMA, nonnegative matrix factorization-NMF) yöntemidir. Diğer önerilen yöntem çok-ölçekli yönlü bilateral süzgeç (ÇYBS, multiscale directional bilateral filter-MDBF) dir. ÇYBS metodu uygulanırken uzamsal Gauss süzgecinin YNR görüntülerinde bir etkisi olmadığı fark edilmiş ve literatürde komşuluk süzgeci (KS, neighborhood filter) olarak geçen ve sadece mesafe bilgisine dayanan Gauss süzgeci, bilateral süzgeç yerine kullanılmıştır. Böylece sadece tek Gauss süzgeci kullanılan KS sayesinde hem performans arttırılmış hem de işlem süresi yarı

yarıya azaltılmıştır. Bu yeni yöntemde çok-ölçekli yönlü komşuluk süzgeci (ÇYKS, multiscale directional neighborhood filter-MDNF) adı verilmiştir. Yapılan çalışmalarda verilen metotlar gömülü cisimlerde ve özellikle mayına benzeyen hedeflerin tespitinde kullanılmıştır. Sınıflandırma yapılmamıştır. Mayına benzer hedeflerin olup olmadığı araştırılmıştır [39].

Bir diğer çalışmada kuru/nemli/ıslak topraklardaki plastik telden ve başka materyallerden yapılmış cisimlerin ayırt edilmesine yönelik bir çalışma yapılmıştır. GprMax programı ile yapay YNR veri seti üretilmiştir. Bu veri seti, kuru/nemli/ıslak topraklardaki plastik telden ve başka materyallerden yapılmış cisimlerden oluşmaktadır. Veri seti, üç çeşit sınıflandırma algoritması ile yapılmıştır. Bunlar; standart ESA, aktarım öğrenmesi kullanılan ESA, çok görevli öğrenme kullanan ESA'dır. Başarıyı yükseltmek için çok görevli öğrenmeli ESA kullanılmıştır. Çok görevli öğrenme, diğer görevlerin eğitim bilgilerinden faydalanarak göreve yönelik öğrenmeyi iyileştirmiştir. Çok görevli öğrenme ile toprak türünün öğrendiklerinin nesne tespit başarımına katkı sağladığı tespit edilmiştir [15].

Bir diğer çalışmada beton, tuğla, ağaç, çalılık gibi engellerin arkasındaki hedeflerin uzaktan tespitine yönelik çalışma yapılmıştır. Menzil ve huzme parametreleri ile yapay açıklık radarı algoritması, mesafe çözünürlüğünü artırarak MUSIC algoritması gibi sinyal işleme algoritmaları geliştirilmiştir. Gizlenmiş nesnelerin takibi sinyal işleme teknikleri ile yapılmıştır [40].

Bir diğer çalışmada el yapımı patlayıcılarda kullanılan tel tespitine yönelik bir çalışma gerçekleştirilmiştir. Tel tespit ve teşhis problemi çalışılmıştır. Matematiksel biçimsellik ile iyileştirilmiş 2 boyutlu LMS ile olası tel konumlar ön görüntülenmiştir. Ardından, 3 boyutlu eğri oluşturma metodu ile, yenilikçi bir 3 boyutlu öz nitelik kümesi çıkarılmıştır. Veri kütüphanesi ile, SVM sınıflandırıcısı eğitilmiş ve önerilen metotların performansları incelenmiştir [41].

Başka bir gerçekleştirilen çalışmada gömülü plastik tellerin tespiti üzerinedir. Çok görevli öğrenme ile takip edilen derin öğrenme temelli bir transfer öğrenme önerilmiştir. VGGNet mimarisinin ilk altı katmanında Derin öğrenme yöntemi, aktarım öğrenmesi ve çok görevli öğrenme yöntemleri kullanılmıştır [42]. Başka çalışmalarda n-Row Average Subtraction (nRAS) kullanılmıştır [43].

Başka bir çalışmada Zaman Bölgesinde Sonlu Farklar (FDTD) ile dalga yayılımı elde edilmiş ve ortamın üst tarafından yayılımı sağlanmıştır. YNR uygulamalarında önce tek sonra alt alta yan yana metaller yerleştirilmiştir. Öncelikle yansımanın olduğu, sonra bu yansımalarından metallerin yerinin tespit edilebildiği çalışılmıştır. Bu sonucun mayın yeri tespitinde fayda sağlayacağı, algoritma geliştirme tahminlerinin oluşturulmasındaki çalışmalara fayda sağlayacağı önerilmiştir [44].

Pouria Asadi, Mayrai Gindy, Marco Alvarez tarafından gerçekleştirilen çalışmada ise YNR B görüntülerinde discrete AdaBoost yerine real AdaBoost kullanılmasının % 9 daha fazla çalışma süresi pahasına performansı % 6 artırdığı tespit edilmiştir. Verilere filtre uygulamanın performansı % 12 artırdığı tespit edilmiştir. Aşama sayısını 25'e çıkarmanın ise, eğitim süresini önemli ölçüde artırdığı, ancak uygulamada amaç en yüksek doğruluğu elde etmek olduğundan, yazarlar YNR verilerinin sınıflandırılmasında kademeli sınıflandırıcı eğitimi için 25 aşamanın uygun olacağını önermişlerdir [45].

Hiyerarşik yöntemlerin mayın tespitindeki performans kıyaslanmasının yapıldığı çalışmalar yapılmıştır. Bir başka çalışmada MBA (Morfolojik Bileşen Analizi)'nin üstünlüğü belirtilmektedir. MBA algoritmasında her bileşen için ayrı sözlük kullanılmaktadır ve görüntü ayrıştırma yapmaktadır. MBA ile farklı teknikler kullanılarak, yeni eklemeler yapılmakta ve daha iyi ve hızlı sonuçlar alındığı gösterilmiştir [46]. Başka bir çalışmada şüpheli bölgeler, YNR görüntülerinden çıkarılan ve SVM tarafından sınıflandırılan Yönlendirilmiş Gradyan Histogramı (HOG) özelliklerinin kullanılarak daha fazla analiz edilebileceğini belirtmektedir [47]. AT ve AP mayınlarını çeşitli boyutlardaki metalik ve metalik olmayan dağınıklaktan ayırmak için Hiyerarşik Uzman Karışımı (HUK) yöntemi kullanılmAI önerilmiştir [48].

Bir diğer çalışmada çok örnekli saklı markov modeli, saklı markov modellerinin karışımı önerilmiştir. Eş zamanlı özellik ve saklı markov modelinden gibbs özellik çıkarma kullanarak ve kullanmadan yapılan çalışmalar da mevcuttur [39].

Başka bir çalışmada durağan dalgacık dönüşümü, ayrık dalgacık dönüşümü, tekil değer ayrışımı, ortalama çıkarma, medyan çıkarma, dalgacık paket dönüşümü, temel bileşen analizi, lifting dalgacık dönüşümü ve bağımsız bileşen analizi yöntemleri uygulanmıştır. Elde

edilen sonuçlar kıyaslanarak Lifting dalgacık dönüşümünün diğer bütün yöntemlere göre daha net tespit ettiği gösterilmiştir [49].

Yapay sinir ağları ve örüntü tanıma teknikleri, oldukça azaltılmış bir hesaplamayla sığ alt yüzeyin yüksek çözünürlüklü bir görüntüsünü otomatik olarak üretmek için önerilen sistemlerde bulunmaktadır [50].

1.2.4 Çalışmaya İten Motivasyon

Kara mayınları, EYPler, patlayıcı cihazlar gibi gömülü nesnelere tespiti, genellikle ilgili kuruluşlar tarafından talep edilen bir görevdir. Herhangi bir can kurtarma, askeri hareket veya emniyet güçleri operasyonunda gömülü nesnelere daha hızlı konum tespiti istenir. Gömülü nesnenin bu kadar yüksek örnekleme oranıyla mümkün olduğunca erken tespit edilmesi çok önemlidir.

Bu tez çalışması ile mayın ve EYP ile mücadele eden Türk Silahlı Kuvvetlerimize ve emniyet güçlerimize yardımcı olmak, otomasyon tespit yöntemi ile tespit edilme olasılıklarını artırma hedeflenmiştir. Tez çalışmasıyla sunduğumuz mimari kendi içinde çeşitli özellikleri ile ve diğer mimariler ile kıyaslanarak avantajları ve dezavantajları ile ortaya konulması hedeflenmiştir.

1.3 Hedefler

Gömülü cisimlerin tespitinin hayati öneme haiz olması ve hızlı bir şekilde karar verebilmek adına tezde bu mimari tasarlanmıştır. Pozitif resimleri yani gömülü cisimleri (mayın, EYP) daha hızlı ve yüksek yüzde ile elde etmek adına bu mimari geliştirilmiştir. Avantaj ve dezavantajlarının diğer parametrik yöntemlerle ve mimarilerle kıyaslanması hedeflenmiştir.

Farklı yerlerde otomatik tespit sisteminde kullanım için uygunluklarını belirlemek ve kara mayını/EYP ayırmacılık algoritmaları koleksiyonunu değerlendirmek de hedeflenmiştir. 8664 pozitif ve 8596 negatif YNR görüntüsü ile büyük bir veri seti kullanılarak bir değerlendirme gerçekleştirme hedeflenmiştir.

2. YERE NÜFUZ EDEN RADAR

2.1 Veri Toplama

200 MHz ve birçok Yere Nüfuz Eden Radar antenleri, yerle temas halinde çalışmak üzere tasarlanmıştır. Anten yüzeyle temas ettiğinde, toprak, antenin Elektromanyetik Dalgasını (EM) emer ve anten zemine bağlanır. En iyi performansı elde etmek için, anten yüzeyden dalga boyunun maksimum % 15'i içinde kalmalıdır [11]. Toprak ile YNR arasındaki boşluğun olabildiğince az olması, yüzeye yakın veya temas halinde olması önerilmektedir. Alt yüzeye nüfuz ederken elektromanyetik dalga enerjisinin yönü esas olarak yüzey tarafından belirlenir. EM dalgası, anten yönünden bağımsız olarak yüzeye dik olarak nüfuz eder.

Anten, biri EM dalgası gönderen diğeri de yansıyan EM dalgalarını alan iki element içerir. 200 MHz antende verici-alıcı arasındaki mesafe 8 cm olup, ilgilenilen nesnelere bu 8 cm içindeki mesafede olması gerekmektedir. Son işlem aşamasında derinlik hesaplamalarında bu değer dikkate alınır. 8 cm'den sonraki kara mayınları/EYP, yeraltı zemine nüfuz eden görüntülerde bulanık ve gürültülü görünebilir ve bunu iyileştirmek için sonradan işlem yapılması gerekir.

EM-dalga penetrasyon derinliği, antenden gönderilen sinyalin toprağa ne kadar derine nüfuz edebileceğini belirtir ve tarama çözünürlüğü, yere giren radar anteninin, belirli bir toprakta ayrı ayrı konumlandırılmış birbirine yakın iki kara mayını görme yeteneğini gösterir.

Çözünürlük, Denklem 2.1'de tanımlandığı gibi frekans ve hızın bir fonksiyonu olan dalga boyu ile belirlenir. Düşük iletkenliğe sahip dielektrik malzemeler için EM dalgaları penetrasyon derinliği Denklem 2.2'de gösterilmiştir.

$$\text{Dalgaboyu} = \frac{v}{f} = c / (f \sqrt{\frac{\epsilon'}{\epsilon_0}}) \quad (2.1)$$

$$\text{Derinlik} = (1/\pi(\epsilon' \tan \delta)) f x \sqrt{\epsilon' / \mu_0} \quad (2.2)$$


Denklem 1’de c ışık hızı, μ_0 vakumda geçirgenlik, d_p elektromanyetiğin penetrasyon derinliği, $\tan\delta$ kayıp tanjantı, λ dalgaboyu, v malzeme içindeki elektromanyetik dalganın hızı, ϵ_0 vakumda geçirgenlik, ϵ_1 dielektrik sabitidir.

Malzeme içinde elektromanyetik dalga boyu azaldıkça, çözünürlük artar; ama bu penetrasyon derinliğini sınırlar. Araca monteli sistemler, çoğunlukla, hareket yönüne dik olarak hizalanmış bir dizi YNR sensöründen oluşur. Sensörler aracın hareket yönü boyunca ilerlerken, 3 boyutlu bir YNR verisi küpü üretilir. Her bir tek sensör kaydına A-taraması denir. Bir yol boyunca yapılan taramalardan oluşan bir koleksiyon, B-taraması olarak adlandırılan 2 boyutlu bir veri dilimi oluşturur. Zaman etki alanı YNR verilerinde, hedef yanıtları, yüzey altı bir nesnenin varlığında oluşturulan karakteristik hiperbol benzeri şekil nedeniyle genellikle B-tarama görüntüleri olarak işlenir. Yükselen ve düşen hiperbol kenarları, sensörün yüzey altı nesneye daha yakın ve daha uzağa hareket etmesinden kaynaklanır.


