

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YERE NÜFUZ EDEN RADARLARDA
ÖĞRENME TABANLI
YENİ KARGAŞA GİDERME YÖNTEMLERİ**

DOKTORA TEZİ

Eyyup TEMLİOĞLU

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Telekomünikasyon Mühendisliği Programı

MAYIS 2023

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YERE NÜFUZ EDEN RADARLARDA
ÖĞRENME TABANLI
YENİ KARGAŞA GİDERME YÖNTEMLERİ**

DOKTORA TEZİ

**Eyyup TEMLİOĞLU
(504152309)**

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Telekomünikasyon Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Işın ERER

MAYIS 2023

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**NEW LEARNING-BASED
CLUTTER REMOVAL METHODS
IN GROUND PENETRATING RADAR**

Ph.D. THESIS

**Eyyup TEMLİOĞLU
(504152309)**

Department of Electronics and Communication Engineering

Telecommunications Engineering Program

Thesis Advisor: Prof. Dr. Işın ERER

MAYIS 2023

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 504152309 numaralı Doktora Öğrencisi Eyyup TEMLİOĞLU, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “YERE NÜFUZ EDEN RADARLARDA ÖĞRENME TABANLI YENİ KARGAŞA GİDERME YÖNTEMLERİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Işın ERER**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Selçuk PAKER**
İstanbul Teknik Üniversitesi

Prof. Dr. Koray KAYABOL
Gebze Teknik Üniversitesi

Prof. Dr. Zümray DOKUR ÖLMEZ
İstanbul Teknik Üniversitesi

Prof. Dr. Ahmet Serdar TÜRK
Yıldız Teknik Üniversitesi

Teslim Tarihi : **30 Aralık 2022**

Savunma Tarihi : **05 Mayıs 2023**





Eşime ve çocuklarıma,



ÖNSÖZ

Bu tez, yedi yıllık doktora eğitimi yolculuğumu sonlandırıyor ve bu deneyimi tanımlayacak basit bir ifade yok. Zorluklarla dolu bu yolculukta bana her türlü koşulda destek olan, yanımda yer alan ve yol gösteren danışmanım Prof. Dr. Işın ERER'e teşekkürlerimi sunarım.

Prof. Dr. Selçuk PAKER'e ve Prof. Dr. Koray KAYABOL'a değerli zamanlarını ayırdıkları ve bu tezin ilerleyişindeki tavsiyeleri için teşekkür ederim.

Ayrıca bu yorucu ve uzun yolculukta desteklerini her zaman hissettiğim aileme minnettarım.

Aralık 2022

Eyyup TEMLİOĞLU
(Telekomünikasyon Mühendisi)

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
ÇİZELGE LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
SUMMARY	xxiii
1. GİRİŞ	1
1.1 Problemin Tanımı ve Tezin Amacı	2
1.2 Önerilen Yöntemler	3
2. YERE NÜFUZ EDEN RADAR	7
2.1 Benzetim Programı ile YNR Verisi Üretme	9
2.2 Referans Veri Üretme	13
2.3 Gerçek YNR Verileri	14
2.4 Veri Çoğaltma Üzerine Yapılan Çalışmalar	15
2.5 Performans Değerlendirme Ölçütleri	17
2.5.1 Tepe işaret gürültü oranı (TİGO - PSNR)	17
2.5.2 İşaret kargaşa oranı (İKO - SCR)	18
2.5.3 Alıcı işletim karakteristiği (AİK - ROC) eğrileri	19
3. KARGAŞA GİDERME YÖNTEMLERİ	21
3.1 Literatür Araştırması	21
3.2 İstatistiksel (Alt Uzay Tabanlı) Yöntemler	25
3.2.1 Temel bileşen analizi (TBA - PCA)	26
3.2.2 Tekil değer ayrışımı (TDA - SVD)	27
3.2.3 Negatif olmayan matris ayrışımı (NMA - NMF)	29
3.3 Düşük Dereceli ve Seyrek Ayrıştırma Yöntemleri	30
3.3.1 Gürbüz temel bileşen analizi (GTBA - RPCA)	30
3.3.2 Gürbüz negatif olmayan matris ayrışımı (GNMA - RNMF)	31
4. ÖNERİLEN MORFOLOJİK BİLEŞEN ANALİZİ YÖNTEMİ İLE YNR VERİLERİNDE KARGAŞA GİDERME	33
4.1 Morfolojik Bileşen Analizi (MBA) Yöntemi	34
4.2 Analitik Sözlükler Kullanılarak MBA Yöntemiyle Kargaşa Giderme	37
4.3 Önerilen Öğrenilmiş Sözlükler Kullanılarak MBA Yöntemiyle Kargaşa Giderme	40
4.3.1 Dik eşleme takibi (DET, orthogonal matching pursuit, OMP) algoritması	42
4.3.2 Kargaşa ve hedef bileşenleri için sözlük öğrenme	43
5. ÖNERİLEN EVRİŞİMSEL OTOKODLAYICILAR İLE YNR VERİLERİNDE KARGAŞA GİDERME	49
5.1 Otokodlayıcılar ile YNR Verilerinde Kargaşa Giderme	52

5.2 Evrişimsel Otokodlayıcılar ile YNR Verilerinde Kargaşa Giderme	54
5.2.1 Önerilen EOK ağ mimarisinde parametre seçimi	56
6. DENEYSEL SONUÇLAR	63
6.1 Öğrenilmiş Sözlükler Kullanan MBA ile YNR Verilerinde Kargaşa Giderme Sonuçları	63
6.2 Evrişimsel Otokodlayıcılar ile YNR Verilerinde Kargaşa Giderme Sonuçları	70
7. SONUÇ VE ÖNERİLER	81
KAYNAKLAR	85
EKLER	97
EK A : Norm İfadeleri	99
ÖZGEÇMİŞ	101



KISALTMALAR

AİK	: Alıcı İşletim Karakteristiği
AKD	: Ayrık Kosinüs Dönüşümü
AS	: Analitik Sözlükler
ASD	: Ayrık Sinüs Dönüşümü
BBA	: Bağımsız Bileşen Analizi
ÇMBA	: Çok-kanallı Morfolojik Bileşen Analizi
DDSA	: Düşük Dereceli ve Seyrek Ayırıştırma
DDB	: Doğrultulmuş Doğrusal Birim
DEOK	: Derin Evrişimsel Otokodlayıcılar
DET	: Dik Eşleme Takibi
DTO	: Doğru Tespit Oranı
EBO	: En Büyüklerin Ortalaması
EKOK	: En Küçük Ortalama Kare
EOK	: Evrişimsel Otokodlayıcılar
EYP	: El Yapımı Patlayıcılar
EYSA	: Evrişimsel Yapay Sinir Ağları
GMBA	: Genelleştirilmiş Morfolojik Bileşen Analizi
GNMA	: Gürbüz Negatif Olmayan Matris Ayırışımı
GOK	: Gürbüz Otokodlayıcı
GTBA	: Gürbüz Temel Bileşen Analizi
HEF	: Hedef Enerji Fonksiyonu
HTB	: Hedef Tespit Bölgesi
HYKA	: Hızlı Yinelemeli Küçülme-Eşiği Algoritması
İKO	: İşaret Kargaşa Oranı
MYAS	: Maksimum Yanlış Alarm Sayısı
MBA	: Morfolojik Bileşen Analizi
NMA	: Negatif Olmayan Matris Ayırışımı
OÇ	: Ortama Çıkarma
OKH	: Ortalama Kare Hatası
ÖS	: Öğrenilmiş Sözlükler
RGİ	: Rastgele Gradyan İnişi
SAR	: Sentetik Açıklıklı Radar
TBA	: Temel Bileşen Analizi
TDA	: Tekil Değer Ayırışımı
TİGO	: Tepe İşaret-Gürültü Oranı
YAB	: Yanlış Alarm Bölgesi
YAO	: Yanlış Alarm Oranı
YNR	: Yere Nüfuz Eden Radar
YOK	: Yığılanmış Otokodlayıcı
YSA	: Yapay Sinir Ağları
ZDSF	: Zaman-Domeninde Sonlu-Farklar



ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 2.1 : Malzemelerin elektromanyetik özellikleri.....	11
Çizelge 5.1 : Tamamen bağlı tek katmanlı YSA otokodlayıcı sonuçları	53
Çizelge 5.2 : Tamamen bağlı üç katmanlı YSA otokodlayıcı sonuçları	54
Çizelge 5.3 : Evrimsel katmanlarda kullanılan farklı filtre boyutları için eğitim süreleri ve ortalama TİGO değerleri	58
Çizelge 5.4 : Evrimsel katmanlarda kullanılan filtrelerin farklı sayıları için eğitim süresi ve ortalama TİGO değerleri	60
Çizelge 5.5 : Farklı devir sayısı, grup boyutu ve filtre sayısı için eğitim süresi ve ortalama TİGO değerleri	61
Çizelge 5.6 : Önerilen EOK ve DEOK yöntemlerine ait ağ mimarileri	62
Çizelge 6.1 : MBA-ÖS yönteminin farklı parametreleri için elde edilen AİK Eğri Altındaki Alan (EAA) değerleri	65
Çizelge 6.2 : %100 tespit oranı için yöntemlerin Yanlış Alarm Oranları (YAO), bu oranların önerilen yöntem ile karşılaştırılması ve AİK Eğri Altındaki Alan (EAA)	66
Çizelge 6.3 : Engebeli yüzey ve yüzeyde su birikintisi (4. senaryo) varken kuru killi toprak 4 cm derinliğe gömülen alüminyum cisim için farklı yöntemlerle elde edilen TİGO değerleri	67
Çizelge 6.4 : AİK eğrisinde gösterilen yöntemlere ait doğru tespit oranı ve yanlış alarm oranı değerleri	69
Çizelge 6.5 : Kuru toprak verisi için İşaret-Kargaşa Oranı (İKO) değerleri	76
Çizelge 6.6 : Islak toprak verisi için İşaret-Kargaşa Oranı (İKO) değerleri	76



ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1 : YNR sistemi ve sistemi oluşturan bileşenlerin gösterimi [1]	7
Şekil 2.2 : YNR sisteminden alınan A-tarama işareti	8
Şekil 2.3 : YNR sisteminden alınan verilerle oluşturulan B-tarama görüntüsü ...	8
Şekil 2.4 : Araca takılı dizi antenlerden oluşan YNR sistemi [2].....	9
Şekil 2.5 : YNR sisteminden alınan verilerle oluşturulan C-tarama görüntüsü [3]	10
Şekil 2.6 : Veri seti üretimi için benzetim modeli	10
Şekil 2.7 : Senaryo-1 için oluşturulan model	12
Şekil 2.8 : Senaryo-2 için oluşturulan model	12
Şekil 2.9 : Senaryo-3 için oluşturulan model	13
Şekil 2.10 : Senaryo-4 için oluşturulan model	13
Şekil 2.11 : Referans veri oluşturma. a) Hedef içeren ham veri. b) Hedef içermeyen arkaplan verisi. c) Referans veri.....	14
Şekil 2.12 : Gerçek YNR verileri. a) Islak topraktan alınan veri. b) Kuru topraktan alınan veri.	15
Şekil 2.13 : Yatay -x (sol) yönünde kaydırma işlemi sonucu elde edilen ham ve referans veriler. Ham veri kaydırma miktarı (a) 10 A-tarama, (b) 8 A-tarama, (c) 6 A-tarama, (d) 4 A-tarama, (e) 2 A-tarama, ve referans veri kaydırma miktarı (f) 10 A-tarama, (g) 8 A-tarama, (h) 6 A-tarama, (i) 4 A-tarama, (j) 2 A-tarama.	16
Şekil 2.14 : Hedef tespit bölgesi ve yanlış alarm bölgelerinin gösterimi	18
Şekil 2.15 : AİK (ROC) eğrisi	20
Şekil 4.1 : MBA yöntemi ile görüntünün alt bileşenlerine ayrılması - 1 [4,5]. (a) Resim ve doku bileşenlerinden oluşan görüntü, (b) ayrıştırma sonrası elde edilen resim bileşeni, (c) ayrıştırma sonrası elde edilen doku bileşeni.	35
Şekil 4.2 : MBA yöntemi ile görüntünün alt bileşenlerine ayrılması - 2 [4,5]. (a) Resim ve doku bileşenlerinden oluşan görüntü, (b) ayrıştırma sonrası elde edilen resim bileşeni, (c) ayrıştırma sonrası elde edilen doku bileşeni.	35
Şekil 4.3 : MBA algoritmasının farklı sözlükler ile ayrıştırma yapmasının gösterimi [6].....	36
Şekil 4.4 : MBA-ÖS yöntemiyle kargaşa giderme işlemlerinin gösterimi	41
Şekil 4.5 : K-SVD algoritması için veri hazırlama işlemleri.....	46
Şekil 4.6 : Hedef imza çıkarma işlemi	47
Şekil 5.1 : Otokodlayıcı akış diyagramı	49
Şekil 5.2 : Tamamen bağlı basit YSA otokodlayıcı mimarisi.....	51
Şekil 5.3 : Tamamen bağlı derin YSA otokodlayıcı mimarisi	54
Şekil 5.4 : Evrimsel Otokodlayıcılar ile kargaşa giderme modeli	55

Şekil 5.5 :	EOK parametrik ağ mimarisi	58
Şekil 5.6 :	Evrişimsel otokodlayıcı ağ mimarisinde kullanılan farklı filtre boylarının görsel çıktıları. (a) Ham YNR verisi (girdi), (b) referans veri (girdi), farklı filtre boyları için yeniden oluşturulan veriler (c) 3x3, (d) 4x4, (e) 5x5, (f) 8x8, (g) 16x16/8x8, ve (h) 16x16.....	59
Şekil 6.1 :	Öğrenilmiş sözlükler ile MBA yönteminde farklı parametreler için elde edilen sonuçlar	64
Şekil 6.2 :	Öğrenilmiş sözlükler ile MBA yönteminin diğer kargaşa giderme yöntemleriyle karşılaştırılması	65
Şekil 6.3 :	Engelibeli yüzey ve yüzeyde su birikintisi (4. senaryo) varken kuru killi toprak 4 cm derinliğe gömülen alüminyum cisim için (a) Ham veri, (b) referans veri, kargaşa giderme sonuçları (c) TBA (PCA), (d) TDA (SVD), (e) NMA (NMF), (f) GNMA (RNMF), (g) GTBA (RPCA), (h) MBA-AS (MCA), ve (i) MBA-ÖS.....	68
Şekil 6.4 :	Hedeflerin gömülme derinliğine göre ortalama TİGO değerleri.	70
Şekil 6.5 :	Farklı toprak tiplerine göre ortalama TİGO değerleri	71
Şekil 6.6 :	Farklı senaryolara göre ortalama TİGO değerleri	72
Şekil 6.7 :	Önerilen yöntemin hedef içermeyen B-tarama verisi ile test edilmesi. (a) Ham hedef içermeyen arkaplan verisi, (b) EOK yöntemi ile elde edilen kargaşa giderme sonucu ve (c) DEOK yöntemi ile elde edilen kargaşa giderme sonucu.....	73
Şekil 6.8 :	Önerilen yöntemin farklı derinliklerde 2 tane hedef içeren B-tarama verisi ile test edilmesi. (a) Ham farklı derinliklerde 2 tane hedef içeren veri, (b) EOK yöntemi ile elde edilen kargaşa giderme sonucu ve (c) DEOK yöntemi ile elde edilen kargaşa giderme sonucu.	74
Şekil 6.9 :	Önerilen yöntemin hedef imzasının bozulduğu zorlu senaryo ile test edilmesi. (a) Ham hedef imzasının bozulduğu veri, (b) EOK yöntemi ile elde edilen kargaşa giderme sonucu ve (c) DEOK yöntemi ile elde edilen kargaşa giderme sonucu.....	74
Şekil 6.10 :	Kuru toprak durumu için gerçek veri sonuçlarının karşılaştırılması. (a) Ham veri, kargaşa giderme sonuçları (b) TBA (PCA), (c) TDA (SVD), (d) NMA (NMF), (e) MBA-AS(MCA), (f) GTBA (RPCA), (g) GNMA (RNMF), (h) EOK ve (i) DEOK.....	77
Şekil 6.11 :	Islak toprak durumu için gerçek veri sonuçlarının karşılaştırılması. (a) Ham veri, kargaşa giderme sonuçları (b) TBA (PCA), (c) TDA (SVD), (d) NMA (NMF), (e) MBA-AS(MCA), (f) GTBA (RPCA), (g) GNMA (RNMF), (h) EOK ve (i) DEOK.....	78
Şekil 6.12 :	Kuru toprak verisi için normalize edilmiş HEF değerleri ile yöntemlerin karşılaştırılması.	79
Şekil 6.13 :	Islak toprak verisi için normalize edilmiş HEF değerleri ile yöntemlerin karşılaştırılması.	79

**YERE NÜFUZ EDEN RADARLARDA
ÖĞRENME TABANLI
YENİ KARGAŞA GİDERME YÖNTEMLERİ**

ÖZET

Yere Nüfuz Eden Radar (YNR, Ground Penetrating Radar (GPR)) en popüler yer altı algılama cihazlarından biridir ve geniş bir uygulama alanına sahiptir. YNR sistemi çok çeşitli jeofizik ve mühendislik uygulamaları için yaygın olarak tercih edilir. Arkeolojik araştırmalar, tünel araştırmaları, şehir alt yapılarının araştırılması, maden araştırmaları, yer altındaki kablo ve boruların tespit edilmesi, asfalt kontrol çalışmaları YNR sisteminin sivil uygulama alanlarından bazılarıdır. YNR sistemi aynı zamanda askeri alanda özellikle plastik içerikli mayınların tespit edilmesinde kullanılmaktadır. YNR sisteminin donanım ve yazılım gereksinimleri uygulama alanına göre değişmektedir. YNR sistemi genel olarak alıcı-verici antenler, kontrol ünitesi ve görüntüleme ekranından oluşmaktadır. Kontrol ünitesinde istenilen özelliklerde darbe üretilir ve verici anten vasıtasıyla bu işaret yerin altına gönderilir, geri yansıyan işaretler alıcı anten ile toplanır ve işlenmesi için kontrol ünitesini iletilir. Alınan işaret üzerinde kuvvetlendirme, örnekleme işlemlerinden sonra işaret işleme algoritmalarıyla gürültü giderme, hedef tespiti gibi işlemler yapılır ve son olarak görüntüleme ekranında kullanıcıya algoritma sonucu ve yerin altına ait görüntüler gösterilir.

Bu tez çalışması; YNR sisteminin askeri alanda mayınların tespit edilmesi amacıyla kullanımına yönelik bir çalışmadır. Mayınlar ilk defa kullanılmaya başlandığında dış kasası metal olarak üretilmişlerdir. Bu mayınların tespit edilmesinde metal dedektörleri gayet başarılıdır. Bunun üzerine mayınların dış kasasında plastik malzeme kullanılmıştır ve içeriği fünye dışında metallere arındırılmıştır. Plastik mayınların tespit edilmesinde metal dedektörleri metal içerikli mayınları tespit etmedeki başarısını gösterememiştir. Metal dedektörlerinin plastik içerikli mayınları tespit etmekte zorlanmasından sonra YNR sistemi bu mayınların tespit edilmesinde kullanılmaya başlamıştır.

YNR sistemi ile plastik mayınların tespit edilmesi bazı koşullarda kolay olsa da toprak yapısı, toprağın elektromanyetik özellikleri ve daha bir çok etkenden dolayı bir çok durumda bu mayınların tespit edilmesi zordur. YNR sistemi ile plastik mayınların tespitini zorlaştıran bozucu etkiler kargaşa olarak adlandırılmaktadır. Özellikle küçük boyutlu plastik mayınlar yeryüzüne yakın gömüldüğünde kargaşa bu mayınların görüntülenmesini ve tespit edilmesini zorlaştırmaktadır. Kargaşa genel olarak yeryüzünden geri yansıyan işaret, alıcı-verici antenler arası kuplaj ve toprak içerisinde bulunan ağaç kökleri, ufak taşlar ve toprak içerisindeki düzensizlikler gibi istenmeyen cisimlerden yansıyan işaretlerden oluşmaktadır. Kargaşa yeryüzüne yakın gömülen plastik cisimlerden alınacak yansımayı bastırarak hedefin tespit edilememesine sebep olmasının yanında hedef olmayan bölgelerde de hedef varmış algısı oluşturarak yanlış tespitlere de sebep olmaktadır. Yanlış tespitlerin önüne geçmek ve yeryüzüne

yakın gömülen küçük plastik mayınların tespit edilmesini kolaylaştırmak için kargaşa giderme yöntemleri önemli bir yere sahiptir.

Literatürde YNR verilerinde kargaşa gidermek için yıllar içinde farklı yaklaşımlar önerilmiştir. En ilkel yaklaşım, hedef olmayan bölgedeki verilerin ortalamasını alarak diğer tüm verilerden çıkararak kargaşa giderme yapan Ortalama Çıkarma (OÇ) yöntemidir. Bu yaklaşım hedefin olmadığı bölge bilgisi gerektirir ve yöntem yeryüzünün düz olduğunu kabul ettiği için yöntemin başarısı yeryüzünün engebesiz olmasına ve anten ile toprak arasındaki mesafenin değişmemesine bağlıdır. Bu yaklaşımın adaptif versiyonları da mevcuttur ancak adaptif yaklaşımlar da hedef imzasını bozmaktadır ve seçilen pencere boyu parametresi yöntemin başarımında önemli rol oynamaktadır.

YNR verilerinde kargaşa gidermek için kullanılan bir başka yaklaşım ise veriyi alt uzaylara ayıran istatistiksel yöntemlerin kullanılmasıdır. Bu yaklaşımda YNR verisi hedef, kargaşa ve gürültü olarak alt bileşenlere ayrılmaktadır. Bu yaklaşım içerisinde Temel Bileşen Analizi (TBA, Principal Component Analysis (PCA)), Tekil Değer Ayrışımı (TDA, Singular Value Decomposition (SVD)) ve Bağımsız Bileşen Analizi (BBA, Independent Component Analysis (ICA)) yöntemleri yer almaktadır ve literatürde yaygın olarak YNR görüntülerinde kargaşa gidermek için kullanılmaktadır. Bu yöntemlerde genellikle en yüksek yansımanın yerden geldiği kabul edilerek kargaşanın en yüksek bilgiye sahip ilk uzayda olduğu, hedefin ise en yüksek ikinci bilgiye sahip ikinci uzayda olduğu ve gürültünün diğer alt uzaylarda olduğu varsayılmaktadır. Ancak YNR verisinde yer alan hedef sayısına göre hedef bilgisi sadece ikinci en yüksek bilgiye sahip uzayla kalmayıp diğer uzaylara da yayılmaktadır. Bu yaklaşım içerisinde veriyi 2 negatif olmayan matrise ayırtıran Negatif Olmayan Matris Ayrışımı (NMA, Non-negative Matrix Factorization (NMF)) yöntemi de yer almaktadır. YNR verilerinde düşük dereceli bileşen kargaşa olarak kabul edilerek kargaşa gidermek için NMA yöntemi kullanılmaktadır. Bu yöntemler ile geçmişte başarılı sonuçlar elde edilse de zorlu senaryolarda bu yöntemlerin başarımı düşmektedir.

Düşük Dereceli ve Seyrek Ayrıştırma (DDSA, Low-Rank and Sparse Decomposition (LRSD)) yöntemleri son yıllarda görüntü işleme alanında yaygın olarak bir çok probleme uygulanmıştır. Bu yaklaşım içerisinde yer alan Gürbüz Temel Bileşen Analizi (GTBA, Robust PCA) ve Gürbüz Negatif Olmayan Matris Ayrışımı (GNMA, Robust NMF) yöntemleri de YNR verilerinde kargaşa gidermek için kullanılmaktadır. Bu yöntemler veriyi eş zamanlı olarak düşük dereceli ve seyrek olarak ayırtırmaktadırlar. YNR verilerinde düşük dereceli bileşen kargaşa bileşeni, seyrek bileşen ise hedef bileşeni olarak kabul edilmektedir.

Görüntüyü sahip olduğu sözlükler ile farklı bileşenlere ayıran Morfolojik Bileşen Analizi (MBA, Morphological Component Analysis) yöntemi de YNR verilerinde kargaşa gidermek için kullanılan yaklaşımlardandır. MBA yöntemi seyrek işaret işleme alanında kullanılan ve bir çok probleme uygulanan bir yöntemdir. Daha önce Analitik Sözlükler (AS) kullanan MBA yöntemi (MBA-AS) ile YNR verilerinde kargaşa giderilerek başarılı sonuçlar elde edilmiştir. Ancak MBA yönteminin işlem yükü biraz fazladır. Bu tez kapsamında, MBA yöntemini hem hızlandırmak hem de daha iyi sonuçlar elde etmek için Öğrenilmiş Sözlükler (ÖS) ile çalışan

MBA yöntemi (MBA-ÖS) önerilmiştir. MBA-ÖS yöntemi, MBA-AS yöntemine göre 6.8 kat daha hızlı çalışmaktadır ve MBA-AS yöntemine göre yanlış alarm oranı 42 kat daha düşüktür. MBA-ÖS yönteminde kullanılan sözlükler birbirinden bağımsız olarak kargaşa ve hedef bileşenlerini ayrı ayrı temsil etmesi için K-SVD algoritması kullanılarak elde edilmişlerdir. MBA-ÖS yöntemi, YNR verisini MBA-AS yönteminde olduğu gibi bir bütün halinde ayrıştırmak yerine YNR verisinden yama olarak adlandırılan küçük görüntü parçaları ile ayrıştırma işlemini gerçekleştirmektedir. Daha sonra ayrıştırılan yamalar ayrı ayrı birleştirilerek kargaşa ve hedef verisini oluşturmaktadır.

Bu tez çalışmasında aynı zamanda öğrenme tabanlı bir kargaşa giderme yöntemi önerilmiştir. Evrimsel Otokodlayıcılar (EOK, Convolutional Autoencoder (CAE)) yöntemi YNR verilerinde kargaşa gidermek için kullanılmıştır. EOK yöntemi öğrenme tabanlı bir yöntemdir ve öğrenmenin gerçekleşebilmesi için EOK yönteminin eğitim veri seti ile eğitilmesi gerekmektedir. Bu yöntem geniş veri setine ve bu veri seti içerisinde yer alan referans verilere ihtiyaç duymaktadır. Referans veriler elde edebilmek için gprMax benzetim programı ile YNR verileri üretilmiştir. Bu benzetim programı sayesinde referans veri de üretmek mümkündür. Ancak bu program ile YNR verileri üretmek hem zahmetli hem de zaman almaktadır. Küçük bir veri seti bile hazırlamak aylar sürmektedir. EOK yönteminin ihtiyaç duyduğu geniş veri setini elde edebilmek için YNR verilerine uygun veri çoğaltma tekniklerinden yararlanılarak veri seti genişletilmiştir. Önerilen EOK yöntemi toprak tipine, hedef gömülme derinliğine, farklı senaryolara göre test edilmiştir ve hem literatürde yer alan klasik yöntemlerle hem de son yıllarda önerilen yöntemlerle karşılaştırılmıştır. Önerilen EOK yönteminin tüm yöntemlere üstünlük sağladığı görülmüştür.



NEW LEARNING-BASED CLUTTER REMOVAL METHODS IN GROUND PENETRATING RADAR

SUMMARY

Ground Penetrating Radar (GPR) is one of the most popular subsurface sensing devices and has a wide range of applications. The GPR system is commonly preferred for a wide variety of geophysics and engineering applications. Archaeological surveys, tunnel surveys, city infrastructure research, mining surveys, detection of underground cables and pipes, asphalt control surveys are some of the civil application areas of the GPR system. The GPR system is also used in the military, especially for the detection of non-metallic landmines. Therefore, the hardware and software requirements of the GPR system are strongly dependent on type of applications. Generally, a receiving antenna, a transmitting antenna, a control unit and a display screen are the basic components of the GPR system. A pulse with the desired characteristics is generated in the control unit and this signal is sent underground through the transmitting antenna, the reflected signals are collected by the receiving antenna and transmitted to the control unit for processing. After the amplification and sampling processes on the received signal, operations such as noise removal and target detection are performed with signal processing algorithms. Finally, the result of the algorithm and images of the underground are shown to the user on the display screen.

This thesis is a study for the use of the GPR system for the detection of landmines in the military field. Landmines are a serious problem affecting civilians and soldiers. Therefore, it is very important to detect and remove of them. Landmines are divided into 2 categories as anti-personnel and anti-tank. The anti-personnel landmines are designed to harm people, while the anti-tank landmines are designed to harm armored vehicles. Therefore, the anti-tank landmines are large in size to contain high explosives and are easy to detect. However, the anti-personnel landmines are difficult to detect because of their small size. When landmines were first produced, their outer casings were metal and these landmines are easily detected by metal detectors. As landmines with metal outer casings can be easily detected by metal detectors, landmines have been produced with a plastic outer casing. After the production of these landmines, the performance of metal detectors decreased and the GPR began to be used for the detection of landmines with little or no metal content.