2.2. Kullanılan YNR Veri Seti

P. Asadi, M. Gindy’ e ait [45] “URIGPRv1.0 dataset” kullanılmıştır. Veri kümesindeki her kayıt kırılıp, etiketlenip ve ayrı bir bit eşlem (BMP) görüntü dosyası olarak kaydedilmiştir. Şekil 6 ve Şekil 7 de , URIGPR veri kümesindeki kayıtların pozitif ve negatif örnekleri gösterilmektedir. Şekil 6 ve 7 kırılmış görüntüleri göstermektedir. Şekil 8 ise kırılmamış görüntüleri göstermektedir.


Bu çalışmada kullanılan veriler araca monteli YNR sistemi kullanılarak toplanmıştır. Deneysel veri seti 8664 pozitif ve 8596 negatif YNR görüntüsünden oluşmaktadır.



Şekil 6 Pozitif görüntü örnekleri



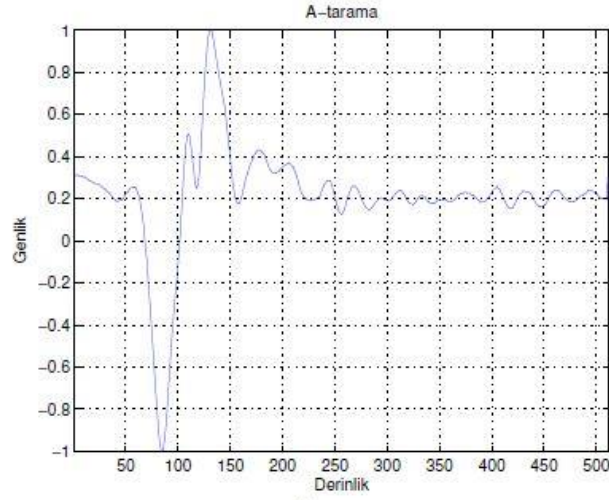
Şekil 7 Negatif görüntü örnekleri



Şekil 8 Hiperbol pozisyonları

2.2.1 YNR Görüntü Çeşitleri


YNR ile elde edilen veriler A tarama, B tarama, C tarama adında üç şekilde ifade edilmektedir. 1-boyutlu işaret olarak alınan görüntüler A-tarama olarak adlandırılmaktadır.



Şekil 9 YNR A- tarama görüntüsü


Şekil 9'da y-ekseni genliği, x-ekseni ise uzunluğu göstermektedir ayrıca derinlik bilgisi olarak da kullanılmaktadır. Radarın nüfuz ettiği derinlik bilinmediğinden birimsizdir.

A-taramalarının bir araya gelmesiyle 2-boyutlu görüntü oluşmaktadır ve B-tarama olarak adlandırılmaktadır. Örnek bir B-tarama Şekil 10'da gösterilmektedir.



Şekil 10 YNR B- tarama görüntüsü

B-tarama görüntüsünün her sütununda A-taramalar bulunmaktadır. B-taramanın y-ekseni A-taramanın x-eksenine karşılık gelmektedir ve derinlik bilgisini göstermektedir. X-ekseni kaç tane A taramadan olduğunu göstermektedir ayrıca ilerleme istikametini göstermektedir.



Şekil 11 YNR C- tarama görüntüsü

B-taramaları ile de 3-boyutlu ve C- tarama olarak adlandırılan veri oluşturulmaktadır. Şekil 11’de görüldüğü üzere 2 boyutlu B- tarama görüntülerinin biraraya getirilmesi ile C-tarama görüntüsü oluşur. C-tarama dikdörtgenler prizması olarak kabul edilirse B-tarama prizmadaki her bir dilime karşılık gelmektedir.

2.2.2 YNR Verisine Uygulanan İşlemler (Anlamlandırma)

Çok sayıda özellik ve sınıflandırma yöntemleri araştırılmıştır. Bu yöntemler, YNR verileri üzerinde başarılı bir şekilde uygulanacak modifikasyonlara ihtiyaç duyarken, çoğu 2-D görüntü verisi işlemede bulunan yöntemlere dayanmaktadır. Kontrast geliştirme bunlardan biridir ve görüntüdeki bölgeleri ya da resmi daha belirgin hâle getirmede kullanılır. Bir diğer yöntem olan geometrik dönüştürmede de küçültme, boyutlandırma, büyütme, döndürme gibi işlemler yapılmaktadır. Renk düzeltmede keskinlik ayarı, parlaklaştırma, renk dönüştürme yapılmaktadır. Optik karıştırma veya sayısal karıştırmada ise iki veya daha fazla görüntü için birleştirme yapılmaktadır. Görüntü düzenleme işlemlerinde görüntünün kalitesini netleştirme ve yükseltme yapılmaktadır. Sabit cisimleri tespit için, parazit oluşturma, iki boyutlu nesne tanıma, istatistiksel bilgiler çıkarma, görüntü üzerinde bilgileri gizleme ve steganaliz, filtre seçenekleri (Gaussian Filters), kayıpsız görüntü sıkıştırma bulunan ve kullanılan yöntemlerden bazılarıdır [37], [38]. Görüntü oluşumunun veri türü ve fiziği, YNR verileri ve görsel görüntüler arasında büyük ölçüde farklılık gösterse de, 2 boyutlu verilerdeki şekilleri tespit etmede öncelikli yöntemlerde tutarlıdır.

2.3 Daha önce YNR ile Yapılan Mayın EYP Tespit Yöntemleri

- Gizli Markov Modeli (Hidden Markov Model)

Gömülü kara mayınlarının varlığından kaynaklanan sinyaller, bu sinyallerin sıralarının kara mayınları tarafından üretilme olasılıklarını yakalayan bir Gizli Markov Modeli (GMM) geliştirmek ve olası kara mayınlarının yerini belirlemek için kullanılabilir. Gizli Markov Modelleri, durumların bir fonksiyonu olarak rastgele gözlemlerin zaman dizilerini üreten karmaşık süreçler için stokastik modellerdir. Konuşma ve el yazısı tanıma sorunlarına başarıyla uygulanmıştır [51 - 53].

MM bağlamına uyması için, her nokta için bir dizi gözlem vektörü üretilmelidir. Bu gözlem vektörleri, kara mayını imzaları hakkındaki önemli bilgileri kompakt bir biçimde kodlayan özelliklerdir. Downtrack ve çapraz ikinci türevler ilk olarak ham veriler üzerinden tahmin edilir. Farklılaşmanın nedeni, taramadan taramaya göreceli olarak sabit kalan etkileri,

örneğin yerden geri dönüş ve YNR'nin çevreleyen bileşenlerle etkileşiminin neden olduğu etkileri ortadan kaldırmasıdır. Bu ikinci türev görüntülerden hesaplanan özellikler, downtrack veya çapraz çizgi B taramalarından hesaplanan köşegen ve ters köşegen kenarların güçleridir.

Yapılan bazı çalışmalar [53] , kara mayını tespiti için gizli markov modeli yöntemini önermiştir.

- Gradyan Tabanlı Yöntem

Geçmişte, alınan YNR sinyallerini işlemek için çok çeşitli sinyal işleme teknikleri kullanılmıştır. Yapılan bazı çalışmalar Gader ve arkadaşları [54] [55], kara mayını tespiti için gradyan tabanlı bir yöntem önermiştir. Bu yöntem, birden çok prototip oluşturarak bulanık kümeleme tekniğini verimli bir şekilde kullanmaktadır.

- En Küçük Kareler Yöntemi

Pürüzlü bir yüzeyde elde edilen zemin sıçramasını gidermek için en küçük kareler yöntemi önerilmiştir. Bununla birlikte, performansı büyük ölçüde referans zemin sıçramasına bağlıdır [55] - [56].

- Doğrusal Tahmin Yaklaşımı

Dr. Ho tarafından kara mayınlarının tespiti için doğrusal bir tahmin yaklaşımı önerilmiştir; bu yaklaşım, mevcut ve son birkaç sinyal numunesinin doğrusal tahmin modeline uymaması durumunda bir mayın tespit alarmı oluşturmak için doğrusal bir tahmin modeli kullanmaktadır [57].


- Maksimum Olabilirlik Uyarlanabilir Sinir Sistemi (MOUSİ)

MOUSİ tekniği, belirli bir objektif karmaşası türü için elektromanyetik saçılma fiziğine dayalı sinyal modellerini dahil ederken bilinmeyen ve değişen toprak koşullarına uyum sağlamak için tasarlanmıştır. Ancak, doğru özellik çıkarımı için, iyi tanımlanmış dağınıklık ve mayın imza modellerini gerektirir. Elde taşınan YNR sistemi, zamanla değişen dağınıklığa sahiptir ve net imza modelleri sağlamaz. Dolayısıyla MOUSİ tekniği araç bazlı sistemler için daha uygun olacaktır [58].

3. EVRİŞİMSEL SİNİR AĞLARI

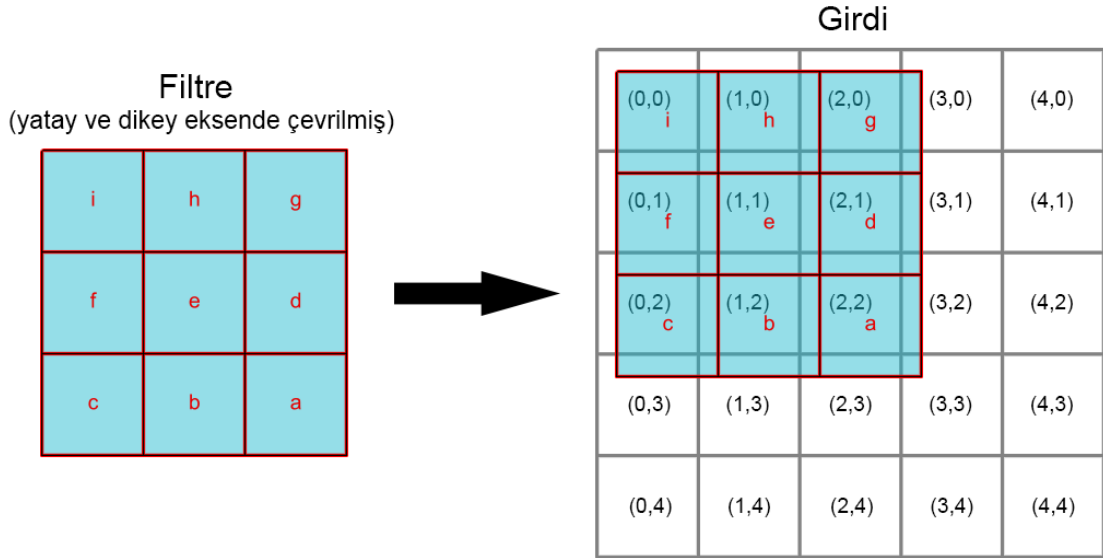
YNR verilerindeki tehditler ve tehdit olmayanlar arasında ayırım yapmak için tasarlanmış algoritmalar üzerine yapılan son çalışmalar, en son teknoloji tespit performansını geliştirmek için bilgisayarla görme yöntemlerini kullanmıştır. Literatürde özellik ayıklayıcılar veya tanımlayıcılar, 2 boyutlu YNR görüntü yamalarını temsil etmede önemli yer tutmaktadır ve gelen tehditlerin sağlam bir şekilde sınıflandırılmasını sağlamaktadır. Son gelişmeler bilgisayarla görme literatüründe daha gelişmiş tekniklerin daha fazla performans iyileştirmeleri sağlayabileceğini göstermektedir. Bir ESA, bir giriş görüntüsünden anlamlı ve ayırt edici özellikler çıkarmak için tasarlanmış bir derin öğrenme yaklaşımıdır. Mimari, bir alt örnekleme süreciyle kaynaşmış bir dizi evrişimli katmandan ve ardından çok katmanlı algılayıcı yapısında gözlemlendiği gibi bir dizi tamamen bağlı katmandan oluşur.

3.1 Bileşenler ve Temel Kavramlar



Şekil 12 ESA mimarisi bileşenleri

- Evrişim işlemi: Giriş görüntüsünden öznitelikleri çıkarmayı amaçlar. Evrişim, küçük giriş verisi kareleri aracılığıyla öğrenme özellikleri gerçekleştirerek pikseller arasındaki uzamsal ilişkiyi depolar. Şekil 12 de görüldüğü üzere her evrişimli katman, kaynak görüntüsü üzerinde bir filtre çekirdeği ile ayrı bir 2D evrişim işlemi gerçekleştirir ve doğrusal olmayan bir transfer işlevi uygular. 2D evrişim işlemi bu işlemi tek bir eksen değil x ve y ekseninde iki eksende bu işlemi yapmaktadır. 2D evrişim görüntü işleme uygulamalarında, görüntünün özelliklerini bulmak için kullanılır. Şekil 13 te 2D evrişim işlemi gösterilmektedir.