Although the GPR system is superior to metal detectors in detecting landmines with little or no metal content, these landmines are not easy to detect using the GPR system. The clutter makes it difficult to detect, especially small-sized and plastic anti-personnel mines buried close to the ground surface. The clutter can be caused by the direct coupling between the transmitting and receiving antennas, the reflections from the soil surface, and the scattering response from non-mine objects such as roots, gravel, or nonuniform terrain. When landmines with minimal metal content are buried close to

the surface, clutter suppresses the target signal because the amplitude of the signal reflected from the target is weaker than the signal reflected from the ground. In addition, the clutter causes false alarms by creating the perception that there is a target in the relevant area even though there is no buried object in the soil in some cases. Furthermore, the performance of GPR systems is also affected by climatic conditions, temperature, soil structure and environmental factors. Thus, removal of the clutter prior to any imaging or detection application is an active research area for GPR community.

It is not easy to reach the GPR system and the dataset created by collecting data from test pools containing soil with different properties with this system. Therefore, the dataset is created using gprMax open source software that numerically solves Maxwell's equations using a second-order Finite-Difference Time-Domain (FDTD) algorithm. The gprMax has the ability to simulate real commercial antennas. In all simulations, Geophysical Survey Systems, Inc. (GSSI) 1.5 GHz (Model 5100) antenna is used. The generated dataset includes data for seven different soil types, two different targets, six different burial depths and four different scenarios. The created dataset contains a total of 364 data, 28 of which are background data and 336 are target data. While generating background data, no buried object was used in the simulation environment and these data are used to generate reference (ground truth) data. Since there was no target, background data were obtained only for 7 different soil types and 4 different scenarios. In order to create reference data, appropriate background data is extracted from the target data, taking into account the soil type and scenario. The burial depth of cylindrical objects was determined at 1 cm intervals between 0-5 cm from the surface for each scenario and soil type. The burial depths of the objects were specifically chosen close to the surface because landmines are very difficult to detect when buried near to the ground. The radius and the height of the cylinder was determined as 2.8 cm and 4 cm respectively. These dimensions are the same as M14 anti-personnel mines. While creating the dataset, 4 different scenarios were created with the changes made on the soil surface as well as the parameters of different soil type, depth of buried object and type of buried object. Scenario-1 is the easiest of all scenarios where the ground surface was assumed flat. In order to examine the effect of vegetation on the GPR data, 10 000 grass blades were planted on a flat surface in Scenario-2. A rough surface is designed in Scenario-3. This scenario is important for testing the robustness of algorithms because most algorithms assume that the ground surface is flat. In scenario-4, there are water puddles on the rough surface.

In addition, the well-known real GPR data from Vrije Universiteit Brussel is also used to validate the effectiveness of the proposed method. In this data set, data were taken from the same object in the same environment when the soil was wet and after the soil was dry. The object was buried in the clay before wetting the soil. The buried object is plastic-case anti-personnel landmine PMA-3 whose height is 4 cm and diameter is 11 cm. The burial depth of the PMA-3 is 5 cm.

As visual inspection is not sufficient to compare the performance of the methods, Peak Signal-to-Noise Ratio (PSNR) is utilized for quantitative analysis. A higher PSNR value indicates that the reconstructed image is more similar to the reference image. Since the PSNR could not be calculated for real data due to the lack of background and reference data, the effectiveness of the proposed method on real data is measured

by Signal-to-Clutter Ratio (SCR). In order to evaluate SCR, reconstructed B-scan data is normalized and then, Target Energy Function (TEF) is calculated for each antenna position. Down-track position of the target and its near surroundings are called Detection Region (DR), and the remaining areas are defined as False Alarm Region (FR) to distinguish the signals from the target and the clutter. Two different SCR metrics were calculated using TEF values from DR and FR. While the PSNR measures the similarity of the reconstructed image and the reference image, the SCR measures how much the reconstructed image is cleared from the clutter. Additionally, Receiver Operating Characteristic (ROC) curves were calculated to compare the methods with each other. The ROC curves provide information on overall detection performance for all scenarios, all soil types, all burial depths of objects, and all types of objects. Probability of Detection (PD) versus False Alarm Rate (FAR) values at different thresholds are used to calculate the ROC curves. PD is equal to the number of alarms received in the detection region divided by the total number of targets. FAR equals false alarms divided by the maximum possible number of false alarms.

Over the years, different approaches have been proposed to remove the clutter in the GPR data. Besides the conventional mean subtraction method, the conventional clutter removal methods are based on subspace methods such as Singular Value Decomposition (SVD), Principal Component Analysis (PCA) and Independent Component Analysis (ICA) where the GPR matrix is decomposed into components according to different constraints. The clutter, much stronger than the reflections from the target, is represented by the dominant component, while the target is represented by the second component in general. However, the target information for multiple target case can be recovered by several components or the components may not be obtained in a decreasing order as in the case of ICA. For such cases, target distinction may become a challenging problem. The recently proposed Nonnegative Matrix Factorization (NMF) method decomposes the data matrix into the product of two nonnegative matrices, and a low rank value choice provides a low rank representation of the data matrix, namely the clutter component similar to the subspace based clutter removal methods.

Low Rank and Sparse Decomposition (LRSD) methods have attracted much interest and found many applications in image processing such as change detection or background subtraction, missing data recovery (completion), anomaly detection, denoising, etc. Their most famous representative, Robust Principal Component Analysis (RPCA) is used to decompose the GPR matrix into its low rank and sparse components. The clutter component is provided by the low rank component and the target which is sparse with respect to the whole raw image is given by the sparse component of the decomposition. RPCA finds the low rank and sparse components iteratively, thus it requires sequential SVD operations increasing its complexity compared to PCA and other subspace methods. There have been many attempts to replace successive SVD operations and obtain faster methods required by field studies such as Go Decomposition (GoDec) which finds the low rank component directly using bilateral random projections or recently proposed RNMF incorporating a sparse component into the NMF decomposition.

Another approach is Morphological Component Analysis (MCA) which decomposes the raw GPR data matrix into clutter and target components, providing their sparse representation in a specific domain using transforms or learned dictionaries. Again, the separation performance depends highly on the appropriate dictionaries. The use of fixed dictionaries (transformations) i.e. Undecimated Discrete Wavelet Transform (UDWT) for the target and curvelet for the clutter, outperforms the former methods. However, this method has higher complexity. In this thesis, it is proposed to use learned dictionaries to enhance the performance of the MCA. Patches are extracted from clutter and target regions of several GPR images and then used to learn the corresponding dictionaries using K-SVD algorithm. Unlike the conventional MCA, the raw data is decomposed in a patch-wise way. Each patch extracted from the GPR data is decomposed using Orthogonal Matching Pursuit (OMP), then the obtained target patches are merged to form the target data. Furthermore, the proposed method is 6.8 times faster than conventional MCA method. The false alarm rate of the proposed method is 42 times lower than the conventional MCA method.

In this thesis, Convolutional Autoencoder (CAE), a learning-based method, is also proposed to removal of clutter in the GPR data. Autoencoding is a data compression algorithm which consists of an encoding function, a decoding function and a loss function. Neural networks are mostly used to implement encoding and decoding functions. Loss function quantifies the agreement between the reconstructed and the input data. Autoencoder (AE) is an unsupervised learning technique, and the representation is learned automatically from the data so that the learned representation is data-specific. The CAE is a type of autoencoder that uses convolutional neural network (CNN) in the encoding and decoding stages. Conventional AE takes 2D image as an 1D sequence so that it cannot take advantage of the image structure. Thus, CAE extracts the structural properties of the images more suitably than conventional AE in the processing of the images. To the best of our knowledge, the proposed approach constitutes the first attempt to apply CAE to eliminate the clutter in the 2-D GPR data. The proposed method learns how to eliminate the clutter in the raw GPR images that contain both the clutter and the target components. The model is trained with the simulated dataset and needs reference/ground truth data in the stage of loss calculation. As a result, the algorithm tries to resemble the input raw GPR data to the reference data that includes only the target component. The generated dataset has been augmented to achieve a more robust model, and appropriate parameter choices have been investigated. The effectiveness of the proposed method has also been demonstrated on the real GPR data. The proposed method outperforms both the traditional and the state-of-the-art methods, especially for more challenging scenarios.

1. GİRİŞ

Yere Nüfuz Eden Radar (YNR, Ground Penetrating Radar (GPR)) en popüler yer altı algılama cihazlarından biridir ve geniş bir uygulama alanına sahiptir. Arkeolojik araştırmalar, tünel araştırmaları, şehir alt yapılarının araştırılması, maden araştırmaları, yer altındaki kablo ve boruların tespit edilmesi, asfalt kontrol çalışmaları YNR sisteminin sivil uygulama alanlarından bazılarıdır [11]. YNR sistemi aynı zamanda askeri alanda özellikle plastik içerikli mayınların tespit edilmesinde kullanılmaktadır. YNR sisteminin donanım ve yazılım gereksinimleri uygulama alanına göre değişmektedir. Temel çalışma prensibi yerin altına verici anten vasıtasıyla sistem tarafından üretilen işaretin gönderilmesi ve alıcı anten vasıtasıyla geri yansıyan işaretlerin toplanarak işlenmesi ve görüntüleme ekranında işlenen verilerin gösterilmesi şeklindedir.

Bu tez kapsamında yapılan çalışma daha çok askeri alanda kara mayınlarının tespit edilmesini zorlaştıran ve kargaşa olarak adlandırılan bozucu etkinin giderilmesi üzerinedir. Ancak yer altındaki kablo ve boruların tespit edilmesinde de benzer problemler olduğu için geliştirilen algoritmalar benzer problemlerde de kullanılabilir. Mayınlar dünya genelinde hem askerlerin hem de sivillerin ölmesine, yaralanmasına veya psikolojik olarak zarar görmesine yol açmaktadır. Bu sebeple mayınların tespit edilmesi ve bulundukları yerden kaldırılması çok önemlidir.

Kara mayınları anti-personel ve anti-tank olmak üzere 2 kategoriye ayrılır. Anti-personel mayınlar insanlara, anti-tank mayınlar ise zırhlı araçlara zarar vermek için tasarlanmıştır. Anti-tank mayınlar yüksek miktarda patlayıcı içerdiği için büyük-türler ve tespit edilmeleri anti-personel mayınlara göre daha kolaydır. Anti-personel mayınlar küçük boyutlu oldukları için ve yeryüzüne yakın gömüldüklerinden dolayı tespit edilmeleri zordur. Kara mayınları ilk üretildiğinde dış kasaları metalden ve bu mayınlar metal dedektörleri tarafından kolaylıkla tespit edilmektedir. Metal dedektörlerinin bu mayınları rahatlıkla tespit etmesi üzerine mayınlar minimum metal

içerecek şekilde dış kasası plastik olarak üretilmişlerdir. Fünne dışında herhangi bir metal içermeyen bu mayınların metal dedektörleri ile tespit edilmesi zorlaşmıştır. Minimum metal içeren plastik kasalı mayınların tespit edilmesi için YNR sistemleri kullanılmaya başlamıştır.

Son yıllarda özellikle terör örgütleri tarafından kullanılan El Yapımı Patlayıcılar (EYP) da mayınlar gibi bir çok insanın ölmesine, yaralanmasına veya psikolojik olarak zarar görmesine neden olmaktadır. EYP'ler düşük maliyetleri ve kolay elde edilebilir ve kullanılabilir olmaları sebebiyle terör örgütleri tarafından sıklıkla kullanılmaktadır. Belirli bir standartı olmayan EYP'lerin de tespit edilmesinde YNR teknolojisi en önemli teknolojilerden biri olarak gözükmektedir [7]–[9]. Ancak YNR teknolojisinin, EYP'lerin tespit edilmesi için kullanılması yönünde yapılan çalışmalar yeterince yaygınlaşmamış ve yeterli olgunluğa ulaşmamış durumdadır.

1.1 Problemin Tanımı ve Tezin Amacı

YNR sisteminin yerin altındaki herşeyi görme yeteneği plastik mayınların tespit edilmesinde avantaj sağlasa da aynı zamanda bir çok problem doğurmaktadır. Görüntülenmek istenen cisimle birlikte toprak içerisindeki düzensizlikler, ağaç kökleri, taşlar gibi görüntülenmek istenmeyen cisimlerde görüntülenmektedir. Bu gelen yansımaların birbirinden ayırt edilmesi veya bozucu etkilerin giderilmesi gerekmektedir. YNR sistemi ile plastik mayınların tespit edilmesi bazı koşullarda kolay olsa da toprak yapısı, toprağın elektromanyetik özellikleri ve daha bir çok etkenden dolayı bir çok durumda bu mayınların tespit edilmesi zordur. YNR sistemi ile plastik mayınların tespitini zorlaştıran bozucu etkiler kargaşa olarak adlandırılmaktadır. Özellikle küçük boyutlu plastik mayınlar yeryüzüne yakın gömüldüğünde kargaşa bu mayınların görüntülenmesini ve tespit edilmesini zorlaştırmaktadır. Kargaşa genel olarak yeryüzünden geri yansıyan işaret, alıcı-verici antenler arası kuplaj ve toprak içerisinde bulunan ağaç kökleri, ufak taşlar ve toprak içerisindeki düzensizlikler gibi istenmeyen cisimlerden yansıyan işaretlerden oluşmaktadır. Kargaşa yeryüzüne yakın gömülen plastik cisimlerden alınacak yansımayı bastırarak hedefin tespit edilememesine sebep olmasının yanında hedef olmayan bölgelerde de hedef varmış algısı oluşturarak yanlış tespitlere de sebep olmaktadır. Ayrıca YNR sistemi sıcaklıktan, iklim koşullarından ve

çevresel faktörlerden de etkilenmektedir. Örneğin yağmur yağmadan önce ve yağmur yağdıktan sonra aynı topraktan YNR sistemi ile alınan veriler farklılık göstermektedir. Islak toprakta toprağa gönderilen işarette çok fazla kayıp olmaktadır ve hedeften yansıyan işaretler de zayıflamaktadır.

Bu tez kapsamında; YNR verilerinde, özellikle yeryüzüne yakın gömülen ve metal içermeyen küçük mayınların tespiti zorlaştıran ve bazı durumlarda yanlış tespitlere sebep olan kargaşanın giderilmesi için 2 farklı yöntem önerilmiştir. Birinci yöntem, daha önce YNR verilerinde kargaşa gidermek için önerilen Analitik Sözlükler (AS) kullanan Morfolojik Bileşen Analizi (MBA-AS) yönteminin hızlandırılması ve iyileştirilmesi için Öğrenilmiş Sözlükler (ÖS) kullanan MBA-ÖS yöntemidir. Bu yöntemin çalışabilmesi için hem kargaşa bileşenini hem de hedef bileşenini temsil eden sözlükler öğrenilmiştir ve MBA yöntemi bu sözlükleri kullanarak kargaşa giderme yapmaktadır. Analitik sözlükler kullanan MBA yöntemine göre 6.8 kat daha hızlı çalışmaktadır. Ayrıca önerilen yöntemin yanlış alarm oranı MBA-AS yöntemine göre 42 kat daha azdır. İkinci olarak Evrişimsel Otokodlayıcılar (EOK) yönteminin YNR verilerinde kargaşa gidermek için kullanılması önerilmiştir. Önerilen yaklaşım, 2-boyutlu YNR verilerindeki kargaşayı gidermek için EOK yöntemini kullanan literatürdeki ilk çalışmadır. Önerilen yöntem, hem hedef hem de kargaşa bileşenlerini içeren YNR verilerinde kargaşanın nasıl giderileceğini öğrenmektedir.

1.2 Önerilen Yöntemler

MBA yöntemi bir görüntü ayrıştırma yöntemidir ve birden fazla farklı yapıdaki bileşenden oluşan görüntülerde her bir bileşeni birbirinden ayırmak için kullanılmaktadır [4,5]. Seyrek işaret işleme alanında önerilen bu yöntem bir çok farklı probleme de uygulanmıştır. MBA yöntemi görüntüyü farklı bileşenlere ayırırken her bir bileşen için o bileşenin yapısal özelliklerini iyi bir şekilde temsil edebilen sözlüklere ihtiyaç duymaktadır. Sözlükler atomlardan oluşmaktadır. Atom 1 boyutlu işaretler olabildiği gibi yama olarak adlandırılan 2 boyutlu küçük görüntü parçaları da olabilmektedir. Sözlükler 2 farklı yöntemle elde edilebilirler. İlk yöntemde analitik ifadeler kullanılarak analitik sözlükler oluşturulurken ikinci yöntemde eldeki

veriler üzerinde sözlük öğrenme algoritmaları çalıştırılarak öğrenilmiş sözlükler elde edilir. Analitik sözlükler aynı zamanda sabit sözlükler olarak da adlandırılmaktadır. Analitik fonksiyonların kullanılmasıyla oluşturulurlar. Ayrık Kosinüs Dönüşümü (AKD) yaygın olarak kullanılan analitik bir sözlüktür. Öğrenme tabanlı sözlükler aynı zamanda adaptif sözlükler olarak adlandırılmaktadır. Analitik sözlüklerin kullanıldığı alandaki veriyi temsil etme kabiliyeti sınırlıdır. Veriye ve probleme özgü sözlükler oluşturmak için veri setinde yer alan görüntülerden yamalar elde edilmektedir. Çok sayıda yama elde edildikten sonra bu yamalar sözlük öğrenme algoritmalarına verilmektedir ve sözlük öğrenme algoritmaları aldığı çok sayıda yamayı işleyerek çıktı olarak öğrenilmiş sözlüğü vermektedir. MBA algoritması görüntüye ait farklı biçimsel yapıdaki bileşenleri birbirinden ayırt etmek için bu bileşenleri iyi temsil eden sözlüklere ihtiyaç duyar ve yöntemin başarımı bu sözlüklere çok bağlıdır. Ayrıca bu sözlükler bir bileşeni seyrek olarak temsil ederken diğer bileşeni seyrek olarak temsil etmemesi gerekmektedir. MBA yönteminin başarımı bu şartın sağlanmasına bağlıdır. Analitik Sözlükler (AS) kullanan MBA algoritmasının (MBA-AS) YNR verilerinde kargaşa gidermek için kullanılabileceği gösterilmiştir [54]. Bu tez çalışması kapsamında Öğrenilmiş Sözlükler (ÖS) kullanan MBA algoritmasının (MBA-ÖS), MBA-AS algoritmasından daha hızlı çalıştığı ve daha iyi sonuç ürettiği gösterilmiştir. Öğrenilmiş sözlükler elde edebilmek için YNR verilerinin kargaşa ve hedef bileşenlerinden ayrı ayrı yamalar çıkarılarak K-SVD algoritmasına verilmiştir [91]. Elde edilen sözlükler kullanılarak YNR verilerinden alınan her bir yama Dik Eşleme Takibi (DET, Orthogonal Matching Pursuit, OMP) yöntemi ile bileşenlerine ayrılmıştır. Bileşenlerine ayrılan yamalar birleştirilerek hedef ve kargaşa görüntülerini oluşturmaktadır.

İkinci olarak Evrişimsel Otokodlayıcılar (EOK) yönteminin YNR verilerinde kargaşa gidermek için kullanılması literatürde ilk kez bu tez kapsamında önerilmiştir. EOK yönteminde, öncelikle önerilen ağ mimarisinin eğitilmesi gerekmektedir. Eğitim aşamasında tanımlanan ağ mimarisindeki katmanlarda kullanılan filtre katsayıları öğrenilmektedir. Katmanlarda kullanılan filtre katsayılarının öğrenilebilmesi ve geri yayılım aşamasında ağa bir geri bildirim verilebilmesi için referans verilere ihtiyaç vardır. Ağ kendi elde ettiği çıktı ile referans veri arasındaki benzerliğe bakarak eğitim

aşamasında öğrenmenin gerçekleşmesi için ağa geri bildirimde bulunmaktadır. YNR verilerinde referans veri, kargaşa içermeyen sadece hedef bileşeni içeren verilerdir. Referans verileri elde etmek için aynı ortam ve şartlarda başka hiç bir parametre değiştirilmeden sadece hedef varken ve yokken veriler alınması gerekmektedir. Bu veriler elde edildikten sonra hedef ve kargaşa bileşenleri içeren veriden sadece kargaşa bileşen içeren veri çıkarılarak referans veri elde edilmektedir. Gerçek YNR sistemi ile topraktan böyle bir veri elde etmek imkansızdır bu sebeple gprMax benzetim programı ile YNR veri seti oluşturulmuştur ve bu veri seti ile referans veri elde edilebilmektedir. EOK yönteminde başarılı sonuçlar elde etmek için veri sayısının çok olması gerekmektedir ancak benzetim programı ile veri elde etmek hem zahmetli hem de aylar süren işlemler gerektirdiği için veri çoğaltma teknikleri ile veri seti YNR verilerine uygun olacak şekilde çoğaltılmıştır. İhtiyaç duyulan veri sayısına ve referans verilere ulaştıktan sonra EOK yönteminin çalıştırılmasındaki en önemli engeller kaldırılmıştır. EOK yöntemi, eğitim aşamasında girdi olarak aldığı hem kargaşa hem de hedef içeren YNR verilerini referans verilere benzetmeye çalışır. Böylelikle kargaşayı nasıl gidereceğini öğrenmiş olur. Önerilen yöntem farklı açılardan bir çok teste tabi tutulmuştur. Hem literatürde yaygın olarak kullanılan yöntemlerle hem de son zamanlarda önerilen gelişmiş yöntemlerle karşılaştırıldığında tüm yöntemlere üstünlük sağladığı görülmüştür.




2. YERE NÜFUZ EDEN RADAR

YNR sistemi çok çeşitli jeofizik ve mühendislik uygulamaları için yaygın olarak tercih edilir. YNR sisteminin donanım ve yazılım gereksinimleri uygulama alanına göre değişmektedir. Genel olarak alıcı-verici antenler, kontrol ünitesi ve görüntüleme ekranı YNR sisteminin temel bileşenleridir. Bu temel bileşenlerden oluşan YNR sistemi [1] Şekil 2.1’de gösterilmektedir. Kontrol ünitesinde istenilen özelliklerde




Şekil 2.1 : YNR sistemi ve sistemi oluşturan bileşenlerin gösterimi [1]

darbe üretilir ve verici anten ile bu işaret yerin altına gönderilir, geri yansıyan işaretler alıcı anten ile toplanır ve işlenmesi için kontrol ünitesini iletilir. Alınan işaret üzerinde kuvvetlendirme, örnekleme işlemlerinden sonra işaret işleme algoritmalarıyla gürültü giderme, hedef tespiti gibi işlemler yapılır ve son olarak görüntüleme ekranında kullanıcıya algoritma sonucu ve yerin altına ait görüntüler gösterilir. YNR sistemlerinde alınan 1 boyutlu işarete A-tarama işareti denir ve örnek A-tarama işareti Şekil 2.2’de gösterilmektedir. X eksenini farklı derinliklerden alınan örnekleri, y eksenini ise işaretin genliğini göstermektedir. YNR sisteminin derinliği toprağın tipine göre değiştiği için x eksenini birimsiz olarak verilmiştir. YNR sistemlerinde aynı zamanda



Şekil 2.2 : YNR sisteminden alınan A-tarama işareti



Şekil 2.3 : YNR sisteminden alınan verilerle oluşturulan B-tarama görüntüsü

A-tarama işaretleri kullanılarak B-tarama olarak adlandırılan 2 boyutlu veriler de elde edilmektedir. A-tarama işaretlerinden elde edilen ve gri skalada çizdirilen B-tarama görüntüsü Şekil 2.3'te gösterilmektedir. B-tarama verisi matris olarak düşünüldüğünde A-tarama işaretleri bu matrisin her bir sütununa karşı gelmektedir. B-tarama verisinin y eksenini derinlik bilgisini, x eksenini ise ilerleme yönünü göstermektedir. Eğer robotik bir YNR sistemi sabit hız ile hareket ettiriliyorsa ve saniyede kaç tane A-tarama sinyali aldığı biliniyorsa yapılacak hesaplamalar ile B-tarama verisinde x eksenini cm




Şekil 2.4 : Araca takılı dizi antenlerden oluşan YNR sistemi [2]

cinsinden ifade edilebilir. 2 boyutlu B-tarama görüntülerinde A-tarama işaretlerine göre daha çok bilgi mevcuttur. Öznitelik çıkarma algoritmaları ile cisimlerden yansıyan işaretlerin oluşturduğu eğrisel izler sınıflandırılabilir. Bazı robotik YNR sistemlerinden birden çok alıcı-verici antenler bulunmaktadır. Bu antenler dizi antenler olarak da adlandırılmaktadır. Araca takılı dizi antenlerden oluşan örnek YNR sistemi Şekil 2.4'te gösterilmektedir [2]. Her bir alıcı-verici anten ikilisinden alınan veriler önce kendi içlerinde 2-boyutlu B-tarama verilerine daha sonra da bu B-tarama verileri birleştirilerek C-tarama olarak adlandırılan 3 boyutlu veriler elde edilmektedir. B-tarama görüntülerinin birleştirilmesiyle elde edilen C-tarama verisi [3] Şekil 2.5'te gösterilmektedir.


2.1 Benzetim Programı ile YNR Verisi Üretme

Yere Nüfuz Eden Radar (YNR) verisi üretmek için açık kaynak kodlu gprMax benzetim programı kullanılmaktadır. GprMax programı, Maxwell denklemlerini 2. dereceden Zaman-Domeninde Sonlu Farklar (ZDSF, Finite-Difference Time-Domain, FDTD) algoritması kullanarak sayısal olarak çözmektedir [50]. GprMax programında ticari antenlerin benzetimi yapılabilmektedir [51]. Veriler üretilirken $17 \times 10.8 \times 4.5$ cm boyutlarında olan Geophysical Survey Systems Inc. (GSSI) 1.5 GHz (Model



Şekil 2.5 : YNR sisteminden alınan verilerle oluşturulan C-tarama görüntüsü [3]

5100) ticari anteni kullanılmıştır [52,53]. Anten ve yeryüzü arasındaki mesafe 5 cm olarak ayarlanmıştır. Benzetim için kullanılan ortam $100 \times 12 \times 40$ cm boyutlarındadır. Modelin çözünürlük adımı ($\Delta x = \Delta y = \Delta z = 0.1$ cm) olarak seçilmiştir. Her YNR verisinde yalnızca bir silindirik gömülü cisim kullanıldı. Gömülü cismin merkezi, x ekseninde (antenin ilerleme doğrultusunda) 50 cm’de konumlandırıldı. Benzetim modeli Şekil 2.6’da gösterilmektedir. Anten x yönünde her benzetimde 1 cm hareket




Şekil 2.6 : Veri seti üretimi için benzetim modeli

ettirilmektedir ve her bir konum için 1 adet A-tarama işareti alınmaktadır. Antenin başlangıç konumu 10 cm’dir ve 80 defa çalıştırılarak 80 cm uzunluğunda bir alan


Çizelge 2.1 : Malzemelerin elektromanyetik özellikleri

Malzeme	Dielektrik Sabiti	İletkenlik
Kuru Kum (Dry sand)	3.0	0.001
Nemli Kum (Damp sand)	8.0	0.01
Islak Kum (Wet sand)	20.0	0.1
Kuru Killi Toprak (Dry clay soil)	10.0	0.01
Islak Killi Toprak (Wet clay soil)	12.0	0.01
Kuru Kum-Kil Toprak (Dry loam soil)	10.0	0.001
Alüminyum	3.1	2.3e7
Plastik	3.0	0.01

taranmaktadır ve B-tarama verisi elde edilmektedir. Veri seti; 4 farklı senaryo, 7 farklı toprak tipi, 2 farklı maddeden yapılmış hedef ve 6 farklı hedef gömülme derinliği için oluşturulmuştur. Veri seti 364 adet veriden oluşmaktadır. 336 tane veri de hedef vardır. 28 tane (4 farklı senaryo, 7 farklı toprak tipi) veri, referans veri elde etmek için hedef olmadan elde edilmiştir. 6 farklı toprak tipinin ve 2 farklı cismin elektromanyetik özellikleri Çizelge 2.1’de gösterilmektedir. Bu tabloda yer alan değerler [54] yayınından alınmıştır. 7. toprak tipi gprMax ile elde edilen karışım toprak tipidir. Kum ve kil aynı oranda karıştırılmıştır. Kütle yoğunluğu 2 g/cm^3 , kum parçacık yoğunluğu 2.66 g/cm^3 , hacimsel su oranı 0.001 – 0.25 olarak seçilmiştir. Her senaryoda ve toprak tipinde silindirik cisim yüzeyden 0, 1, 2, 3, 4, 5, cm derinliğe gömülmüştür. Mayınlar yüzeye yakın gömüldüklerinde tespiti çok zor olduğundan, cisimlerin gömülme derinlikleri özellikle yüzeye yakın olarak seçilmiştir. Cisim olarak yarıçapı 2.8 cm ve yüksekliği 4 cm olan silindir kullanılmıştır. Cismin boyutları M14 plastik anti-personel mayınının boyutlarıyla aynıdır. Veriler 4 farklı senaryo kullanılarak üretilmiştir. İlk senaryoda yeryüzü düz olarak modellenmiştir. Bu senaryo tüm senaryolar içerisindeki en basit senaryodur. Şekil 2.7’de gösterilen senaryo-1, gprMax programından alınan çıktının açık kaynak kodlu Paraview [40] programında gösterilmesiyle elde edilmiştir. İkinci senaryoda düz bir zemin üzerinde 2 cm kökü, 2 cm yüksekliği olan 10000 adet çim modellenmiştir ve görsel olarak Şekil 2.8’de sunulmuştur. Bu senaryo ile bitki örtüsünün etkisi incelenmektedir. Üçüncü senaryoda yeryüzü engebeli olarak modellenmiştir. Genellikle algoritmalar yeryüzünü düz kabul ettiği için YNR sistemi ile gömülü cisim tespiti yaparken en çok yanlış alarm




Şekil 2.7 : Senaryo-1 için oluşturulan model




Şekil 2.8 : Senaryo-2 için oluşturulan model

yeryüzünün engebeli olmasından kaynaklanmaktadır. Geliştirilen algoritmanın birçok koşulda başarılı olabilmesi için bu senaryonun veri setinde olması büyük önem arz etmektedir. Yeryüzündeki dalgalanma 2 cm olacak şekilde modelleme yapılmıştır. Oluşturulan model Şekil 2.9'da gösterilmektedir. Son senaryo engebeli yüzeyde su birikintilerinden oluşmaktadır. Suyun iletkenliği yüksektir ve işaret su içerisinde fazla kayıp verdiği için kuru ortamlara göre derinlere inmesi zorlaşır. Yeryüzündeki dalgalanma üçüncü senaryoyla aynıdır. Bu engebeli yüzeyde 0.5 cm yüksekliğinde su birikintileri oluşacak şekilde modelleme yapılmıştır. Oluşturulan model Şekil 2.10'da gösterilmektedir.