Şekil 13 2D evrişim işlemi

Alınacak herhangi bir nokta ile bu nokta için evrişim hesabı yapılabilir. Örnek olarak $y(1,0)$ noktasındaki değeri hesaplanabilir. Aşağıda verilen 3.1 denkleminde i ve j , filtrenin girdi üzerindeki konumlarıdır. Örnekte i ve j 0'dan 2'ye değerler almaktadır.

$$\begin{aligned}
 Y[1,0] &= \sum_i \sum_j x[i,j]h[1-i][0-j] \\
 &= x[0,0]h[1,0] + x[1,0]h[0,0] + x[2,0]h[-1,0] + x[0,1]h[1,-1] + x[1,1]h[0,-1] + \\
 &+ x[2,1]h[-1,-1] + x[0,2]h[1,-2] + x[1,2]h[0,-2] + x[2,2]h[-1,-2]
 \end{aligned} \tag{3.1}$$

- **Havuzlama İşlemi:** Havuzlama, subsampling veya downsampling, farklı havuzlama türlerine bağlı olarak en önemli özellikleri filtreleyerek özellik haritalarının boyutsallığını azaltmayı amaçlamaktadır. Şekil 14'de havuzlama işlemi gösterilmiştir. Temel olanlar şu şekildedir: Maks, Min, Ortalama ve Toplam.



Şekil 14 Maks havuzlama işlemi

Şekil 14'te 2×2' lik filtre ve 2 adım değeri ile yapılan max pooling işleminde en yüksek değer alınarak 2×2' lik bir çıktı elde edilmektedir. Sonuç olarak küçültme işlemi gerçekleştirilmektedir.

Ortalama havuzlamada ortalama değer, Max havuzlama işleminde de en büyük değer alınmaktadır. Min havuzlama işleminde en küçük değer alınmaktadır. Toplam havuzlama işleminde de toplam değer alınmaktadır. Farklı havuzlama yöntemleri farklı modeller için uygulanmaktadır. Popüler derin öğrenme modellerinde kullanılan havuzlama yöntemlerinden bazıları şu şekildedir:


- LeNET = ortalama havuzlama
 - AlexNet = max havuzlama
 - VGGNet = max havuzlama
- Tam Bağlı Katman: Çıktı katmanında softmax aktivasyon işlevine sahip basit bir Çok Katmanlı Algılayıcı (Multi Layer Perceptron - MLP)'dir. Böyle bir aşamanın amacı, giriş görüntüsünü, önceki evrişimli katmanların ürettiği özelliklere dayalı olarak çeşitli sınıflara ayırmaktır.
 - Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu, bir karar işlevi olarak hizmet eder ve karmaşık kalıpların öğrenilmesine yardımcı olur. Uygun bir aktivasyon fonksiyonunun seçilmesi, öğrenme sürecini hızlandırabilir. ESA için aktivasyon fonksiyonu denklemi denklem 3.2 de gösterilmiştir.

$$T_1^k = g_a(F_1^k) \quad (3.2)$$

Yukarıdaki denklemde F_1^k evrişim ağı çıktısı, doğrusal olmayan I 'nci katman için g_a ile çarpılması sonucu aktivasyon fonksiyonu sonucu T_1^k elde edilir.

Literatürde, sigmoid, tanh, maxout, SWISH, ReLU gibi farklı aktivasyon fonksiyonları ve sızdıran ReLU, ELU ve PReLU gibi ReLU varyantları kullanılmaktadır [59], [60], [61] - [63]. Ancak, kaybolan gradyan probleminin üstesinden gelmeye yardımcı oldukları için ReLU ve varyantları tercih edilir [64], [65].

- Dropout: ESA'larda, doğrusal olmayan bir ilişkiyi öğrenen birden fazla bağlantı bazen birlikte uyarlanır ve bu da aşırı uyuma neden olur [66]. Bazı bağlantıların veya birimlerin rasgele bırakılması birkaç inceltilmiş ağ mimarisi üretir ve son olarak, küçük ağırlıklarla bir temsili ağ seçilir. Bu seçilen mimari daha sonra önerilen tüm ağların bir yaklaşımı olarak kabul edilir [67].



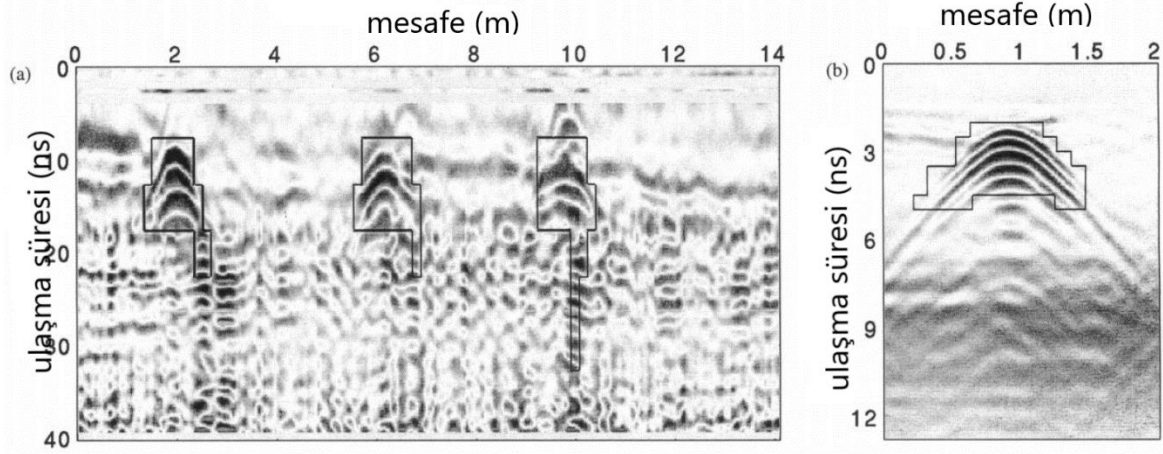
Şekil 15 Örnek bir ESA mimarisi

Şekil 15’de yukarıda anlatılan ESA mimarisi bileşenlerinin oluşturmuş olduğu örnek bir mimariyi göstermektedir.

3.2 Temel Prensipte ve Özellikleri

ESA'ların ana yararı, tamamen bağlı (fully connected) ağlardan daha az parametreye sahip olmalarıdır. Eğitim süreci ESA’da giriş verilerinin alınmasına müteakip katman katman işlemler yapılarak gerçekleştirilir. Doğru sonuç ile karşılaştırma yapabilmek için bir sonuç çıktısı verir. Elde edilen sonuç ile istenen sonuç farkı kadar bir hata elde edilir. Geriye yayılım algoritması hatanın bütün ağırlıklara aktarılması için kullanılır. İterasyonlarla ağırlıkların güncellenmesi yapılarak hatanın azaltılması sağlanır. Test hatasının azalmasının durduğu görüldüğü anda eğitim durdurulur. Sonuç olarak, ağı eğitmek daha kolay bir iştir.

Eđitimli sinir ađı daha sonra, sinir ađına yeni bir radargramdan tam bir radargram zellik setini ve ıktıyı sınıflandırmak iin uygulanabilir. Daha sonra Őekil 15'de gsterildiđi gibi hedef yansımalara karŐılık gelecek Őekilde sınıflandırılan grntnn blmlerini "vurgulamak" iin kullanılır. Radargramın tamamı bylece iki sınıftan birine ait olan blgelere blnecektir. Hedef yansımalar olarak sınıflandırılan bu blgeler, sonraki aŐamalara gre daha fazla iŐlenir.



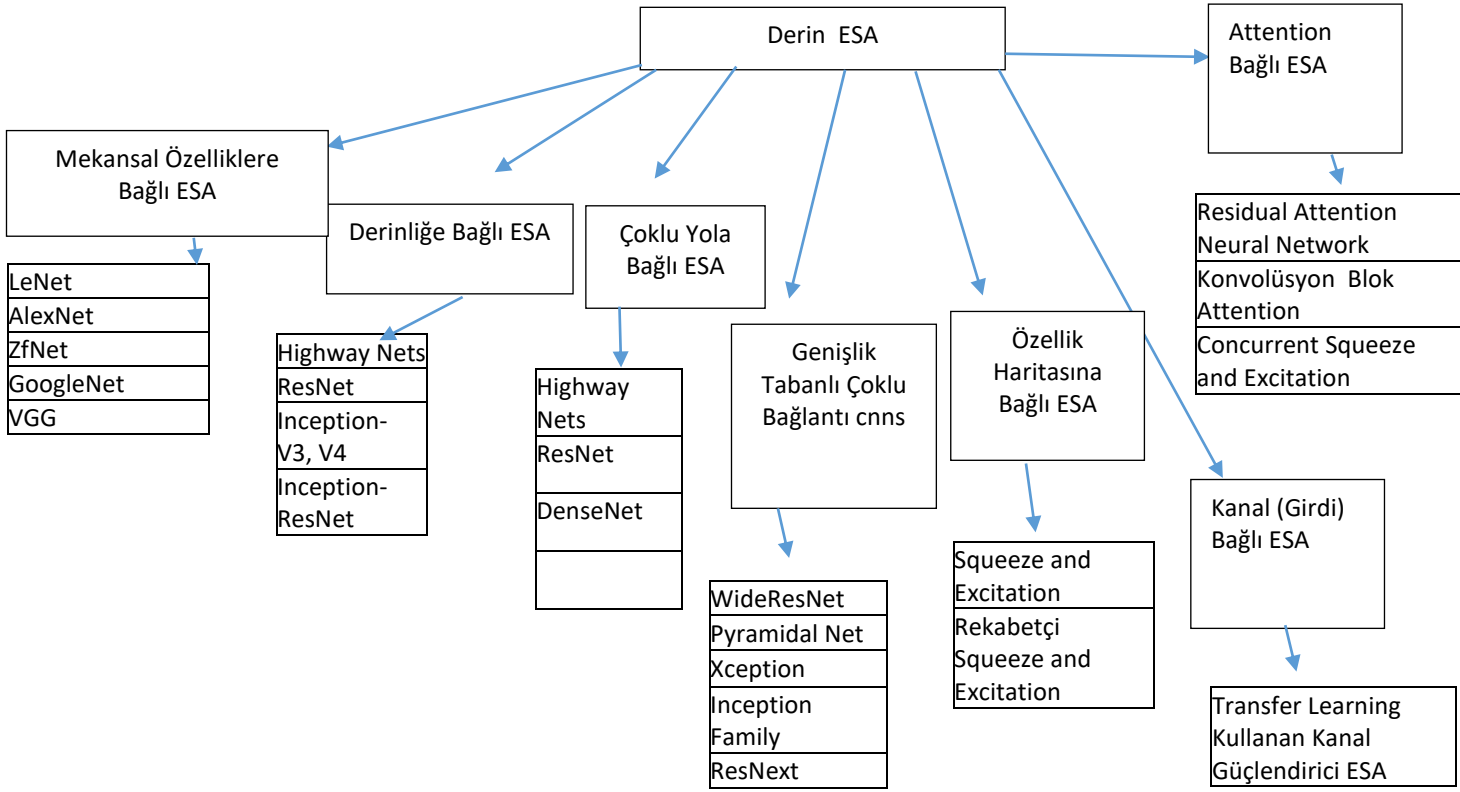
Őekil 16 Yansımaları ieren radargramların tespiti

Őekil 16'da soldaki grnt (elik, plastik ve kil) zerindeki yansımaları ieren radargramların tespitini gstermektedir. Sađdaki grnt ise bir anti personel kara mayını (metal ve plastikten) yansımaları ieren radargramların tespitini gstermektedir.

3.3 Kullanılan Mimariler

1990'ların sonlarından 2000'e kadar ESA'yı byk, heterojen, karmaŐık ve ok sınıflı problemlere leklenebilir hale getirmek iin ESA đrenme metodolojisi ve mimarisinde eŐitli iyileŐtirmeler yapıldı. ESA'lardaki yenilikler, iŐleme birimlerinin modifikasyonu, parametre ve hiper parametre optimizasyon stratejileri, tasarım kalıpları ve katmanların bađlanabilirliđi gibi farklı ynleri ierir. ESA tabanlı uygulamalar, AlexNet'in 2012'de ImageNet veri setindeki rnek performansından sonra yaygınlaŐtı [68]. Bu tarihten itibaren ESA'da nemli yenilikler nerildi ve byk lde iŐleme birimlerinin yeniden yapılandırılmasına ve yeni blokların tasarlanması hedeflendi. Zeiler ve Fergus [69], VGG'de gerekleŐtirildiđi gibi derin mimaride dŐk uzaysal znrlkte zneteliklerin ıkarılması

hedefi ile, öznitelik çıkarma aşamalarının anlaşılmasını iyileştirmek için ESA'nın katman bazında görselleştirilmesi kavramını oluşturdular [70]. Günümüzde, yeni mimarilerin çoğu, VGG'de tanıtılan basit ve homojen topoloji ilkesi üzerine inşa edilmiştir. Google derin öğrenme grubu, başlangıç bloğu olarak bilinen karşılık gelen blokla yenilikçi bir bölme, dönüştürme ve birleştirme fikrini tanıttı. Başlangıç bloğu ilk kez, farklı uzamsal ölçeklerde özelliklerin soyutlanmasına izin veren bir katman içinde dallanma kavramını verdi [71]. 2015 yılında, ResNet [72] tarafından derin ESA'ların eğitimi için sunulan atlama bağlantıları kavramı popülerlik kazandı. Daha sonra bu kavram, Inception ResNet, Wide ResNet, ResNeXt, vb. sonraki ağların çoğu tarafından kullanıldı [73 - 75]. Şekil 17'de ise derin ESA mimarilerinin özelliklerine göre hangi kategoriler içinde yer aldığı gösterilmektedir.