Şekil 2.9 : Senaryo-3 için oluşturulan model



Şekil 2.10 : Senaryo-4 için oluşturulan model

2.2 Referans Veri Üretme


Oluşturulan veri setinde her bir toprak tipi ve her bir senaryo için hedef içermeyen arkaplan verisi de üretilmiştir. 336 adet hedef içeren veriler için elde edildikleri senaryo ve toprak tipi göz önünde bulundurularak ilgili arkaplan verisi çıkarılmaktadır ve her bir hedef içeren veri için kargaşa olmayan referans veri elde edilmektedir. Referans veri ve bu veriyi oluşturmak için kullanılan veriler Şekil 2.11’de gösterilmektedir.



Şekil 2.11 : Referans veri oluşturma. a) Hedef içeren ham veri. b) Hedef içermeyen arkaplan verisi. c) Referans veri.

2.3 Gerçek YNR Verileri

Önerilen yöntemlerin performansı gerçek YNR verileri ile de test edilmiştir. Önerilen yöntemin etkinliğini doğrulamak için literatürde yaygın olarak kullanılan Vrije Universiteit Brussel [41] tarafından paylaşılan gerçek YNR verileri seçildi. Verinin alındığı YNR sisteminde 1 GHz anten kullanılmıştır ve darbe (pulse) genişliği 1 ns, örnekleme aralığı 25 ps, örnek sayısı 512'dir. Tarama işlemi gerçekleştirilirken antenler ile yüzeyin en yüksek noktası arasındaki mesafe 5 cm'dir. Veri almadan önce test havuzunun yüzeyi düzeltilmiştir ancak yine de yüzeyde 10 cm civarında düzensizlikler vardır. İlk veri 24 Mart 1999 tarihinde içerisinde küçük taşların olduğu ıslatılmış kil toprakla dolu test havuzunda gerçekleştirilmiştir. Yüksekliği 4 cm, çapı 11 cm olan plastik dış kasası olan PMA-3 anti-personel mayını 5 cm derinliğe gömülmüştür. İlk veri alındıktan sonra toprak kurumaya bırakılmıştır ve 23 gün sonra toprak hala nemli bir durumdayken ikinci kez gömülü cisimde herhangi bir değişiklik yapmadan veri alınmıştır. Toprağın yüzeyinde çatlaklar vardır. Toprak




Şekil 2.12 : Gerçek YNR verileri. a) Islak topraktan alınan veri. b) Kuru topraktan alınan veri.

ıslakken ve kuruduktan sonra PMA-3 plastik mayınından alınan veriler Şekil 2.12’de gösterilmektedir.

2.4 Veri Çoğaltma Üzerine Yapılan Çalışmalar

Derin öğrenmede kullanılan ağ mimarileri genellikle çok sayıda veriye ihtiyaç duymaktadır. Veri sayısı arttıkça daha büyük modeller kullanılmaktadır ve daha yüksek başarı oranları elde edilmektedir. GprMax benzetim programı güçlü bir ekran kartı üzerinde çalıştırıldığında (GTX 1080) bir adet YNR görüntüsü (B-tarama) elde edebilmek için yaklaşık 3.5 saat gerekmektedir. İşlemci (CPU) üzerinde çalıştırılan benzetimler yaklaşık 72 saat sürmektedir. 364 adet veriden oluşan veri setini üretmek için yaklaşık 1274 (364x3.5) saat harcanmıştır. Bilgisayarın hiç durmadan çalıştırıldığı durum için bu veri setini üretmek için 53 gün vakit gerekmektedir. YNR verisi elde etmek, yapılan hesaba göre çok vakit alan bir süreçtir. Bu sebeple yapay sinir ağlarında daha yüksek başarılar elde edebilmek için veri çoğaltma algoritmalarından yararlanılmıştır [95]. Veri çoğaltma işlemi genelde döndürme, ölçeklendirme, gürültü, engel, gölge ekleme, görüntüyü yatay ve dikeyde kaydırma gibi birçok işlem ile



Şekil 2.13 : Yatay $-x$ (sol) yönünde kaydırma işlemi sonucu elde edilen ham ve referans veriler. Ham veri kaydırma miktarı (a) 10 A-tarama, (b) 8 A-tarama, (c) 6 A-tarama, (d) 4 A-tarama, (e) 2 A-tarama, ve referans veri kaydırma miktarı (f) 10 A-tarama, (g) 8 A-tarama, (h) 6 A-tarama, (i) 4 A-tarama, (j) 2 A-tarama.

gerçekleşmektedir. Fakat görüntü sınıflandırma, nesne tespit etme gibi alanlarda uygulanan bu işlemler YNR görüntüleri için uygun değildir [96,97]. 4 farklı senaryo, 7 farklı toprak tipi ve 2 farklı cisim ile veri seti çeşitlendirilmeye çalışılmıştır. Aynı zamanda cisim 6 farklı derinlik seviyesine gömülmüştür. Bu sebeple yatay yönde uygulanacak kaydırma işlemi verileri arttırmak için uygun bir yöntemdir, diğer işlemlere gerek yoktur. Kaydırma işlemi hem $-x$ hem de $+x$ yönlerinde 2, 4, 6, 8 ve

10 piksel boyutunda gerçekleştirilir. Böylelikle tek bir YNR verisinden, veri çoğaltma işlemi sonucunda 10 tane yeni YNR verisi elde edilmektedir. Toplamda hedef içeren YNR veri sayısı 336'sı orijinal 3360'ı çoğaltılan olmak üzere 3696'ya çıkarılmıştır. Kaydırma işlemi sonucunda oluşan boş pikseller, kaydırma işlemi yapmadan önce o bölgede yer alan A-tarama işaretlerinin ortalaması ile doldurulmaktadır. Senaryo-1'de, karışım toprakta alüminyum silindirin 0 cm derinliğe gömülmesiyle elde edilen verinin yatay kaydırma işlemi sonunda elde edilen referans ve ham veriler Şekil 2.13'te gösterilmektedir.

2.5 Performans Değerlendirme Ölçütleri

Yöntemlerin performansını karşılaştırmak için görsel inceleme yeterli değildir. Yöntemleri sayısal sonuçlar ile değerlendirmek gerekmektedir.

2.5.1 Tepe işaret gürültü oranı (TİGO - PSNR)


Gprmax benzetim programı ile oluşturulan veri setinde kargaşa içermeyen sadece hedeften oluşan veriler olduğu için bu veri seti ile Tepe İşaret-Gürültü Oranı (TİGO, Peak Signal-to-Noise Ratio, PSNR) hesabı yapılabilir. TİGO hesabı referans verilere ihtiyaç duymaktadır. YNR verilerinde kargaşa giderme yapıldıktan sonra elde edilen çıktı, referans veri ile karşılaştırılarak kargaşa gidermenin ne kadar başarılı yapıldığı ölçülmektedir. TİGO (2.1) ile hesaplanmaktadır.

$$TİGO(dB) = 10 \log \left(\frac{1}{OKH(X, Y)} \right) \quad (2.1)$$

burada Ortalama Kare Hatası (OKH, Mean Squared Error, MSE)

$$OKH = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (X(i, j) - Y(i, j))^2 \quad (2.2)$$

olarak hesaplanmaktadır. X referans veriyi, Y kargaşa giderme işlemi yapıldıktan sonra yeniden oluşturulan veriyi temsil etmektedir. M ve N parametreleri YNR B-tarama verisinin sırasıyla yükseklik ve genişlik değerlerini göstermektedir.



Şekil 2.14 : Hedef tespit bölgesi ve yanlış alarm bölgelerinin gösterimi

2.5.2 İşaret kargaşa oranı (İKO - SCR)

Gerçek YNR verilerinde referans veri elde edilemediği için yöntemlerin performansını karşılaştırmak için TİGO dışında farklı bir değerlendirme ölçütüne ihtiyaç vardır. Gerçek YNR verilerinde yöntemlerin kargaşa giderme performansını karşılaştırmak için İşaret-Kargaşa Oranı (İKO, Signal-to-Clutter Ratio, SCR) ölçütü kullanılacaktır. İKO hesabı için öncelikle yeniden oluşturulan B-tarama verisi ($X \in \mathbb{R}^{M \times N}$) $[-1, 1]$ aralığına normalize edilir. Daha sonra Hedef Enerji Fonksiyonu ($HEF \in \mathbb{R}^N$) her bir anten pozisyonu için ($k = 1, 2, \dots, N$) için hesaplanır. HEF genellikle düzensizlik (anomaly) tespiti için kullanılır ve (2.3) ile hesaplanır.

$$HEF(k) = \sum_{i=1}^M X(i, k)^2. \quad (2.3)$$

HEF değeri hesaplandıktan sonra 1 değerine normalize edilir. Hedefin, antenin ilerleme doğrultusundaki pozisyonu ve yakın çevresi Hedef Tespit Bölgesi (HTB) olarak adlandırılır. HTB dışında kalan bölgeler Yanlış Alarm Bölgesi (YAB) olarak adlandırılır. Bu bölgeler hedef ve kargaşa işaretlerini ayırt etmek için kullanılmaktadır. Hesaplanan HEF değerleri bu bölgeler gözönünde bulundurularak hedef tespit bölgesine ait değerler (HEF_{HTB}) ve yanlış alarm bölgesine ait değerler (HEF_{YAB}) olarak 2'ye ayrılır. İşaret gücü HEF_{HTB} 'nin maksimum değeri olarak hesaplanır. Kargaşa gücü HEF_{YAB} değerlerinden yararlanarak 2 farklı şekilde hesaplanır. İlk olarak HEF_{YAB} değerinin maksimum değeri alınarak $\hat{I}KO_{maks}$ değeri

(2.4) ile hesaplanır.

$$IKO_{maks} = \frac{\max(HEF_{HTB})}{\max(HEF_{YAB})}. \quad (2.4)$$

İkinci olarak (2.5) ile HEF_{YAB} değerlerinin ortalaması kullanılarak IKO_{ort} değeri hesaplanır.

$$IKO_{ort} = \frac{\max(HEF_{HTB})}{1/K \sum_{n=1}^K HEF_{YAB}(n)} \quad (2.5)$$

Burada K değeri yanlış alarm bölgesinde bulunan örnek sayısını ifade etmektedir. Hedef tespit bölgesi ve yanlış alarm bölgeleri Şekil 2.14'te gösterilmektedir. İKO değeri yeniden oluşturulan görüntüde kargaşanın ne kadar çok temizlendiğini ölçmektedir.

2.5.3 Alıcı işletim karakteristiği (AİK - ROC) eğrileri


Alıcı İşletim Karakteristiği (AİK - ROC) eğrileri ikili sınıflandırma sistemlerinde sistemin performansını farklı eşik değerleri için hesaplayan ve grafiksel olarak gösteren bir hesaplama yöntemidir. AİK grafiği sayesinde farklı eşik değerleri için yöntemin doğru tespit oranının, yanlış alarm oranına göre durumu incelenebilmektedir. Genellikle y ekseninde doğru tespit oranı, x ekseninde ise yanlış alarm oranı verilmektedir. AİK grafiğinde en iyi yöntem, en yüksek doğru tespit oranı veren ve aynı zamanda en düşük yanlış alarm oranına sahip olan yöntemdir. Yöntemlerin performansı bu 2 kritere göre değerlendirilir. Örnek AİK (ROC) eğrisi Şekil 2.15'te gösterilmektedir. Doğru Tespit Oranı (DTO), hedef tespit bölgesi içerisinde yer alan hedefin tespit sayısının veri setinde yer alan toplam B-tarama sayısına bölünmesi ile elde edilir. Her B-tarama verisi sadece 1 tane hedef içerdiğinden dolayı toplam B-tarama sayısı aynı zamanda toplam hedef sayısını vermektedir. DTO ifadesi (2.6) denkleminde verilmiştir.

$$DTO = \frac{\text{toplam doğru tespit sayısı}}{\text{toplam tespit edilmesi beklenen cisim sayısı}} \quad (2.6)$$

Yanlış Alarm Oranı (YAO), yanlış alarm bölgesinde alınan toplam tespit sayısının maksimum yanlış alarm sayısına bölünmesi ile bulunur (2.7).

$$YAO = \frac{\text{yanlış alarm bölgesinde alınan toplam tespit sayısı}}{\text{maksimum yanlış alarm sayısı (MYAS)}} \quad (2.7)$$

Eşik değerini geçen 5 örnek 1 tespit olarak kabul edilmiştir. Bu sebeple Maksimum Yanlış Alarm Sayısı (MYAS), yanlış alarm bölgesindeki örnek sayısının 5'e bölünmesi



Şekil 2.15 : AİK (ROC) eğrisi

ile elde edilmektedir (2.8).

$$MYAS = \frac{\text{yanlış alarm bölgesindeki örnek sayısı}}{5} \quad (2.8)$$

3. KARGAŞA GİDERME YÖNTEMLERİ

Yere Nüfuz Eden Radarda (YNR) özellikle yeryüzüne yakın gömülen küçük cisimlerin tespitini zorlaştıran bozucu etkiler kargaşa olarak adlandırılmaktadır. Kargaşa genel olarak yeryüzünden geri yansıyan işaret, alıcı-verici antenler arası kuplaj ve toprak içerisinde istenmeyen cisimlerden yansıyan işaretlerden oluşmaktadır. Toprak içerisindeki istenmeyen cisimlere örnek olarak ağaç kökleri, ufak taşlar ve toprak içerisindeki düzensizlikler verilebilir. YNR sistemi ile metal dedektörlerinin tespit edemediği minimum metal içeren plastik mayınlar tespit edilebilmektedir ancak kargaşa olarak adlandırılan bozucu etkiler bu mayınların görüntülenmesinin ve tespit edilmesinin önüne geçmektedir. Kargaşa yeryüzüne yakın gömülen plastik cisimlerden alınacak yansımayı bastırarak hedefin tespit edilememesine sebep olmasının yanında hedef olmayan bölgelerde de hedef varmış algısı oluşturarak yanlış tespitlere de sebep olmaktadır. Yanlış tespitlerin önüne geçmek ve yeryüzüne yakın mesafeye gömülen küçük boyutlu (anti-personel) plastik maddeden yapılmış mayınların tespit edilmesini kolaylaştırmak için kargaşa giderme yöntemleri önemli bir yere sahiptir.