Şekil 17 Yedi farklı kategoriye gösteren derin ESA mimarilerinin taksonomisi

- AlexNet

AlexNet [66], görüntü sınıflandırma ve tanıma görevleri için çığır açan sonuçlar gösteren ilk derin ESA mimarisi olarak kabul edilir. Krizhevesky ve arkadaşları tarafından önerilen AlexNet, ESA'nın öğrenme kapasitesi derinleştirilerek ve çeşitli parametre optimizasyon stratejileri uygulanarak geliştirilmiştir [68]. Genel olarak, derinliğin farklı görüntü çözünürlükleri için genellemeyi geliştirmesine rağmen, derinlikteki artışla ilişkili ana dezavantaj, aşırı uyumdu. Bu zorluğun üstesinden gelmek için, Krizhevesky (2012), Hinton [67], [69] fikrinden yararlanarak, algoritmaları eğitim sırasında bazı dönüşümsel birimleri rastgele atlayarak modeli daha sağlam özellikler öğrenmeye zorladı. Buna ek olarak ReLU, gradyan kaybolması sorununu bir dereceye kadar hafifleterek yakınsama oranını iyileştirmek için doyurucu olmayan bir aktivasyon fonksiyonu olarak kullanıldı [65], [77]. Yapılan diğer ayarlamalar, daha önce önerilen ağlara kıyasla ilk katmanlarda büyük boyutlu filtrelerin (11x11 ve 5x5) kullanılmasıydı.

- VGG

ESA'ların görüntü tanıma görevlerinde başarılı bir şekilde kullanılması, mimari tasarımdaki araştırmaları hızlandırmıştır. Bu bağlamda Simonyan ESA mimarileri için basit ve etkili bir tasarım ilkesi önerdi [70]. Bu bulgulara dayanarak VGG, 11x11 ve 5x5 filtreleri 3x3 filtre katmanından oluşan bir yığınla değiştirdi ve deneysel olarak küçük boyutlu (3x3) filtrelerin eşzamanlı yerleştirilmesinin büyük boyutlu filtrenin (5x5 ve 7x7) etkisini tetikleyebileceğini gösterdi. Küçük boyutlu filtrelerin kullanılması, parametre sayısını azaltarak düşük hesaplama karmaşıklığına ek bir fayda sağlamaktadır. VGG, evrişimli katmanlar arasına 1x1 konvolüsyonlar yerleştirerek bir ağırlık karmaşıklığını düzenler ve bunun yanı sıra ortaya çıkan özellik haritalarının doğrusal bir kombinasyonunu öğrenir. VGG, hem görüntü sınıflandırma hem de yerleştirme sorunları için iyi sonuçlar vermiştir. VGG ile ilişkili temel sınırlama, 138 milyon parametrenin kullanılması sebebiyle hesaplama açısından pahalı ve düşük kaynak sistemlerinde dağıtılmasının zor olmasıdır.

- ResNet

ResNet, 2015-ILSVRC yarışmasını kazanan 152 katmanlı derin ESA önerdi [66], [70]. AlexNet ve VGG'den sırasıyla 20 ve 8 kat daha derin olan ResNet, daha önce önerilen ağlardan [68], [70] daha az hesaplama karmaşıklığı göstermiştir. 50/101/152 katmanlı ResNet görüntü sınıflandırma görevinde 34 katmanlı Düz ve Derin ESA (Plain Deep CNN)'ndan daha az hataya sahip olduğunu deneysel olarak gösterdi. Ayrıca ResNet, COCO [111] adlı ünlü görüntü tanıma kıyaslama veri setinde % 28'lik bir iyileştirme elde etti. ResNet'in görüntü tanıma ve yerleştirme görevlerindeki iyi performansı, temsil derinliğinin birçok görsel tanıma görevi için merkezi bir öneme sahip olduğunu gösterdi.

3.4 Kullanılan Kütüphaneler

Pandas, numpy, seaborn, matplotlib, keras, scikit-learn, tensorflow kütüphanelerinden faydalanılmıştır.

Pandas kütüphanesi veri için okuma ve yazma yapabilen bir kütüphanedir. Çalışmalarda veri çekme işlemleri için kullanılır. Tez çalışmasında ilgili data türlerini okumak maksadı ile bu kütüphaneden faydalanılmıştır [78].

NumPy, matrislerle çalışmaya yardım eden Python diline ait çok boyutlu dizilerle işlemler yapılabilen bir kütüphanedir. Numerik ve açık kaynak bir Python kütüphanesidir. Matris veri yapıları ve çok boyutlu dizin içerir. Numarray ve numeric öğelerinin uzantısıdır. Ayrıca rastgele sayı üreteçlerine vardır. Dizinlerde cebirsel, matematiksel, istatistiksel operasyonlar için kullanılır. Çalışmada dizin ve matris veri yapısından faydalanmak için kullanılmıştır [79].

Seaborn ise Matplotlib kütüphanesine arayüz sağlayan bir kütüphanedir. Ayrıca Seaborn ile estetik olarak varsayılan temaları kullanmaktadır. Göz alıcı istatistiksel grafikler, özel olarak renk paleti, dağılımları esnek bir şekilde sergileme, DataFrame ve matris içindeki bilgileri görselleştirme yapılabilir. Tez çalışmasında ise python kod çıktısında renkli çıktı sonuçları alınması maksadı ile kullanılmıştır [80].

Matplotlib; veri görselleştirmesinde kullanılan temel Python kütüphanesidir. 2 ve 3 boyutlu çizimler yapılmasını sağlar. Tez çalışmasında çıktı sonuçlarında x-y eksenli başlıklarını, tablo başlıklarını oluşturma ve göstermede kullanılmıştır [81].

Keras, Tensorflow veya Theano'yu backend olarak kullanan bir wrapper'dır. Python dilini kullanır. Modelleri tanımlama ve eğitmek için kullanılmıştır. Tez çalışmasında Backend olarak tensorflow kullanılmıştır. Modellenin eğitilmesi tanımlanmasında Keras kütüphanesinden faydalanılmıştır [82].

TensorFlow veri akış çizgelerini kullanarak sayısal hesaplamalar yapmayı sağlar. Keras kütüphanesinde backend kullanılarak model yüklemede ve optimizasyon hesaplanmasında kullanılmıştır [83].

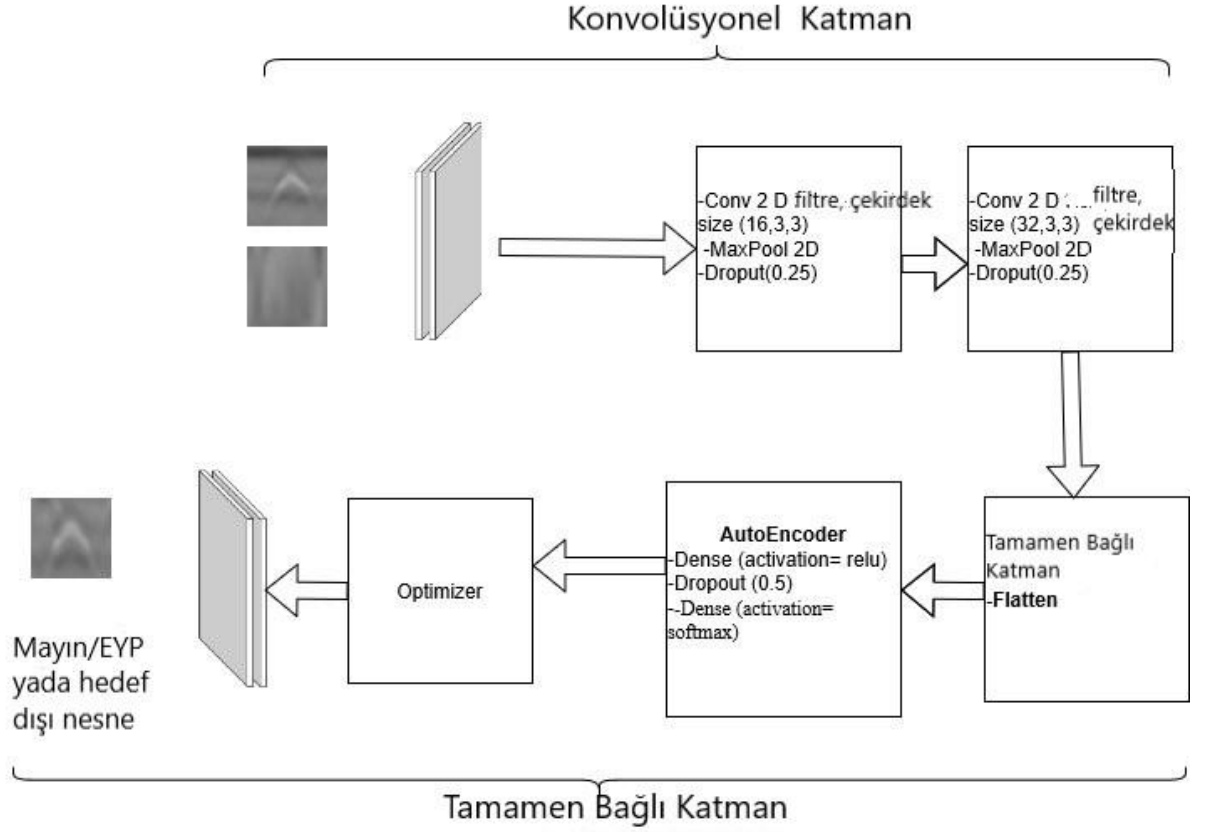
Scikit-learn de kullanılan kütüphanelerden bir diğeridir. Lojistik regresyon, Doğrusal regresyon, rastgele orman, karar ağaçları, gibi temel yöntemleri içermektedir. Tez çalışmasında çapraz doğrulama , veri kümesini bölmek, tespit için kullanılmıştır [84].

4. KULLANILAN YÖNTEM

4.1 Önerilen Mimarinin özellikleri

Şekil 18’de, YNR vasıtasıyla elde edilen B-taramasının kara mayınlarının tespiti için izlemek veya hiperboller içerip içermediğini tespit etmek için önerilen ESA mimarisi gösterilmiştir. Gömülü bir nesne varsa, genellikle hiperbolik iz olarak görünür. Görüntü çoğunlukla doğrusal izler içerdiğinde ise sadece bir toprak tabakası var demektir.

Şekil 18’de gösterilen önerilen ESA mimarisi iki evrişimli katmana, iki maksimum havuz katmanına ve üç ReLU katmanına sahiptir. Ek olarak, aşırı uyumdan kaçınmak için, her biri 0.25 ve 0.5 oranlarına sahip iki dropout işlemi eklenmiştir. Veri kümesindeki çoğu YNR görüntüsünün boyutu 48x48 olduğundan, ESA girişi bu boyuta uyacak şekilde oluşturulmuştur. Eğitim sırasında ESA girişi sabit boyutlu 48×48 gri tonlamalı bir görüntüdür. 50x50 ve 51x51 boyutlarına sahip diğer resimler de bu giriş boyutuna uyacak şekilde kırpılmıştır.