3.1 Literatür Araştırması

Literatürde YNR verilerinde kargaşa gidermek için yıllar içinde farklı yaklaşımlar önerilmiştir. En ilkel yaklaşım, hedef olmayan bölgedeki verilerin ortalamasını alarak diğer tüm verilerden çıkararak kargaşa giderme yapan Ortalama Çıkarma (OÇ) yöntemidir [10,12,23]. Bu yaklaşım hedefin olmadığı bölge bilgisi gerektirir ve yöntem yeryüzünün düz olduğunu kabul ettiği için yöntemin başarısı yeryüzünün engebesiz olmasına ve anten ile toprak arasındaki mesafenin değişmemesine bağlıdır. OÇ yöntemine çok benzeyen bir diğer yöntem ise Medyan Çıkarma (MÇ) yöntemidir [12,23]. MÇ yönteminde hedef olmayan bölgedeki A-tarama işaretlerinin ortalaması yerine medyanı alınmaktadır ve yine OÇ yönteminde olduğu gibi diğer tüm A-tarama işaretlerinden çıkarılmaktadır. Bu yaklaşımların Hareketli Ortalama Çıkarma (HOÇ)

ve Hareketli Medyan Çıkarma (HMÇ) adlarında adaptif versiyonları da mevcuttur ancak adaptif yaklaşımlar da hedef imzasını bozmaktadır ve seçilen pencere boyu parametresi yöntemin başarımında önemli rol oynamaktadır [26,27]. Kalman filtresi [28]–[31] ve Dalgacık (Wavelet) Dönüşümü (DD) [12,16,17,32,33] gibi istatistiksel yöntemlerde öncelikle arkaplan sinyali kestirmektedir. Bu kestirim kargaşasının ya da arkaplanın modellenmesi olarak değerlendirilebilir. Kestirilen arkaplan sinyali diğer tüm işaretlerden çıkarılarak kargaşa giderme yapılmaktadır. Kalman filtresi yönteminin OÇ, MÇ, HOÇ, HMÇ ve DD yöntemlerine üstünlük sağladığı [28] yayınında gösterilmiştir. DD yöntemi ile YNR verilerinde kargaşa giderme yapıldığında OÇ, MÇ, HOÇ, HMÇ, Olabilirlik Oranı Testi (OOT) ve Tekil Değer Ayrışımı (TDA) yöntemlerine göre daha iyi sonuçlar elde edilmiştir [12]. Dalgacık Dönüşümü ve Kalman Filtresi yöntemleri de diğer yöntemler gibi hedef olmayan bölgede arkaplan kestirimi yaptığı için arkaplan kestirimi yapılacak bölgede hedefin olup olmadığı bilgisine ihtiyaç duymaktadır. Ayrıca kalman filtresi yönteminin işlem yükü çok fazladır. OOT yönteminin YNR verilerinde kargaşa gidermek için kullanılması [34] yayınında önerilmiştir ve OÇ yöntemine göre daha iyi sonuçlar elde edilmiştir. Bu yöntemin başarımında kullanılan eşik değeri etkili olmaktadır ve uygun eşik değeri belirlenemediğinde yöntemin başarımı düşmektedir [12,34]. YNR verilerinde kargaşa gidermek için [35] yayınında iki boyutlu sayısal filtre tasarlanmıştır ve tasarlanan filtre ile kargaşa giderme yapıldığında OÇ yöntemine göre daha iyi sonuçlar elde edilmiştir ancak filtre tasarımı yapılırken hem yeryüzü ve antenler arası mesafenin değişmediği hemde yeryüzünün düz olduğu varsayımında bulunulmuştur. Bu sebeple önerilen yöntemin başarımı yeryüzünün engebeli olduğu durumlarda düşmektedir. [35] yayınında önerilen iki boyutlu sayısal filtreleme yöntemine üstünlük sağlayan ve yeryüzünün engebeli olduğu durumlarda da başarımı düşmeyen simetrik filtre tasarımı [36] yayınında önerilmiştir. [37] yayınında ilk olarak, antenin kendisinden ve anten ile yer arasındaki etkileşimden kaynaklanan çoklu anten yansımaları, lineer transfer fonksiyonları kullanılarak giderilir. İkinci olarak yüzey yansıması için simüle edilmiş bir Green fonksiyonu çıkarılır. Böylelikle YNR verilerinde kargaşa giderme işlemi gerçekleştirilir. Önerilen bu yöntemin OÇ yöntemine üstünlük sağladığı gösterilmiştir. YNR verilerinde kargaşayı modellemek

için önerilen parametrik yöntem de vardır [38]. Kargaşayı modelleyen parametrik yöntem OÇ yöntemine üstünlük sağlamıştır, ancak bu yöntem hedefe ait referans işarete ihtiyaç duymaktadır.

YNR verilerinde kargaşa gidermek için kullanılan bir başka yaklaşım ise veriyi alt uzaylara ayıran istatistiksel yöntemlerin kullanılmasıdır. Bu yaklaşımda YNR verisi hedef, kargaşa ve gürültü olarak alt bileşenlere ayrılmaktadır. Tekil Değer Ayrışımı (TDA) [12,13,33,42,43,49], Temel Bileşen Analizi (TBA) [14,18,23,24,49], Bağımsız Bileşen Analizi (BBA) [14,18,19,24,25,46]–[49], Çarpan Analizi (ÇA) [15,49], Bağımsız Çarpan Analizi (BÇA) [15] yöntemleri bu yaklaşım içerisinde yer alan YNR verilerinde kargaşa gidermek için kullanılan yöntemlerdir. Ayrıca BBA yöntemini gerçekleyen farklı algoritmalar geliştirilmiştir. Bell-Sejnowski [20], Molgedey-Schuster [21], FASTICA [44], Joint Approximate Diagonalization of Eigenmatrices (JADE) [45] ve Kernel-ICA (KICA) [22] algoritmaları BBA yöntemi için önerilen algoritmalarlardır. Tüm bu veriyi alt uzaya ayıran yöntemler genel olarak kargaşayla hedefin iç içe olduğu ve basit bir şekilde ayrıştırılamadığı durumda B-tarama görüntülerini hedef, kargaşa ve gürültü (arkaplan) şeklinde alt uzaylara ayırmaktadır. Bu yaklaşım içerisinde Negatif Olmayan Matris Ayrışımı (NMA) yöntemi de yer almaktadır [65,68]. NMA yöntemi görüntüyü iki matrisin çarpımı şeklinde ifade etmektedir ve bu yöntemde her iki matrisin elemanlarında negatif olmaması gerekmektedir.

Görüntüyü sahip olduğu sözlükler ile farklı bileşenlere ayıran Morfolojik Bileşen Analizi (MBA, Morphological Component Analysis) yöntemi de YNR verilerinde kargaşa gidermek için kullanılan yaklaşımlardandır [54]. Önerilen yöntem analitik sözlükler (dönüşümler) kullanarak YNR verilerinde kargaşa giderme yapmaktadır. Bu tez çalışması kapsamında Öğrenilmiş Sözlükler kullanan MBA (MBA-ÖS) yöntemi YNR verilerinde kargaşa gidermek için önerilmiştir. Sözlük öğrenmek için K-SVD algoritmasından yararlanılmıştır. Bu yöntemle ait daha ayrıntılı bilgiler Bölüm 4'te yer almaktadır. Ayrıca, YNR verilerinde sözlük öğrenerek kargaşa veya gürültü giderme yapan çalışmalar da mevcuttur [75,76].

Çoklu Çözünürlüklü ve Çoklu Yönlü (ÇÇÇY, Multi-Scale Multi-Directional, MSMD) yöntemler de YNR verilerinde kargaşa gidermek için önerilmiştir [68]–[74]. Shearlet dönüşümü [70,71] yayınlarında, curvelet dönüşümü [72,73] yayınlarında, contourlet dönüşümü ise [74] yayınında YNR verilerinde kargaşa gidermek için önerilmiştir.

Son yıllarda görüntü işleme alanında yaygın olarak kullanılan ve bir çok probleme uygulanan Düşük Dereceli ve Seyrek Ayırıştırma (DDSA, Low-Rank and Sparse Decomposition (LRSD)) yöntemleri de kargaşa gidermek için kullanılmaktadır. Bu yöntemler veriyi eş zamanlı olarak düşük dereceli ve seyrek olarak ayırştırmaktadırlar. YNR verilerinde düşük dereceli bileşen kargaşa bileşeni, seyrek bileşen ise hedef bileşeni olarak kabul edilmektedir. Bu yaklaşım içerisinde yer alan Gürbüz Temel Bileşen Analizi (GTBA, Robust PCA) yöntemi [56] YNR verilerinde kargaşa gidermek için kullanılmaktadır [57]. GTBA yönteminde konveks optimizasyon probleminde nükleer norm kullanılmıştır ve nükleer norm kullanımı yüksek boyutlu TDA işlemi gerektirir ve bu sebeple bu yöntemin işlem yükünü azaltabilmek adına farklı yaklaşımlar da önerilmiştir. GoDec yönteminde [59] TDA işlemi yerine daha az iş yükü gerektiren bilateral random projections işleminin kullanılması önerilmiştir. GoDec yöntemi [60,61] yayınlarında YNR verilerinde kargaşa gidermek için kullanılmıştır. Gürbüz Ortonormal Alt uzay Öğrenimi (GOAÖ, Robust Orthonormal Subspace Learning, ROSL) yönteminde düşük dereceli bileşeni modellemek için GTBA yönteminde yer alan nükleer norm ifadesi yerine ortonormal alt uzay altındaki grup seyreklik katsayıları kullanılır [62]. GOAÖ yöntemi de YNR verilerinde kargaşa gidermek için kullanılmaktadır [63]. Veriyi eş zamanlı olarak hem düşük dereceli matrise hem de seyrek bileşene ayıran bir diğer yöntem ise Gürbüz Negatif Olmayan Matris Ayırışımı (GNMA, Robust NMF) yöntemidir [66]. YNR verilerinde kargaşa gidermek için önerilen GNMA yöntemi, GTBA yönteminden 25 kat daha hızlıdır ve GTBA yöntemini performans olarak geçmektedir [67]. YNR verilerinde kargaşa gidermek için DDSA probleminin GTBA yöntemi yerine Gürbüz Otokodlayıcı (GOK, Robust Autoencoder (RAE)) ile çözülmesi önerilmiştir [119]. GOK yönteminde, seyrek bileşen GTBA yönteminde olduğu gibi elde edilirken düşük dereceli bileşen için TDA yönteminin iteratif kullanımı yerine otokodlayıcıların lineer olmayan gösterim kabiliyetinden yararlanır [119].

Derin öğrenme alanında yaşanan gelişmeler YNR verilerinde kargaşa giderme konusuna da yansımıştır. Derin öğrenme alanında önerilen ağlar bir çok problemde klasik yöntemlere üstünlük sağlamaktadır ve gün geçtikçe derin öğrenme alanı içerisinde yer alan yöntemler bir çok alanda kullanılmaktadır. Bu tez çalışması kapsamında Evrışimsel Otokodlayıcıların (EOK) YNR verilerinde kargaşa gidermek için kullanılması önerilmiştir [98]. Önerilen yöntem literatürde bu alanda yapılan ilk çalışmadır. Aynı zamanda farklı derin ağ modelleri kullanan çalışmalarda yapılmaktadır. [124] yayınında Koşullu Çekişmeli Üretici Ağlar (KÇÜA, Conditional Generative Adversarial Nets (cGAN)) yöntemi YNR verilerinde kargaşa gidermek için önerilmiştir. EOK yönteminde olduğu gibi önerilen ağ yapısı kargaşayı nasıl gidereceğini öğrenmektedir. [126] yayınında GNMA yöntemi eşliğinde çalışan derin öğrenme ağ yapısı YNR verilerinde kargaşa gidermek için önerilmiştir. Önerilen ağ yapısı 2 alt ağdan oluşmaktadır, bu ağlardan birisi düşük dereceli bileşeni diğeri ise seyrek bileşeni elde etmek için kullanılmaktadır. [125] yayınında U-Net ağ mimarisinden yararlanan bir kargaşa giderme ağı önerilmiştir. Ağın eğitilmesinde hem benzetim programı yardımıyla elde edilen benzetim verileri hem de gerçek YNR sistemi ile elde edilen veriler kullanılmıştır. [127] yayınında ise derin evrışimsel gürültü giderici otokodlayıcılar YNR verilerinde sadece gürültü gidermek için önerilmiştir.

3.2 İstatistiksel (Alt Uzay Tabanlı) Yöntemler

YNR verilerinde kargaşa gidermek için kullanılan yaklaşımlardan biri veriyi alt uzaylara ayıran istatistiksel yöntemlerdir. Bu yaklaşımda YNR verisi hedef, kargaşa ve gürültü olarak alt bileşenlere ayrılmaktadır. Bu yöntemlerde genellikle en yüksek yansımanın yerden geldiği kabul edilerek kargaşanın en yüksek bilgiye sahip ilk uzayda olduğu, hedefin ise en yüksek ikinci bilgiye sahip ikinci uzayda olduğu ve gürültünün diğeri alt uzaylarda olduğu varsayılmaktadır. Ancak YNR verisinde yer alan hedef sayısına göre hedef bilgisi sadece ikinci en yüksek bilgiye sahip uzayla kalmayıp diğeri uzaylara da yayılmaktadır. Bu yaklaşım içerisinde yer alan ve yaygın olarak

kullanılan Temel Bileşen Analizi (TBA), Tekil Değer Ayrışımı (TDA) ve Negatif Olmayan Matris Ayrışımı (NMA) yöntemlerinden bahsedilecektir.

3.2.1 Temel bileşen analizi (TBA - PCA)

TBA, gözlem başına çok sayıda boyut içeren büyük veri kümelerini analiz etmek, maksimum bilgi miktarını korurken verilerin yorumlanabilirliğini arttırmak ve çok boyutlu verilerin görselleştirilmesini sağlamak için kullanılan popüler bir tekniktir. Özetle, TBA veri kümesinin boyutsallığını azaltmak için kullanılan istatistiksel bir yöntemdir. Boyut azaltma işlemi verilerin doğrusal bir dönüşümle verilerdeki varyasyonun ilk verilerden daha az boyutla tanımlanabileceği yeni bir koordinat sistemine dönüştürülmesiyle gerçekleştirilir. TBA yöntemi görüntü işleme alanında gürültü gidermek için kullanılan bir yöntemdir. TBA yöntemi veriyi ilintisiz bileşenlere ayırdığından dolayı YNR verilerini de kargaşa ve hedef olarak ayırmak için kullanılmaktadır. B-tarama verisi M satır ve N sütundan oluşan matris olarak X_{ij} ($i = 1, 2, \dots, M$ ve $j = 1, 2, \dots, N$) ifade edilir ve burada i derinliği, j ise anten konumunu göstermektedir. TBA yöntemi B-tarama verisini N temel bileşen olarak (3.1) ile ifade etmektedir.

$$Y = A^T X \quad (3.1)$$

Burada X sıfır ortalamalı giriş matrisi, Y temel bileşenler olarak adlandırılan çıkış matrisi, A ise $M \times N$ boyutunda dönüşüm matrisidir. Temel bileşenleri bulmak için A dönüşüm matrisi bulunmak zorundadır. A matrisinin hesaplanabilmesi için öncelikle ortalaması çıkarılmış ve normalize edilmiş X matrisinin ortak değişinti (kovaryans) matrisi C_x (3.2) ile hesaplanır.

$$C_x = \frac{1}{N} X X^T \quad (3.2)$$

Hesaplanan ortak değişinti matrisinin öz vektör ve öz değerleri (3.3) formülüyle bulunur.

$$C_x \phi = \phi \Lambda \quad (3.3)$$

Burada $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_N)$ ve $\lambda_1, \lambda_2, \dots, \lambda_N$ öz değerlerdir. Bulunan öz değerler ve bu özdeğerlere karşı düşen öz vektörler azalan sıraya göre sıralanırlar ($\lambda_1 \geq \lambda_2 \geq$

$\dots \geq \lambda_N$). A dönüşüm matrisi sıralanan öz vektörler kullanılarak (3.4) bulunur.

$$A = [\phi_1, \phi_2, \dots, \phi_N] \quad (3.4)$$

A dönüşüm matrisi hesaplandıktan sonra temel bileşen matrisi, S , (3.5) ile hesaplanabilir. S , temel bileşen matrisinin hesaplanmasıyla B-tarama görüntüsü kargaşa ve hedef şeklinde alt bileşenlere ayrılabilir.

$$S = A^T X \quad (3.5)$$

Bu çalışmada ayırma işlemi yaparken birinci öz görüntüde kargaşa bileşeni vardır ve (3.6) ile ifade edilir. Hedef için iki farklı yaklaşım vardır. Birinci yaklaşımda hedefin ikinci öz görüntüde olduğu varsayılır ve (3.7) ile ifade edilir. İkinci yaklaşımda ise hedefin birinci öz görüntü dışında diğer öz görüntülerde olduğu varsayılmaktadır ve (3.8) ile ifade edilmektedir.

$$X_{kargaşa} = A_1^T S_1 \quad (3.6)$$

$$X_{hedef} = A_2^T S_2 \quad (3.7)$$

$$X_{hedef} = \sum_{i=2}^N A_i^T S_i \quad (3.8)$$

3.2.2 Tekil değer ayrışımı (TDA - SVD)

TDA, gerçek veya karmaşık bir matrisin çarpanlarına ayrılmasıdır. İşaret işleme, görüntü işleme ve makine öğrenmesi alanlarında bir çok problemde kullanılan bir matris ayrıştırma yöntemidir. TDA yöntemi genellikle işaret-gürültü oranını arttırmak amacıyla veri matrisini işaret ve gürültü şeklinde alt uzaylara ayırarak kullanılmaktadır. YNR verileri de içerisinde hedef ve kargaşa bileşenleri içerdiği için TDA yöntemi YNR verilerinde kargaşa gidermek için kullanılmaktadır. TDA yöntemiyle YNR verilerinde kargaşa giderme yapılırken B-tarama verisi M satır ve N sütundan oluşan matris olarak X_{ij} ($i = 1, 2, \dots, M$ ve $j = 1, 2, \dots, N$) ifade edilir ve burada i derinliği, j ise anten konumunu göstermektedir. X matrisinin TDA dönüşümü (3.9) ile ifade edilmektedir.

$$X = USV^T \quad (3.9)$$

Bu ifadede U ($M \times M$) ve V ($N \times N$) birimcil matrislerdir, $S = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_N)$ ve $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_N \geq 0$ özelliğini sağlar. U ve V matrislerinin sütunları

sırasıyla XX^T ve X^TX ifadelerinin özvektörleridir. Ayrıca U ve V matrislerinin her bir sütunu sırasıyla sol ve sağ tekil vektörler, S matrisinin köşegen elemanları ise X matrisinin tekil değerleri olarak adlandırılır. Açık bir ifadeyle, X matrisi TDA yöntemi kullanılarak (3.10, 3.11, 3.12) ile ifade edilmektedir.

$$X = \sigma_1 \begin{pmatrix} \vdots \\ u_1 \\ \vdots \end{pmatrix} (\cdots v_1^T \cdots) + \sigma_2 \begin{pmatrix} \vdots \\ u_2 \\ \vdots \end{pmatrix} (\cdots v_2^T \cdots) + \cdots + \sigma_N \begin{pmatrix} \vdots \\ u_N \\ \vdots \end{pmatrix} (\cdots v_N^T \cdots) \quad (3.10)$$

$$X = \sum_{i=1}^N \sigma_i u_i v_i^T \quad (3.11)$$

$$X = M_1 + M_2 + \dots + M_N \quad (3.12)$$

X matrisi N tane alt uzaya ayrılmıştır. M_i matrisleri X matrisinin i . öz görüntüsü olarak adlandırılır ve X ile aynı boyuttadır.

B-tarama verisi N adet alt bileşene ayrılmıştır ama gerçekte hedef, kargaşa ve gürültü bileşenlerine ayrılmak istenmektedir. Bu aşamada kargaşa, hedef ve gürültü bileşenlerinin hangi öz görüntülerde yer aldığına karar verilmesi gerekmektedir. Literatürde bu bileşenleri en doğru şekilde elde etmek için yapılan çalışmalar vardır ancak önerilen yöntemlerin performansı birbirine yakındır [13,42,43].

Bu çalışmada TDA yöntemi kullanılarak kargaşa giderme yapılırken birinci öz görüntü (3.13) kargaşa için kullanılacaktır. Hedef ise 2 farklı şekilde elde edilmektedir. İlk olarak [13] yayınında önerildiği gibi ikinci öz görüntü (3.14) kullanılarak elde edilir. İkinci yaklaşımda ise hedef birinci öz görüntü dışında tüm öz görüntüler (3.15) kullanılarak oluşturulacaktır. Kargaşa (3.13) ifadesi ile ve hedef (3.14, 3.15) denklemleri ile ifade edilmektedir.

$$X_{kargaşa} = \sigma_1 u_1 v_1^T \quad (3.13)$$

$$X_{hedef} = \sigma_2 u_2 v_2^T \quad (3.14)$$

$$X_{hedef} = \sum_{i=2}^N \sigma_i u_i v_i^T \quad (3.15)$$

3.2.3 Negatif olmayan matris ayrışımı (NMA - NMF)

Negatif Olmayan Matris Ayrışımı (NMA) yöntemi, veri matrisinde düşük-dereceli bileşenin (low-rank) çıktısı olarak alınabildiği bir yöntemdir. Bu sebeple görüntü işleme, video işleme, ses işleme gibi bir çok alanda kullanılmaktadır [64]. NMA yöntemi, YNR verilerini de ayrıştırarak kargaşa giderme yapmak için kullanılmaktadır [65]. NMA yönteminde, YNR B-tarama verisi X matrisi ile ifade edilirse, bu matris negatif olmayan W ve H matrislerinin çarpımı olarak (3.16) ile ifade edilebilir.

$$X \approx WH \quad \text{öyle ki:} \quad W, H \geq 0 \quad (3.16)$$

burada $X \in \mathbb{R}^{M \times N}$, $W \in \mathbb{R}^{M \times k}$ ve $H \in \mathbb{R}^{k \times N}$. W temel matris, H katsayı matrisi ve k matris derecesi (rank) olarak adlandırılmaktadır. Genellikle k , $k \leq \min(M, N)$ kriterini sağlayacak şekilde seçilmektedir. Denklem (3.16) optimizasyon problemi olarak yeniden formüle edilebilir.

$$W, H = \arg \min_{\{W, H \geq 0\}} D(X; W, H) \quad (3.17)$$

burada D sapma (divergence) fonksiyonu olarak adlandırılır. (3.17), veri matrisi X ile yeniden oluşturulmuş veri matrisi WH arasındaki farklılığı en aza indiren uygun bir W ve H bulmak için kullanılır. W ve H matrisleri için güncelleme kuralı Kullback-Leibler sapması kullanılarak türetilmiştir.

$$W \leftarrow W \bullet \frac{X H^T}{\mathbf{1} H^T}, \quad H \leftarrow H \bullet \frac{W^T X}{W^T \mathbf{1}} \quad (3.18)$$

(3.18)'de geçen $A \bullet B$, (A/B) ve $\mathbf{1}$ ifadeleri sırasıyla eleman bazlı çarpım, bölme ve birler matrisini göstermektedir. X matrisinin düşük dereceli bileşeni $k \leq \min(M, N)$ kriteri ile elde edilebilir. YNR verilerinde kargaşa, hedef işarete göre daha baskın olduğu için $k = 1$ için en yüksek bileşen kargaşa bileşenini vermektedir.

$$X_{kargaa} = W_{M \times 1} H_{1 \times N} \quad (3.19)$$

(3.19) denkleminde görüldüğü üzere NMA yöntemi ile sadece düşük dereceli bileşen olan kargaşa bileşeni elde edilir. Hedef bileşeni, kargaşa bileşeni elde edildikten sonra kargaşa bileşeninin ham YNR verisinden çıkarılmasıyla elde edilir.

$$X_{hedef} = X - X_{kargaa} \quad (3.20)$$

3.3 Düşük Dereceli ve Seyrek Ayırıştırma Yöntemleri

Düşük Dereceli ve Seyrek Ayırıştırma (DDSA, Low-Rank and Sparse Decomposition (LRSD)) yöntemleri son yıllarda görüntü işleme alanında yaygın olarak bir çok probleme uygulanmıştır. Bu yaklaşım içerisinde yer alan Gürbüz Temel Bileşen Analizi (GTBA, Robust PCA) ve Gürbüz Negatif Olmayan Matris Ayırışımı (GNMA, Robust NMF) yöntemleri de YNR verilerinde kargaşa gidermek için kullanılmaktadır. Bu yöntemler veriyi eş zamanlı olarak düşük dereceli ve seyrek olarak ayırıştırmaktadırlar. YNR verilerinde düşük dereceli bileşen kargaşa bileşeni, seyrek bileşen ise hedef bileşeni olarak kabul edilmektedir.

3.3.1 Gürbüz temel bileşen analizi (GTBA - RPCA)

Günümüzde veri analizindeki temel problemlerden biri yüksek boyutlu verinin esas düşük boyutlu yapısını çıkarmaktır. Farklı koşullar altında düşük-dereceli bileşen (low-rank) veya seyrek (sparse) bileşen ilgilenilen nesne olabilir. Matematiksel olarak ölçülen veri matrisi D (3.21)'de belirtildiği gibi formülize edilebilir.

$$D = L + S + N \quad (3.21)$$

Burada L , düşük-dereceli matris; S seyrek matris ve N gürültü bileşenini ifade etmektedir. Gürültü bileşeninin Frobenius normu $\gamma > 0$ için $\|N\|_F \leq \gamma$ şartını sağladığı varsayılır. D matrisi, aşağıdaki konvex optimizasyon formülü ile (3.22) bileşenlerine ayrılabilir.

$$\min_{\{L,S\}} \|L\|_* + \lambda \|S\|_1 \quad \text{öyle ki:} \quad \|D - L - S\|_F \leq \gamma \quad (3.22)$$

Burada $\|\cdot\|_*$ tekil değerlerin toplamını ifade eden nükleer normdur. $\|\cdot\|_1$ ifadesi l_1 normunu göstermektedir. Norm ifadeleri hakkında detaylı bilgi Ek A'da yer almaktadır. λ hassas ayar parametresidir [57]. YNR verilerinde düşük dereceli bileşen (low-rank) kargaşa, seyrek (sparse) bileşen hedef olarak kabul edilmektedir ve Gürbüz TBA yöntemi hedefi içeren seyrek bileşeni elde etmek için uygulanmaktadır. [57] yayınında (3.22) denklemini direk çözmek yerine (3.23) denkleminde verilen (3.22) denkleminin rahatlatılmış versiyonu çözülmüştür.

$$\min_{\{L,S\}} \|L\|_* + \lambda \|S\|_1 + \frac{1}{2\mu} \|D - L - S\|_F^2 \quad (3.23)$$

(3.23) denklemini çözmek için Hızlı Yinelemeli Küçülme-Eşiği Algoritması (HYKA, Fast Iterative Shrinkage-Thresholding Algorithm, FISTA) kullanılmıştır [58].