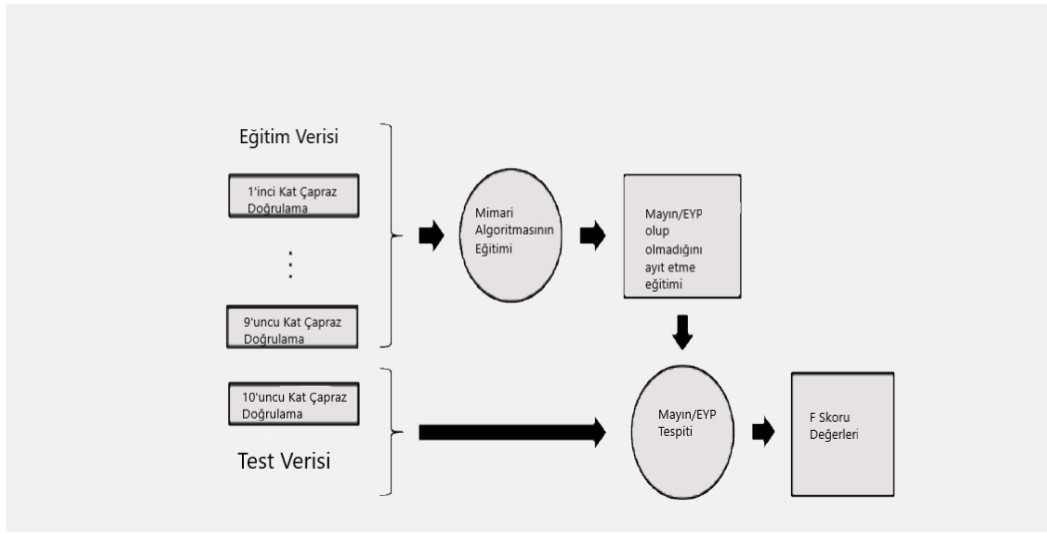
Şekil 18 Önerilen ESA mimarisi

Tasarlanan ESA mimarisi iki evrişimli katmandan, tamamen bağlı katman ve ardından bir soft-max katmanından oluşmaktadır. Evrişimli katman, mayın yada EYP yakalamak için çok küçük bir alıcı alana sahip düz ve düz olmayan filtrelerin (3x3) kullanıldığı iki evrişimli katmandan oluşan bir yığından oluşur. İki katman için dağıtılan filtrelerin sayısı sırasıyla 16 ve 32'dir. Mimari aynı zamanda birinci ve ikinci konvolüsyonel katmanı izleyen iki maksimum havuz katmanı içerir. Maksimum havuzlama, 2×2 piksellik bir pencere üzerinde gerçekleştirilir. Eğitimde aşırı uyumu önlemek ve karar işlevini daha ayırıcı hale getirmek için bir düzeltme işlevi (ReLU) aracılığıyla verilere doğrusal olmama özelliği eklenmiştir. Tamamen bağlı katman bloğu, bir flatten katmanı ve Autoencoder katmanından oluşmaktadır. Bunları takiben de soft-max katmanı gelmektedir.

Tüm ağ, doğrulama kaybında 5 iterasyona kadar bir düşüş olup olmadığını tespit için Adam optimizier kullanılarak eğitilmiştir.

4.2 Eğitimin Detayları

Bu bölümde kullanılan deneysel tasarımın ayrıntıları sunulmaktadır. Tüm bu çalışmalar, 2.90 GHz hızında Intel i7- işlemciye ve 8 GB RAM'e sahip bir sistem üzerinde gerçekleştirildi. Önerilen mimarinin algoritma performansı kendi içinde parametreleri değiştirilerek ölçülmekte ve diğer mimariler ile de karşılaştırılmaktadır. Daha da önemlisi, önerilen mimarinin hangi parametrelerle daha iyi sonuç verdiği araştırılmaktadır. Aşırı uyumdan (Overfitting) kaçınmak için, her biri 0.25 ve 0.5 oranlarına sahip iki dropout işlemi uygulanmaktadır. Elde edilen örneklerin yalnızca %10'u, ESA mimarisini eğitmek için rastgele seçilir.



Şekil 19 Mayın EYP tespiti için kullanılan 10lu çapraz doğrulama prosedürünün şekli

Şekil 19'da eğitim verisi ve test verisi gösterilmiştir. Bu işlem, yeni, YNR verilerinde tehdit çıkarımı (Mayın/EYP) için kullanılabilecek eğitilmiş bir tespit algoritması sağlar. Eğitilmiş algoritma, eğitimden alınmış çapraz doğrulama verisi ile tehdit çıkarımı için uygulanır. Bu, her bir ön tarama alarmının gerçek bir gömülü tehdide karşılık gelme olasılığını gösteren F Skor değer istatistikleri listesini verir. Bu işlem 10 defa gerçekleştirilir, böylece her şerit tehdit çıkarımı için tam olarak bir kez kullanılır. Her şeritten alınan F skor istatistikleri daha sonra toplanır.

- Algoritma Çalışma Süresi

Bu bölüm, burada karşılaştırılan algoritmalar için hesaplama çalışma süresinin bir tablosunu sağlar.

Tablo 2 Çeşitli Parametrelere Göre ve Sunulan Mimariye Göre Ortalama Eğitim Süresi

	Eğitim Süresi Ortalama(sn)
Drop Out 0.25-0.50-0.50	132.064
Drop Out 0.25-0.40-0.50	132.714
Sunulan Model	136.748
AutoEncoder Down Sampling	139.155
Optimizasyon RMSProp	150.047
Optimizasyon SGD	173.189
Filtre Sayısı 16 64	192.825
Filtre Sayısı 32 64	249.832
VGG16 Net	5.226.086
AlexNet	10.135.813
ResNet	15.952.486

Tablo 2’de, sunulan mimarinin bazı özellikleri değiştirilerek ortalama eğitim sürelerinin en azdan en fazla olana olacak şekilde sıralanması gösterilmektedir. Değiştirilen parametreler drop-out oranları, autoencoder down sampling, optimizasyon, filtre sayıları ve diğer mimarilerdir. Kıyasta kullanılan parametre değerleri ve optimizasyonlar literatürde kabul gören değerlerdir. Sunulan mimarimizde dropout oranları olarak 0.25-0.25-0.50 kullanılmıştır. Filtre olarak 16-32 kullanılmıştır. Optimizasyon olarak adam optimizasyonu kullanılmıştır. Tablodan da anlaşılacağı üzere sunulan mimari VGG16 Net, AlexNet ve ResNet’e göre eğitim zamanı yönünden daha kısa sürmüştür. Drop out oranları dışında diğer özellikler yönünden eğitim süresi daha kısa sürmüştür.

- Çapraz Doğrulama Yöntemi ile Kıyaslama

Tablo 3 Sunulan Mimarinin K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim
					Zamanı (sn)
1	0,966	0,99	0,944	0,967	134,404
2	0,991	0,988	0,994	0,991	138,210
3	0,991	0,99	0,991	0,991	136,622
4	0,988	0,987	0,987	0,987	135,002
5	0,99	0,989	0,99	0,99	140,140
6	0,988	0,989	0,988	0,988	141,061
7	0,989	0,982	0,995	0,988	136,202
8	0,986	0,981	0,99	0,985	135,493
9	0,99	0,992	0,987	0,99	135,696
10	0,98	0,991	0,967	0,979	134,646
ortalama	0,9859	0,9879	0,9833	0,9856	136,748

Sunulan mimari çapraz doğrulama yönteminde Tablo 3'den de anlaşılacağı üzere büyük fark bulunmamaktadır.

Tablo 4 Sunulan Mimarinin (Dropout 0.25- 0.40- 0.50 Oranlı) K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,979	0,989	0,965	0,977	134,339
2	0,984	1	0,968	0,983	133,838
3	0,978	0,992	0,963	0,977	134,118
4	0,975	0,993	0,956	0,974	133,012
5	0,981	0,995	0,967	0,98	133,121
6	0,969	0,99	0,949	0,969	132,667
7	0,973	0,92	0,955	0,974	133,402
8	0,976	0,993	0,957	0,975	129,635
9	0,976	0,995	0,958	0,976	132,850
10	0,971	0,997	0,946	0,971	130,154
ortalama	0,9762	0,9864	0,9584	0,9756	132,714

Sunulan mimarinin Dropout 0.25- 0.40- 0.50 oranlı hali Tablo 4'den de anlaşılacağı üzere 2'nci çapraz doğrulamadan sonra performans değerleri düşmektedir.

Tablo 5 Sunulan Mimarinin (Dropout 0.25- 0.50- 0.50 Oranlı) K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,972	0,982	0,963	0,973	130,000
2	0,978	0,995	0,962	0,978	134,731
3	0,969	0,991	0,945	0,968	131,327
4	0,976	0,992	0,958	0,975	131,423
5	0,97	0,989	0,951	0,97	133,560
6	0,972	0,985	0,956	0,97	133,071
7	0,971	0,99	0,948	0,969	132,457
8	0,975	0,987	0,961	0,974	131,731
9	0,967	0,99	0,946	0,968	131,475
10	0,972	0,988	0,954	0,971	130,861
ortalama	0,9722	0,9889	0,9544	0,9716	132,064

Sunulan mimarinin Dropout 0.25- 0.50- 0.50 oranlı hali tablo 5' den de anlaşılacağı üzere 2'nci çapraz doğrulamadan sonra performans değerleri düşmektedir.

Tablo 6 Sunulan Mimarinin (Filtre Sayıları 16-64) K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,971	0,989	0,951	0,97	172,999
2	0,975	0,998	0,951	0,974	211,170
3	0,982	0,984	0,98	0,982	189,580
4	0,982	0,981	0,983	0,982	200,599
5	0,987	0,988	0,984	0,986	194,885
6	0,986	0,982	0,987	0,985	190,252
7	0,987	0,987	0,987	0,987	193,833
8	0,983	0,982	0,983	0,983	194,199
9	0,988	0,99	0,987	0,988	193,029
10	0,988	0,985	0,99	0,988	187,700
ortalama	0,9829	0,9866	0,9783	0,9825	192,825

Sunulan mimarinin filtre sayıları 16-64 olan hali tablo 6'dan da anlaşılacağı üzere performans değerlerinde net bir düşüş gözlemlenmemektedir.

Tablo 7 Sunulan Mimarinin (Filtre Sayıları 32-64) K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,979	0,985	0,972	0,978	246,802
2	0,984	0,985	0,982	0,984	256,645
3	0,987	0,989	0,985	0,987	257,192
4	0,979	0,988	0,968	0,978	239,462
5	0,979	0,995	0,963	0,978	239,258
6	0,986	0,986	0,985	0,986	242,228
7	0,983	0,982	0,983	0,982	244,877
8	0,987	0,993	0,983	0,988	254,856
9	0,99	0,995	0,984	0,989	257,719
10	0,991	0,992	0,99	0,991	259,279
ortalama	0,9845	0,989	0,9795	0,9841	249,832

Sunulan mimarinin filtre sayıları 32-64 olan hali tablo 7’den de anlaşılacağı üzere performans değerlerinde net bir düşüş gözlemlenmemektedir.

Tablo 8 AlexNet Mimarisinin K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,691	0,981	0,379	0,547	10.002,969
2	0,685	0,993	0,373	0,543	10123,730
3	0,701	0,986	0,414	0,583	10.183,431
4	0,692	0,97	0,41	0,576	10.035,586
5	0,713	0,964	0,425	0,59	10.000,002
6	0,702	0,975	0,411	0,579	10039,41
7	0,692	0,961	0,419	0,583	10198,979
8	0,706	0,95	0,429	0,592	10519,211
9	0,704	0,981	0,418	0,586	10.123,113
10	0,713	0,965	0,448	0,612	10131,695
ortalama	0,6999	0,9726	0,4126	0,5791	10.135,813

AlexNet performans değerlerinde çapraz doğrulama sayıları arasında net bir değişiklik olmamıştır.

Tablo 9 ResNet Mimarisinin K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,986	0,987	0,984	0,985	15.597,184
2	0,989	0,989	0,989	0,989	15757,795
3	0,994	0,995	0,994	0,994	15.843,140
4	0,991	0,991	0,991	0,991	15.958,357
5	0,993	0,988	0,997	0,992	16.019,746
6	0,994	0,994	0,994	0,994	15947,728
7	0,992	0,991	0,992	0,992	15971,438
8	0,993	0,994	0,992	0,993	16233,7
9	0,993	0,991	0,994	0,993	16.064,933
10	0,991	0,99	0,992	0,991	16130,839
ortalama	0,9916	0,991	0,9919	0,9914	15.952,486

ResNet performans değerlerinde çapraz doğrulama sayıları arasında net bir değişiklik olmamıştır.

Tablo 10 VGG16 Mimarisinin K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,703	0,834	0,492	0,619	4.944,147
2	0,702	0,84	0,488	0,618	5176,143
3	0,703	0,852	0,474	0,609	5.249,121
4	0,685	0,823	0,484	0,61	5.292,213
5	0,71	0,849	0,507	0,635	5.390,752
6	0,717	0,856	0,516	0,644	5311,304
7	0,699	0,814	0,489	0,611	5384,313
8	0,708	0,825	0,514	0,633	5259,897
9	0,706	0,849	0,498	0,628	5.088,194
10	0,715	0,82	0,522	0,638	5164,780
ortalama	0,7048	0,8362	0,4984	0,6245	5226,086

VGG16 performans deęerlerinde apraz doęrulama sayıları arasında net bir deęişiklik olmamıştır.

Tablo 11 Sunulan Mimarinin (RMSProp Optimizasyon) K-Fold Performansı

Kth-fold	Doęruluk	Kesinlik	Duyarlılık	F-Skor	Eęitim Zamanı (sn)
1	0,907	0,974	0,84	0,902	127,391
2	0,915	0,92	0,909	0,915	221,407
3	0,917	0,935	0,905	0,92	213,571
4	0,911	0,962	0,857	0,907	130,165
5	0,913	0,947	0,87	0,907	137,070
6	0,911	0,932	0,886	0,908	133,584
7	0,921	0,952	0,889	0,919	133,297
8	0,916	0,942	0,881	0,91	136,172
9	0,914	0,949	0,874	0,91	134,469
10	0,917	0,937	0,89	0,913	133,340
ortalama	0,9142	0,945	0,8801	0,9111	150,047

Sunulan mimarinin RMSProp ile optimizasyon deęerlerinde apraz doęrulama sayıları arasında net bir deęişiklik olmamıştır.

Tablo 12 Sunulan Mimarinin (SGD Optimizasyon) K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,915	0,954	0,877	0,914	130,209
2	0,91	0,943	0,868	0,904	130,099
3	0,923	0,955	0,889	0,921	129,601
4	0,916	0,948	0,875	0,91	128,184
5	0,914	0,945	0,877	0,91	128,945
6	0,913	0,955	0,873	0,912	128,756
7	0,921	0,952	0,889	0,907	127,633
8	0,914	0,936	0,887	0,911	297,407
9	0,916	0,954	0,869	0,909	309,232
10	0,917	0,968	0,868	0,915	221,821
ortalama	0,9159	0,951	0,8772	0,9113	173,189

Sunulan mimarinin SGD ile optimizasyon değerlerinde çapraz doğrulama sayıları arasında net bir değişiklik olmamıştır.

Tablo 13 Autoencoder Downsampling K-Fold Performansı

Kth-fold	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
1	0,979	0,982	0,975	0,978	123,383
2	0,983	0,984	0,982	0,983	143,774
3	0,984	0,979	0,99	0,984	141,761
4	0,987	0,988	0,987	0,987	139,365
5	0,982	0,981	0,982	0,982	143,022
6	0,983	0,994	0,971	0,982	137,457
7	0,986	0,992	0,978	0,985	137,363
8	0,989	0,99	0,988	0,989	140,163
9	0,989	0,994	0,985	0,989	140,754
10	0,986	0,99	0,982	0,986	144,510
ortalama	0,9848	0,9874	0,982	0,9845	139,155

AutoEncoder DownSampling çapraz doğrulama sayıları arasında net bir deęişiklik olmamıştır.

4.3 En Uygun Parametrelerin Bulunması

Tablo 14 Confusion Matrix

Tahminlenen

Gerçekleşen	True Positives (TP)	False Negatives (FN)
	False Positives (FP)	True Negatives (TN)

TP ve TN modelin doğru olarak, FP ve FN ise modelin yanlış tahminlediği alanlardır.

True Positive : Gömülü cismin mayın/EYP olarak tahmin edildiği ve tahminin doğru çıktığı sonuçtur.

True Negative : Gömülü cismin mayın/EYP olarak tahmin edilmediği ve tahminin doğru çıktığı sonuçtur.

False Positive : Gömülü cismin mayın/EYP olarak tahmin edildiği ve tahminin yanlış çıktığı sonuçtur.

False Negative : Gömülü cismin mayın/EYP olarak tahmin edilmediği ve tahminin yanlış çıktığı sonuçtur.

Doğruluk (Accuracy) değeri şu şekilde hesaplanmaktadır; doğru tahmin edilen bölgenin toplam veri kümesine oranlanması ile hesaplanmaktadır. Eğer 100 mayın/EYP den oluşan bir alanda 95 mayın/EYP doğru tahmin edilirse doğruluk değeri %95 olacaktır.

$$(TP+TN)/(TP+FP+TN+FN) \quad (4.1)$$

Denklem 4.1 doğruluk oranını vermektedir.

Kesinlik (Precision) ise doğru olarak tahminlenen değerlerin kaç adedinin doğru olduğunu göstermektedir. Kesinlik değeri denklem 4.2'deki formül ile hesaplanmaktadır.

$$\text{Kesinlik} = TP/(TP+FP) \quad (4.2)$$

Kesinlik değeri özellikle FP tahmininin maliyet olarak yüksek olduğu durumlar için önemlidir.

Duyarlılık (Recall) ise doğru olarak tahmin edilmesi gereken işlemlerin ne kadarının Positive olarak tahmin edildiğini gösteren bir metriktir. Duyarlılık değeri denklem 4.3'deki formül ile hesaplanmaktadır.

$$\text{Duyarlılık} = \text{TP}/(\text{TP}+\text{FN}) \quad (4.3)$$

Duyarlılık değeri de FN olarak tahmin maliyetinin yüksek olduğu durumlar için yardımcı olacak bir metriktir. Yüksek olması önemlidir.

F1 skor değeri Kesinlik ve Duyarlılık değerlerinin harmonik ortalamasını göstermektedir.

Harmonik ortalama olmasının sebebi uç durumların da gözardı edilmesidir. Basit bir ortalama hesaplamasında doğruluk değeri 1 ve duyarlılık değeri 0 olan bir modelde F1 skoru 0.5 olarak çıkacaktı ve yanıltıcı bir sonuç olacaktı.

$$F1=2* ((\text{duyarlılık}*\text{kesinlik})/ (\text{duyarlılık} +\text{kesinlik})) \quad (4.4)$$

F1 skoru denklem 4.4'teki formül ile hesaplanır.

Doğruluk yerine F1 Skor değerinin kullanılmasının sebebi eşit dağılmayan veri setinde hatalı bir model seçimi yapmamak içindir. Ayrıca sadece FN ya da FP değil tüm hata maliyetlerini ölçme metriğine ihtiyaç duyulduğu için F1 skoru çok önemlidir.

4.3.1 Filtre Sayısı Kıyaslanması


Filtre sayısı olarak 3 farklı deneme yapılmıştır. Birinci ve ikinci evrimsel ağda sırası ile 16-32, 16-64, 32-64 filtre sayıları kullanılmıştır. Bu kullanılan 3 filtre sayısında en iyi sonuç 16-32 filtre sayısında elde edilmiştir. Bu nedenle sunulan mimaride 16-32 filtre sayısı kullanılmıştır. Kullanılan aynı mimarinin filtre sayıları 16-64 ve 32-64 olan sonuçları, sunulan mimari ile kıyaslanmıştır ve Tablo 15 de gösterilmiştir.

Tablo 15 Farklı Filtre Sayılarının Performans Değerlerinin Kıyaslanması

	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
Sunulan Model	0,9859	0,9879	0,9833	0,9856	136,748
Filtre Sayısı 16 64	0,9829	0,9866	0,9783	0,9825	192,825
Filtre Sayısı 32 64	0,9845	0,9890	0,9795	0,9841	249,832

4.3.2 Dropout Oranlarının Kıyaslanması

Genel olarak, dropout, eğitim sırasında belirli bir katmandaki her düğümün çıktısını $1-p$ (p tipik olarak 0,5'e eşittir) olasılıkla 0'a ayarlayarak çalışır. Çıkarılan düğümler, parametre güncellemelerine katkıda bulunmaz. Test sırasında tüm düğümler kullanılır ancak çıktılar olasılık p ile ağırlıklandırılır. Bu stratejinin ardından, yeni bir eğitim örneği sunulduğu zaman, ağ farklı bir mimariyi örnekler ve eğitir. Başka bir deyişle, Dropout bir ağlar grubunu eğitir (2^N ağları, N de düğüm sayısını ifade etmektedir.) aynı anda geleneksel toplulukla karşılaştırıldığında eğitim süresinde önemli bir hızlanmaya yol açar.



Şekil 20 Dropout sinir ağı modeli

Şekil 20'de soldaki ağ standart bir sinir ağıdır. Sağdaki ise dropout uygulandıktan sonraki aynı ağıdır.

3 farklı dropout oranı kullanılmıştır. Bunlar 0,25-0,50-0,50 ikinci dropout oranı 0,25-0,40-0,50 ve üçüncü olarak da 0,25-0,40-0,50 dropout oranları kullanılmıştır. En iyi sonuç 0,25-0,25-0,50 dropout oranında elde edilmiştir. Bu nedenle mimaride Dropout oranı olarak 0,25- 0,25- 0,50 kullanılmıştır. Kullanılan aynı mimari dropout oranları 0,25-0,40-0,50 ve 0,25-0,50-0,50 kullanılarak, sunulan mimari ile kıyaslanmıştır ve Tablo 16 da gösterilmiştir.

Tablo 16 Dropout Oranlarının Performans Değerlerinin Kıyaslanması

	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
Sunulan Model	0,9859	0,9879	0,9833	0,9856	136,748
Drop Out 0.25-0.40-0.50	0,9762	0,9864	0,9584	0,9756	132,714
Drop Out 0.25-0.50-0.50	0,9722	0,9889	0,9544	0,9716	132,064

4.3.3 Optimizasyon Çeşidine Göre Kıyaslanması

3 farklı optimizasyon yöntemi denenmiştir. Kullanılan yöntemler; Adam optimizasyonu, RMSProp ve SGD'dir. En iyi sonuç Adam Optimizasyonda elde edilmiştir. Dolayısı ile mimaride bu optimizasyon yöntemi kullanılmıştır. Sunulan mimaride kullanılan Adam optimizasyonu ve diğer optimizasyon yöntemleri olan RMSProp ve SGD kıyaslanmıştır ve sonuçları tablo 17 de gösterilmiştir.

Tablo 17 Optimizasyonların Performans Değerlerinin Kıyaslanması

	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
Sunulan Model	0,9859	0,9879	0,9833	0,9856	136,748
Optimizasyon RMSProp	0,9142	0,9450	0,8801	0,9111	150,047
Optimizasyon SGD	0,9159	0,951	0,8772	0,9113	173,189

4.3.4 AutoEncoder-Downsampling Kıyaslanması

Normal evrişim (adımsız) işlemi, giriş görüntüsü ile aynı boyutta çıktı görüntüsü verir, örn. Adım (stride) 1 ve dolgu (padding) 1 ile 4x4 giriş görüntüsünde 3x3 çekirdek (filtre) evrişimi aynı boyutta çıktı verir.

Ancak autoencoder-downsamplingde, yani giriş görüntüsünün boyutunda, örn. Adım (stride) 2 ve dolgu (padding) 1 ile 3x3 evrişim, 4x4 boyutundaki resmi 2x2'ye dönüştürür.

Tasarlanan mimari autoencoder downsamplingli yöntem ile kıyaslanmıştır. Sunulan model sonucu daha iyi bir sonuç elde etmiştir. Tablo 18 de sonuçlar gösterilmektedir.

Tablo 18 Autoencoder-Downsampling Performans Değerleri İle Kıyaslanması

	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
Sunulan Model	0.9859	0.9879	0.9833	0.9856	136.748
AutoEncoder Down Sampling	0.9848	0.9874	0.982	0.9845	139.155

4.4 Sonuçlar

Dört farklı mimarinin her birinde (sunulan mimari, AlexNet, VGG16Net, ResNet), Test / Eğitim Birleşik Çerçeve sistemi ile kullanılmak üzere uygulandı. Veriler rastgele eğitim, test verisi olmak üzere bölüm 4.2 de açıklandığı gibi 2 gruba bölündü. İlgili çalışma Anaconda Navigator üzerinde Windows işletim sistemi ile gerçekleştirilmiş ve Python dili ile geliştirilmiştir.

8664 pozitif ve 8596 negatif YNR görüntülerinden oluşan bölüm 2.2 de açıklanan veri seti kullanılmıştır. Sınıflandırma performansını değerlendirmek için doğruluk, kesinlik, duyarlılık, F-skoru gibi ölçütler kullanıldı.

Tablo 19 En uygun parametreler ile oluşturulan mimarinin diğer yöntemler ile kıyaslanması

	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitim Zamanı (sn)
Sunulan Model(16-32 filtre sayısı, 0,25-0,50-0,50 dropout oranı, Adam optimizasyonu)	0,9859	0,9879	0,9833	0,9856	136,748
AlexNet	0,6999	0,9726	0,4126	0,5791	10135,813
ResNet	0,9916	0,991	0,9919	0,9914	15952,486
VGG16 Net	0,7048	0,8362	0,4984	0,6245	5226,086

Sistemde, çapraz doğrulama olarak (burada her bir mayın şeridi, eğitim için kullanılan şeritlerin geri kalanıyla birlikte bir test seti olarak değerlendirilir) 10 katlı çapraz doğrulama stratejisi uygulandı. Amaç, beş performans kriterini basitçe en aza indirmektir: Eğitim ve test setlerine kıyasla yanlış pozitifler ve negatifler (FP, FN; FP, FN) ve ayrıca ortalama eğitim süresidir.

Erken durdurma genellikle ezberlemeyi önlemek için kullanılır. Erken durdurma kriteri için yineleme sayısı 5'e, eğitim deneme sayısı 5'e ayarlandı.

Bu tez çalışmasında 10 Katlı çapraz doğrulama yöntemi ile sunulan mimari daha güvenilir sonuçlar elde edilmesi düşünülmüştür. Sunulan mimari ile ResNetin hariç diğer mimariler ve Auto Encoder Downsampling'e göre daha iyi sonuç elde edilmiştir. Doğruluk oranları kıyaslandığında da yine ResNet dışındaki diğer tüm yöntemlere göre başarının daha yüksek olduğu görülmektedir. Aynı yorumu kesinlik değerlerinin kıyası için de yapmak mümkündür. Sunulan mimari için başarıyı en fazla yapan filtre sayıları 32 64, drop out oranları ise 0.25-0.50-0.50 olarak bulunmuştur. Duyarlılık yönünden incelendiğinde de yine ResNet dışındaki yöntemlere üstün geldiği görülmüştür. F1 skoru ile yapılan kıyaslama da bu sonucu doğrulamaktadır.

Elde edilen sonuçlara göre ResNet mimarisinin değerleri en yüksek görünse de performans farkı %1'in altındadır. Eğitim sürelerine bakıldığında ise sunulan mimarinin ResNet'e göre 100 kattan daha hızlı olduğu gözlenmiştir (Tablo 19). Askeri harekatta,

harekatın devamlılığı ve hızı için Mayın/EYP gibi tespitin hızlı bir şekilde yapılması gerekmektedir. Dolayısı ile sunulan mimarinin askeri uygulamalarda ResNet'e göre daha kullanışlı olduğu söylenebilir.

4.5 Çalışmanın Katkısı

Bu tezin araştırmasında, tespit sonucunu iyileştirmeye ve mayın/EYP tespiti için yanlış alarm oranlarını azaltmaya çalışan bir teknik araştırılmış ve önerilmiştir. Algoritma geliştirme çabaları, mayın algılama sistemine uygun algoritmalar geliştirmeye yöneliktir. Bu tür herhangi bir sistemde, yanlış alarmlar sistemin ilerlemesini geciktirecektir ve en önemlisi can kaybına sebep verecektir.

Bu çalışmada mimariler arasındaki kavramsal farklılıklar ve sunulan mimarinin kendi özellikleri kıyaslanarak ve elde edilen sonuçlara dayanarak, çalışmada kullanılan ve sunulan farklı mimarilerin kendi içinde farklı özellikleri kıyaslanarak sonuçlar elde edilmiştir.

Gömülü cisimlerin tespitinin hayati öneme haiz olması ve hızlı bir şekilde karar verebilmek adına bu mimari tasarlanmıştır. Pozitif ve negatif resimlerde de gösterildiği üzere pozitif resimleri daha hızlı ve yüksek yüzde ile elde etmek adına geliştirilmiştir. Avantaj ve dezavantajları diğer parametrik yöntemlerle ve mimarilerle kıyaslanmıştır.

Bu çalışmada hedeflenen amaç, çeşitli farklı yerlerde otomatik bir tespit sisteminde kullanım uygunluklarını belirlemek için bir kara mayını ayırmacılık algoritmaları koleksiyonunu değerlendirmektir. 8664 pozitif ve 8596 negatif YNR görüntüsü toparlanarak bir değerlendirme gerçekleştirilmiştir.

Ayrıca, aynı veri seti ile yapılan başka bir çalışmada kara mayınlarına nüfuz eden veriler üzerinde % 92,4 bir doğrulama elde edilmiştir [11]. Bu tezde sunulan ESA mimarisi bu sonuca göre bir üstünlük sağlayabilmiştir.

Sonuç olarak;

1. Mimaride doğruluk oranı, duyarlılık ve F1 skoru açısından sunulan mimari ResNet dışındakilere göre iyi sonuçlar vermektedir. Ancak, ResNet ile çok

yakın performans sergilediğinden ve de ResNet'e kıyasla eğitimi çok daha hızlı olduğundan, daha üstün bir çözüm olduğu söylenebilir.

2. Kesinlik değeri yanlış pozitif tahminin maliyeti yüksek olduğu durumlarda önemlidir. Bu tezde incelenen durumda da mayın EYP tahmininde mayın EYP olarak tespit edilenlerinin gerçekte kaçının mayın EYP olduğu önem kazanmaktadır. Bu açıdan incelendiğinde, sunulan mimarinin drop out oranı 0.25-0.50-0.50 ve filtre sayısı 32-64 olan halinin kullanılması daha iyi sonuç elde edilmesini sağlayacaktır.
3. Ortalama eğitim süresi yönünden sunulan mimarinin 0.25-0.50-0.50 dropoutlu oranı diğer mimarilere göre en kısa sürede cevap vermektedir.

4.6 Geleceğe Yönelik Çalışmalar ve Sonuç

Bu tez çalışmasında, çeşitli teknikler uygulanmıştır ve YNR görüntüsünün analizi için bir algoritma önerilmiştir. Bu bölümde elde edilen sonuçlar sunulmuştur. Belirlenen mimarilere göre, filtre sayılarına göre, drop out oranlarına göre, optimizasyon ve aotoencoder downsampling özelliklerine göre sonuçlar kıyaslanmıştır. Bundan sonra, ne tür bir mimarinin kullanılmasının daha iyi sonuçlar sunacağına dair çıkarımlarda bulunulmuştur. Son olarak, özelliklere ilişkin ek bilgiler sağlayan sonuçların bir analizi sunulmuştur.

Bu tezde, YNR verilerinde mayın EYP tespiti için yeni bir ESA mimarisi önerilmiştir. Önerilen mimari belirlenen mimarilere göre, filtre sayılarına göre, drop out oranlarına göre, optimizasyon ve aotoencoder downsampling yöntemine göre kıyaslanmıştır. Tasarlanan model ile diğer sınıflandırma tekniklerinden daha yüksek veya benzer sonuçlar elde edilmektedir. Literatürde bulunan en iyi sonuçlara benzer bir performans sergilemelerine rağmen, çok daha küçük karmaşıklığa sahip mimari sunulmuştur.

Sonuç olarak, bu çalışma gömülü nesnelere veri seti için bir ESA modeli önererek kara mayını/EYP tespit problemini ele almıştır. Deneysel sonuçlardan ortalama algılama performansının doğruluk açısından %98,59'un üzerinde olduğu görülmektedir.

Ek olarak, önerilen model, VGG-16, AlexNet, ResNet gibi önceden eğitilmiş diğer ESA modellerine kıyasla basit bir mimariye sahiptir, bu da daha az bellek gerektirmesini ve daha hızlı eğitilmesini sağlamaktadır.

Gömülü nesnelere değişen koşullar altında şekil değiştirebildiğinden, sistemin daha sağlıklı çalışabilmesi adına çok çeşitli eğitim veri kümesine sahip olmak çok önemlidir.

Bu tezde ortaya çıkabilecek fikirlerden bir tanesi de, arazide, askeri operasyon alanlarında mayın/EYP tespiti için yapılabilecek bir otomatik anormallik / hedef yazılım dedektörü tasarımıdır. Önerilen mimari ile tespit ve doğruluk oranı daha yukarılara çıkarılarak karar destek mekanizmasında daha da etkili olabilir.

Yere nüfuz eden radar, toprak altı yapıların ve farklı nesne karakterizasyonlarının tanımlanmasına olanak tanıyan hayati bir uygulama ile ilgili aktif bir araştırma teknolojisidir. YNR imzalarının kullanılması, konumun belirlenmesine ve gömülü hedeflenen nesnelere hakkında maddi bilgiler toplanmasına imkan sağlar. Bu nedenle, jeologlara, askeri personele radargram görüntülerinin analizinde yardımcı olabilecek bir hesaplamalı akıllı uygulamanın varlığı önemlidir. Tasarlanan bu mimari personele karar destek mekanizmasında yardımcı olacaktır.

Genel olarak, ESA mimarisi tespit sonuçları SVM ile karmaşıklık yönünden aynıdır fakat doğruluk oranı yüksektir. MOGA yaklaşımı, Viola Jones kademelerinden daha yüksek sonuçlar elde etmektedir. MOGA ile karşılaştırsak, ESA modellerinin muazzam karmaşıklığına rağmen doğruluk oranı yönünden ESA tercih edilmelidir. Çünkü küçük bir hata veya yanlış kötü sonuçlar doğurabilir.

Aktif öğrenme, kullanılan pasif öğrenme prosedürünün aksine, eğitim setine dahil edilecek eğitim için mevcut setten en bilgilendirici örneklerin seçilmesinden oluşur. Sistem daha sonra eğitimde kullanılan veri örneklerini, öğrenme ilerledikçe kötü sınıflandırılmış kalıpları dahil ederek aktif olarak değiştirir. Bu nedenle daha iyi sonuçlar elde edilmesi adına aktif öğrenme de ileriki çalışmalarda kullanılabilir.

Tespit kalitesi, büyük ölçüde eğitim için mevcut verilerin kalitesine bağlıdır. Ayrıca, her YNR sistemi, uygulama alanına bağlı olarak da değişen farklı imza türleriyle karakterize edilir. Geliştirilen sınıflandırıcılar, yalnızca her durum için aynı sistemle elde edilen aynı veriler içinde kullanılır. Ancak, iyi tespit sonuçlarıyla genel bir hiperbol tespiti oluşturmak mümkündür. Bu amaca ulaşmak için, şu anda piyasada bulunan farklı sistemlerle daha büyük miktarda bir veri gerekmektedir.

KAYNAKLAR

- [1] International Campaign to Ban Landmines, “Landmine monitor 2019,” Monitoring and Research Committee, ICBL-CMC Governance Board DanChurchAid Danish Demining Group Human Rights Watch Humanity & Inclusion Mines Action Canada Research team leaders · ICBL-CMC staff experts, 2019
- [2] D. Nabelek and K. C. Ho, “Detection of deeply buried non-metal objects by ground penetrating radar using non-negative matrix factorization,” Proc. SPIE, vol. 9454, May 2015, Art. no. 945419.
- [3] S. W. Jaw and M. Hashim, “Accuracy of data acquisition approaches with ground penetrating radar for subsurface utility mapping,” in Proc. IEEE Int. RF Microw. Conf., Seremban, Malaysia, Jun. 2011, pp. 40–44
- [4] F.H.C Tivive , A. Bouzerdoun , C. Abeynayake “GPR Target Detection by Joint Sparse and Low-Rank Matrix Decomposition” IEEE Transaction Geoscience and Remote Sensing, Vol. 57, No. 5, May 2019 2583-2599
- [5] S.M. Shrestha, I. Arai, “Signal processing of ground penetrating radar using spectral estimation techniques to estimate the position of buried targets.” EURASIP Journal on Advances in Signal Processing, 2003 (12), 1198–1209.
- [6] T. Thitimakorn, “Subsurface void detection under the road surface using ground penetrating radar (GPR), a case study in the Bangkok metropolitan area.“ Thailand. International Journal of Geo-Engineering, 7 (2), 1–9. Water Environment
- [7] N. Kim, K. Kim, Y. K. An, H. J. Lee, J.J Lee 2 “Deep learning-based underground object detection for urban road pavement”, International Journal of Pavement Engineering , 2018

y

- [8] S.E Yuksel, P.D. Gader " Context-based classification via mixture of hidden Markov model experts with applications in landmine detection", IET Comput. Vis., 2016, Vol. 10 Iss. 8, pp. 873-883
- [9] E.Pasolli, F. Melgani, and Donelli, M.: "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] R. Sakaguchi, K.D. Morton, L.M. Collins, P.A. Torrione, "A comparison of feature representations for explosive threat detection in ground penetrating radar data," IEEE Transactions on Geoscience and Remote Sensing 55 (12), 6736-6745, 2017.
- [11] B. Aggarwal, Acharya A.,Laghari A. "An Efficient Multi-Stage Adaptive Boosting Approach for Landmine Detection in Ground Penetrating Radar Data",2019 Oct.
- [12] Deniz Ç., Target Detection Using Ground Penetrating Datas, M. Eng. Thesis,Baskent University Institute of Science,Sep. 2018
- [13] W. Wai-Lok Lai, X. Derobert, P. Annan, "A review of Ground Penetrating Radar application in civil engineering: a 30-year journey from locating and testing to imaging and diagnosis", NDT and E Int. 96 (2018) 58–78,
- [14] D.J. Daniels, "Ground Penetrating Radar", 2nd ed., The IEE, 2004.
- [15] Enver A., Yere Nüfuz Eden Radar Verilerinde Tel Tespiti İçin Aktarım ve Çok Görevli Öğrenme Yöntemleri, Elektrik-Elektronik Mühendisliği Yüksek Lisans Tezi, Hacettepe üniversitesi Fen Bilimleri Enstitüsü, Mart 2018
- [16] 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 Transaction Geoscience and Remote, VOL. 42, NO. 11, pp. 2522-2534, Nov. 2004

- [17] A. Annan, "GPR – trends, history, and future developments," Proceedings of the EAGE
- [18] Rob Siegel, Land Mine Detection, IEEE Instrumentation & Measurement Magazine, Vol. 5, No. 4, Dec. 2002. Conference, Jun. 2001.
- [19] N. Xiang, J.M. Sabatier, An experimental study on antipersonnel landminedetection using acoustic-to-seismic coupling, Journal of the Acoustical Society of America 113 (3) (2003).
- [20] N. Xiang, J.M. Sabatier, Landmine detection measurements using acoustic-toseismic coupling, in: Proceedings of SPIE, Orlando, USA, vol. 4038, 2000, pp. 645–655.
- [21] H. Kasban, O. Zahran, S.M.S. Elaraby, M. El-Kordy, F.E. Abd El-Samie, Automatic object detection from acoustic to seismic landmines images, in: IEEEInternational Conference on Computer Engineering and Systems, Cairo, Egypt, November 2008.
- [22] H. Kasban, O. Zahran, S.M.S. Elaraby, M. El-Kordy, S. El-Rabie, F.E. Abd El-Samie, Efficient detection of landmines from acoustic images, Progress in Electromagnetics Research C 6 (2009) 79–92.
- [23] Current and Emerging Technologies for Use in a Hand-Held Mine Detector, Moody and LeVasseur, 19 June 2000, The Royal Military College of Canada, Dept. Appl.Military Science, p. 58.
- [24] Detection of Landmines by Quadrople Resonance at the Naval Research Laboratory (NRL), press release, Feb. 22, 2000.
- [25] Ashley, S., Searching for Landmines, Mechanical Engineering, Vol. 118, No. 4, p.62, April 1956.

- [26] Campbell, J.C. and Jacobs, A.M., Detection of Buried Land Mines by Backscatter Imaging, Nuclear Science and Engineering, Vol.110, p. 417, 1992.
- [27] 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.
- [28] D. J. Daniels, “Surface-penetrating radar,” Electronic Communication Engineering Journal, vol. 8, no. 4, pp. 165–182, 1996.
- [29] 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.
- [30] F. Abujarad, “Ground Penetrating Radar Signal Processing For Landmine Detection,” PhD Thesis, 2007.
- [31] “MALA Ground Penetrating Radar”, Professional Explorer,
- [32] 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.
- [33] E. Tebchrany, F. Sagnard, V. Baltazart, J-P. Tarel, and X. Dérobert, Assessment of statistical-based clutter reduction techniques on groundcoupled GPR data for the detection of buried objects in soils, in Proc.15th Int. Conf. Ground Penetrating Radar, Jun./Jul. 2014, pp. 604–609.
- [34] P. Klesk, A. Godziuk, M. Kapruziak, and B. Olech, Fast analysis of c scans from ground penetrating radar via 3-D Haar-like features with application to landmine detection, Trans. Geosci. Remote Sens., vol. 53, no. 7, pp. 3996–4009, Jul. 2015.

- [35] P. A. Torrione, K. D. Morton, R. Sakaguchi, and L. M. Collins, Histograms of oriented gradients for landmine detection in groundpenetrating radar data, *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 3, pp. 1539–1550, Mar. 2014.
- [36] D. Reichman, L. M. Collins, and J. M. Malof, Somegood practices for applying convolutional neural networks to buried threat detection in Ground Penetrating Radar, in *Proc. 9th Int. Workshop Adv. Ground Penetrating Radar (IWAGPR)*, Jun. 2017, pp. 1–5.
- [37] S. E. Yuksel, J. Bolton, and P. D. Gader, Landmine detection with multiple instance hidden Markov models, in *Proc. IEEE Int. Workshop Mach. Learn. Signal Process.*, Sep. 2012, pp. 1–6.
- [38] A. Manandhar, K. D. Morton, L. M. Collins, and P. A. Torrione, Multiple instance hidden Markov models for GPR-based landmine detection, *Proc. SPIE*, vol. 8709, Jun. 2013, Art. no. 87091L.
- [39] D.Kumlu, “New Clutter Removal Methods For Through Obstacle Target Detection”, M.Sc. thesis, Istanbul Technical University, Istanbul, Turkey, 2018
- [40] M. Orhan “Çok Geniş Bantlı Radar İle Gizlenmiş Hedef Tespit Ve Takibi İçin Görüntüleme Algoritmalarının Geliştirilmesi”, Yüksek Lisan Tezi, Yıldız Teknik Üniversitesi,2016
- [41] U.Yılmaz “Buried Wire Detection Using Ground Penetrating Radars”, M.Sc. thesis, Middle East Technical University,2017
- [42] E.Aydın, S.E.Y.Erdem, “Transfer and multitask learning using convolutional neural networks for buried wire detection from ground penetrating radar data” *Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXIV VOL.11012.*, 2019

- [43] Meşecan İ., Bucak İ.Ö. , Çiço B. 2018 “Comparison of histograms of oriented gradients (HOG) and n-Row average subtraction (nRAS) using GprMax” *Microprocessors and Microsystems* 63 2018 pp. 140–146
- [44] A.Alper ,” Yere Nüfuz Eden Radar (Ynr) Görüntülerinin Elde Edilmesinde Zaman Bölgesinde Sonlu Farklar (Ftd) Metodunun Kullanılması”, Yüksek Lisans Tezi, Gazi Üniversitesi,2011
- [45] P. Asadi, M. Gindy, M. Alvarez, “A Machine Learning Based Approach for Automatic Rebar Detection and Quantification of Deterioration in Concrete Bridge Deck Ground Penetrating Radar B-scan Images”, *KSCE Journal of Civil Engineering* vol. 2019 pp. 2618–2627,
- [46] E. Temlioğlu, ” Yere Nüfuz Eden Radar Görüntülerinde Morfolojik Bileşen Analizi Yöntemi İle Kargaşa Giderme”, Yüksek Lisan Tezi, İstanbul Teknik Üniversitesi , 2015
- [47] A.Doğan, ” Forward-Looking Long-Wave Infrared Image Based Pre-Screener For Landmine Detection”, M.Sc. thesis , Middle East Technical University ,2017
- [48] S. E. Yuksel, G. Ramachandran, P. Gader, J. Wilson, D. Ho, G. Heo ,” Hierarchical Methods For Landmine Detection With Wideband Electro-Magnetic Induction And Ground Penetrating Radar Multisensor Systems”, *IGARSS 2008*, pp. 177–180
- [49] A. Akdoğan, ” Yere Nüfuz Eden Radarlarda Lifting Temelli Dalgacık Dönüşümü İle Kargaşa Bastırma”, Yüksek Lisan Tezi, İstanbul Teknik Üniversitesi , 2013
- [50] W. Al-Nuaimy, Y. Huang , M. Nakhkash , M.T.C. Fang , V.T. Nguyen,” Automatic Detection Of Buried Utilities And Solid Objects With GPR Using Neural Networks And Pattern Recognition”, *Journal of Applied Geophysics* 43 .2000, pp 157–165,

- [51] R. Cole, J. Mariani, H. Uszkoreit, A. Zaenen, and V. Zue, *Survey of the State of the Art in Human Language Technology*. Washington, DC: Nat. Sci. Found., Commission Eur. Communities, Oregon Graduate Inst., 1995.
- [52] L. Rabiner and B.-H. Juang, *Fundamentals of Speech Recognition*. Englewood Cliffs, NJ: Prentice-Hall, 1993.
- [53] L. Rabiner, A tutorial on hidden Markov models and selected applications in speech recognition, *Proc. IEEE*, vol. 77, no. 2, pp. 257–286, Feb. 1989
- [54] P. D. Gader, B. N. Nelson, H. Frigui, G. Vaillette, and J. M. Keller, “Fuzzy Logic Detection of Land Mines with Ground Penetrating Radar,” *Signal Processing, Spec. Issue Fuzzy Logic Signal Processing (Invited Paper)*, Vol. 80, No. 6, pp. 1069-1084, June 2000.
- [55] P. D. Gader, B. N. Nelson, A. Koksal Hocaoglu, S. Auephanwiriyaikul, and M. A.Khabou, “Neural versus Heuristic Development of Choquet Fuzzy Integral Fusion Algorithms for Land Mine Detection,” in *NeuroFuzzy Pattern Recognition*, H. Bunke and A. Kandel, Eds, Singapore: World Scientific, 2000.
- [56] H. Brunzell, Clutter Reduction and Object Detection in Surface Penetrating Radar, in *Proc. Radar.97 Conf.*, 1997 pp. 688-691.
- [57] K. C. Ho and Paul D. Gader, “A Linear Prediction Land Mine Detection Algorithm for Hand-Held Ground Penetrating Radar,” *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 40, No. 6, June 2002.
- [58] MOUSÍ: R. W. Deming, “Automatic Buried Mine Detection Using the Maximum Likelihood Adaptive Neural System (MLANS),” in *Proc. 1998 IEEE ISIC/CIRA/ISAS Joint Conf.*, pp. 428-433, Gaithersburg, MD, Sept. 1998.

- [59] J. Gu et al., Recent advances in convolutional neural networks, *Pattern Recognit.*, vol. 77, pp. 354–377, 2018.
- [60] T. Wang, D. J. D. J. Wu, A. Coates, and A. Y. Ng, End-to-end text recognition with convolutional neural networks, *ICPR, Int. Conf. Pattern Recognit.*, no. May, pp. 3304–3308, 2012.
- [61] B. Xu, N. Wang, T. Chen, and M. Li, Empirical Evaluation of Rectified Activations in Convolutional Network, *J. Foot Ankle Res.*, vol. 1, no. S1, p. O22, May 2015.
- [62] Y. LeCun, Efficient BackPrp, *J. Exp. Psychol. Gen.*, vol. 136, no. 1, pp. 23–42, 2007.
- [63] P. Ramachandran, B. Zoph, and Q. V. Le, Swish: a Self-Gated Activation Function, *arXiv*, 2017.
- [64] C. Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, Activation Functions: Comparison of trends in Practice and Research for Deep Learning, *arXiv Prepr. arXiv1811.03378*, Nov. 2018.
- [65] S. Hochreiter, The vanishing gradient problem during learning recurrent neural nets and problem solutions, *Int. J. Uncertainty, Fuzziness Knowledge-Based Syst.*, vol. 6, no. 02, pp. 107–116, 1998.
- [66] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, Improving neural networks by preventing co-adaptation of feature detectors, pp. 1–18, 2012.
- [67] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, Dropout: A Simple Way to Prevent Neural Networks from Overfittin, *J. Mach. Learn. Res.*, vol. 1, no. 60, p. 11, 2014.

- [68] A. Krizhevsky, I. Sutskever, and G. E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks, *Adv. Neural Inf. Process. Syst.*, pp. 1–9, 2012. (REsnet)
- [69] M. D. Zeiler and R. Fergus, Visualizing and Understanding Convolutional Networks, *arXiv Prepr. arXiv1311.2901v3*, vol. 30, no. 1–2, pp. 225–231, 2013.
- [70] K. Simonyan and A. Zisserman, VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION, *ICLR*, vol. 75, no. 6, pp. 398–406, 2015. (REsnet)
- [71] C. Szegedy et al., Going deeper with convolutions, in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, vol. 57, no. 3, pp. 1–9.
- [72] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” *Multimed. Tools Appl.*, vol. 77, no. 9, pp. 10437–10453, Dec. 2015.
- [73] S. Xie, R. Girshick, P. Dollar, Z. Tu, and K. He, Aggregated Residual Transformations for Deep Neural Networks, in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 5987–5995.
- [74] C. Szegedy, S. Ioffe, and V. Vanhoucke, Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning, *arXiv Prepr. arXiv1602.07261v2*, vol. 131, no. 2, pp. 262–263, 2016.
- [75] S. Zagoruyko and N. Komodakis, Wide Residual Networks, *Proceedings Br. Mach. Vis. Conf. 2016*, pp. 87.1-87.12, May 2016.
- [76] G. E. Dahl, T. N. Sainath, and G. E. Hinton, Improving deep neural networks for LVCSR using rectified linear units and dropout, in *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on*, 2013, pp. 8609–8613.

- [77] V. Nair and G. E. Hinton, Rectified linear units improve Restricted Boltzmann machines, in ICML 2010 - Proceedings, 27th International Conference on Machine Learning, 2010.

- [78] pandas: powerful Python data analysis toolkit Release 1.2.4 Wes McKinney and the Pandas Development Team Apr 12, 202 Apr 12, 2021

- [79] NumPy Reference Release 1.20 Date January 31, 2021

- [80] Seaborn <https://elitedatascience.com/python-seaborn-tutorial>

- [81] Matplot Overview — Matplotlib 3.4.1 documentation

- [82] Keras Developer guides (keras.io)

- [83] Tensorflow Guide | TensorFlow Core

- [84] Scikitlearn User guide: contents — scikit-learn 0.19.1 documentation (sklearn.org)