3.3.2 Gürbüz negatif olmayan matris ayrışımı (GNMA - RNMF)

NMA yönteminde sadece düşük dereceli bileşen elde edilmektedir. Gürbüz Negatif Olmayan Matris Ayrışımı (GNMA) yönteminde X veri matrisi eş zamanlı olarak hem düşük dereceli matrise hem de seyrek (sparse) bileşene (S) ayrıştırılmaktadır. Düşük dereceli bileşen NMA yönteminde olduğu gibi negatif olmayan W ve H matrislerinin çarpımı şeklinde ifade edilir. Bu durumda X veri matrisi (3.24) denklemi ile bileşenlerine ayrıştırılır.

$$X \approx WH + S \quad (3.24)$$

burada $X \in \mathbb{R}^{M \times N}$, $W \in \mathbb{R}^{M \times k}$ ve $H \in \mathbb{R}^{k \times N}$, $S \in \mathbb{R}^{M \times N}$ ve k NMA yöntemindeki ayrıştırma derecesidir. GNMA yönteminde optimizasyon problemi (3.25) ile yeniden formüle edilir.

$$\min_{\{W, H, S\}} \|X - WH - S\|_F^2 + \lambda \|S\|_1 \quad \text{öyle ki: } W, H \geq 0 \quad (3.25)$$

burada $\|S\|_1 = \sum_{i=1}^m \sum_{j=1}^n |S_{ij}|$ ve $\lambda \geq 0$. λ düzenleme parametresidir ve YNR verilerini ayrıştırırken kritik öneme sahiptir [67]. Uygun W ve H matrisleri bulmak için W ve H matrisleri (3.26) ve (3.27) formülleri ile güncellenir.

$$W_{ij} \leftarrow \left[\frac{|((S - X)H_T)_{ij}| - ((S - X)H_T)_{ij}}{2(WHH^T)_{ij}} \right] W_{ij} \quad (3.26)$$

$$H_{ij} \leftarrow \left[\frac{|(W_T(S - X))_{ij}| - (W_T(S - X))_{ij}}{2(W^TWH)_{ij}} \right] H_{ij} \quad (3.27)$$

burada W ve H (3.28) ve (3.29) formülleri ile normalize edilir.

$$W_{ij} \leftarrow \frac{W_{ij}}{\sqrt{\sum_{k=1}^n W_{kj}^2}} \quad (3.28)$$

$$H_{ij} \leftarrow H_{ij} \sqrt{\sum_{k=1}^n W_{ki}^2} \quad (3.29)$$

S için güncelleme adımı (3.30) denkleminde verilmiştir.

$$S \leftarrow T_{\frac{\lambda}{2}}(X - WH) \quad (3.30)$$

(3.30) denkleminde göre eğer $\frac{\lambda}{2} > \max_{ij}(X - WH)_{ij}$ olursa, S matrisinin tüm elemanları sıfıra eşit olur. Yüksek λ değerleri için GNMA yöntemi, klasik NMA yöntemine eşdeğer olmaktadır. GTBA yönteminde olduğu gibi YNR verilerinde kargaşa düşük dereceli bileşen, hedef ise seyrek bileşen olarak ifade edilmektedir.

$$X_{kargaa} = WH \quad (3.31)$$

$$X_{hedef} = S \quad (3.32)$$

λ değeri ham verinin düşük dereceli bileşen ve seyrek bileşen olarak ayrıştırılmasında doğrudan etkilidir. λ değeri azaltıldığında ham veriye ait daha çok bilgi seyrek bileşen olarak ayrıştırılmaktadır. Burada kritik bir eşik vardır ve bu eşik altında kargaşa ve gürültü de seyrek bileşen olarak ayrıştırılabilmektedir.

4. ÖNERİLEN MORFOLOJİK BİLEŞEN ANALİZİ YÖNTEMİ İLE YNR VERİLERİNDE KARGAŞA GİDERME

Morfolojik Bileşen Analizi (MBA, Morphological Component Analysis (MCA)), içerisinde farklı biçimsel özelliklere sahip birden fazla bileşen içeren ve bu bileşenlerin iç içe olduğu görüntüleri içerisinde yer alan bileşenlerine ayırmak için önerilen bir görüntü ayrıştırma yöntemidir [4,5]. MBA ilk olarak önerildiğinde doku ve resim bileşenlerinin iç içe olduğu görüntüleri doku bileşeni ve resim bileşeni olarak alt bileşenlerine ayırtmıştır. MBA yöntemi iki boyutlu görüntüleri alt bileşenlerine ayırdığı gibi tek boyutlu örtüşmüş işaretleri de alt bileşenlerine ayırmak için kullanılmaktadır [77]. MBA yöntemi zamanla farklı alanlarda farklı problemlere çözüm olarak da kullanılmıştır. [79] yayınında görüntüdeki eksik pikselleri tamamlamak için içboyama işleminde kullanılması önerilmiştir. [78] yayınında aynı anda hem iç boyama işlemi hem de görüntü ayrıştırma işleminde MBA yöntemi kullanılmıştır. [79,80] yayınlarda Çok-kanallı MBA (ÇMBA, Multichannel MCA (MMCA)) yöntemi, [77,81] yayınlarda ise Genelleştirilmiş MBA (GMBA, Generalized MCA (GMCA)) yöntemi çok kanallı verilerde kör kaynak ayrışım probleminin çözümü için önerilmiştir. Beynin elektriksel aktivitesini ölçen ElectroEncephaloGram (EEG) işaretlerinde yapay gürültüyü gidermek ve kaynak ayrışımı yapmak için ÇMBA ve GMBA yöntemleri kullanılmıştır [82,83]. MBA yöntemi farklı versiyonları dışında orijinal haliyle zamanla bir çok farklı uygulamada kullanılmaya devam etmiştir. [89] yayınında uydu görüntülerini sınıflandırmak için, [88] yayınında mamografi görüntülerinde kitle tespiti için ön işlem olarak, [90] yayınında yüksek frekans yüzey dalga radarında gemi tespit performansını artırmak için, [87] yayınında hiperspektral görüntülerini sınıflandırmak için, [86] yayınında video görüntülerinde doku bileşenlerinin ayrıştırılması için MBA yöntemi kullanılmıştır. MBA yöntemi iteratif bir yöntemdir ve her iterasyonda eşikleme işlemi yapmaktadır. MBA yönteminin önerildiği [4,5] yayınlarda doğrusal ve üstel olmak üzere iki farklı eşikleme stratejisi kullanılmıştır, daha sonra bu eşikleme stratejilerinin istenilen sonuca


yakınsamada yavaş olduğu düşünülerek En Büyüklerin Ortalaması (EBO, Mean of Maximum (MOM)) adında adaptif bir eşikleme stratejisi önerilmiştir [85] ve diğer yöntemlerden daha hızlı bir şekilde istenilen sonuca yakınsadığı gösterilmiştir.

Seyrek işaret işleme alanında yer alan diğer yöntemler gibi MBA yönteminin de başarımı sözlüklere bağlıdır. MBA yöntemi önerildiğinde bir çok yöneme üstünlük sağlasa da zaman içinde başarımını kısıtlayan durumların önüne geçilmeye çalışılmıştır. MBA yöntemi ilk önerildiğinde sözlük olarak analitik sözlükler (dönüşümler) kullanılmaktadır ancak bu sözlüklerin veriyi temsil etme kabiliyeti bazı durumlarda kısıtlı kalmaktadır. Bu durumun önüne geçmek için MBA yöntemi içerisinde sözlük öğrenme işlemi yapılarak kısıtlı temsil kabiliyetinin artırılması ve sonuçların iyileştirilmesi amaçlanmıştır [84]. Ancak bu çalışmada sadece doku bileşeni için öğrenilen sözlük kullanılmıştır. Resim bileşeni için sabit dönüşüm kullanılmıştır. Adaptif MBA olarak adlandırılan bu yöntem ile MBA yöntemine göre daha başarılı sonuçlar elde edilmiştir. Sabit dönüşümler kullanan MBA algoritması YNR verilerinde kargaşa gidermek için [54] yayınında önerilmiştir. Bu tez kapsamında hem kargaşa hem de hedef için K-SVD sözlük öğrenme yöntemiyle [91] ayrı ayrı sözlükler öğrenilerek Dik Eşleme Takibi (DET, Orthogonal Matching Pursuit, OMP) yöntemiyle ham YNR verisi kargaşa ve hedef bileşenlerine ayrıştırılmıştır.


4.1 Morfolojik Bileşen Analizi (MBA) Yöntemi

MBA yöntemi ile doku ve resim bileşenlerinden oluşan görüntülerin alt bileşenlerine ayrıştırılması örnek olarak Şekil 4.1 ve Şekil 4.2’de gösterilmektedir [4,5]. Curvelet sözlüğü resim bileşenini elde etmek için her iki örnekte de kullanılmaktadır. Doku bileşenini elde etmek için ise örnek-1’de global Ayrık Kosinüs Dönüşümü (AKD, Discrete Cosine Transform (DCT)), örnek-2’de lokal AKD sözlüğü tercih edilmiştir.

MBA yöntemi ile görüntünün alt bileşenlerine başarılı bir şekilde ayrılması için öncelikle görüntü içerisinde yer alan alt bileşenlerin farklı karakteristik yapılar içermesi gerekmektedir. MBA yöntemi aynı karakteristik yapıdaki bileşenleri ayırt etmekte zorlanabilir. Bu şart sağlandıktan sonra MBA yönteminin başarısı kullanılacak olan sözlüklere bağlıdır. Kullanılacak olan sözlükler görüntü içerisindeki sadece bir bileşeni seyrek olarak ifade edebilmelidir. Şekil 4.3’te MBA yönteminin çalışma



Şekil 4.1 : MBA yöntemi ile görüntünün alt bileşenlerine ayrılması - 1 [4,5]. (a) Resim ve doku bileşenlerinden oluşan görüntü, (b) ayrıştırma sonrası elde edilen resim bileşeni, (c) ayrıştırma sonrası elde edilen doku bileşeni.




Şekil 4.2 : MBA yöntemi ile görüntünün alt bileşenlerine ayrılması - 2 [4,5]. (a) Resim ve doku bileşenlerinden oluşan görüntü, (b) ayrıştırma sonrası elde edilen resim bileşeni, (c) ayrıştırma sonrası elde edilen doku bileşeni.

prensibi gösterilmektedir. Burada doğrusal çizgiler ve gauss bileşeni içeren görüntü farklı karakteristik bileşenler içermektedir ve sadece bir bileşeni seyrek olarak ifade edebilecek sözlükler vardır. Gauss bileşeni için kullanılan sözlük sadece bu bileşeni seyrek olarak ifade ederken doğrusal çizgi bileşenini seyrek olarak ifade edememektedir. Aynı durum ve şart diğer bileşen olan doğrusal çizgi bileşeni ve onun için kullanılan sözlük için de geçerlidir. Böylelikle ayrıştırma işlemi başarılı bir şekilde gerçekleştirilmektedir.

MBA yöntemi, X ile ifade edilen görüntünün K tane morfolojik bileşenin (x_k) doğrusal süperpozisyonundan oluştuğu ve gürültüyle bozulduğunu varsaymaktadır (4.1).

$$X = \sum_{k=1}^K x_k + \varepsilon, \quad \sigma_{\varepsilon}^2 = \text{Var}[\varepsilon] < \infty \quad (4.1)$$



Şekil 4.3 : MBA algoritmasının farklı sözlükler ile ayrıştırma yapmasının gösterimi [6]

MBA algoritması K morfolojik bileşenden oluşan X görüntüsünü her bir bileşenin (x_k) bir sözlükle (ϕ_k) seyrek olarak ifade edilebildiğini varsayarak K ayrı bileşene ayırmayı amaçlamaktadır (4.2).

$$x_k = \phi_k \alpha_k, \quad k = 1, \dots, K \quad (4.2)$$

Burada α_k seyrek katsayı vektörüdür ve birkaç katsayısı dışında kalan katsayılar sıfırdır. MBA algoritmasının X görüntüsünü başarılı bir şekilde bileşenlerine ayırabilmesi için x_k bileşeni ϕ_k sözlüğü ile seyrek olarak ifade edilirken bir başka sözlükle ($\phi_{l, l \neq k}$) seyrek olarak ifade edilememesi gerekmektedir. Bu varsayım algoritmanın başarılı bir şekilde ayrıştırma yapmasında en önemli anahtar varsayımdır.

MBA yöntemi (4.3) ile ifade edilen optimizasyon problemini mümkün olan en seyrek çözümü bulacak şekilde çözme amaçlar.

$$\{\alpha_1^{opt}, \dots, \alpha_K^{opt}\} = \arg \min_{\{\alpha_1, \dots, \alpha_K\}} \sum_{k=1}^K \|\alpha_k\|_0 \quad \text{öyle ki:} \quad X = \sum_{k=1}^K \phi_k \alpha_k \quad (4.3)$$

Burada ifade edilen optimizasyon problemini çözmek zordur ve problemin karmaşıklığı sözlüklerin sütun sayısı ile üstel olarak artmaktadır. Temel Takip (TK, Basis Pursuit (BP)) [94] yönteminde l_0 normu yerine l_1 normunun kullanılması önerilmiştir. Norm ifadeleri hakkında detaylı bilgi Ek A'da yer almaktadır. Bu problemin çözümü için bu yaklaşım kullanılarak problem çözülebilir bir formda (4.4) ile ifade edilir [5].

$$\{\alpha_1^{opt}, \dots, \alpha_K^{opt}\} = \arg \min_{\{\alpha_1, \dots, \alpha_K\}} \sum_{k=1}^K \|\alpha_k\|_1 \quad \text{öyle ki:} \quad X = \sum_{k=1}^K \phi_k \alpha_k \quad (4.4)$$

X ile ifade edilen görüntünün tam olarak bileşenlerine ayrılması ve ayrıştırma işleminin başarılı olabilmesi için gürültü bileşeninin de probleme dahil edilmesi gerekmektedir,

aksi takdirde MBA algoritması başarılı bir şekilde ayrıştırma yapamayacaktır. Gürültünün göz önünde bulundurularak probleme dahil edilmesiyle problem (4.5) denkleminde dönüşür [5].

$$\{\alpha_1^{opt}, \dots, \alpha_K^{opt}\} = \arg \min_{\{\alpha_1, \dots, \alpha_K\}} \sum_{k=1}^K \|\alpha_k\|_1 + \lambda \|X - \sum_{k=1}^K \phi_k \alpha_k\|_2^2 \quad (4.5)$$

Bu ifadede bilinmeyenler seyrek katsayı vektörleridir. Problemin çözümünün basitleştirilmesi için problemin bilinmeyenleri morfolojik bileşenler olarak değiştirilir ve problemin son hali (4.6)'da gösterilmektedir.

$$\{x_1^{opt}, \dots, x_K^{opt}\} = \arg \min_{\{x_1, \dots, x_K\}} \sum_{k=1}^K \|\phi_k^+ x_k\|_1 + \lambda \|X - \sum_{k=1}^K x_k\|_2^2 \quad (4.6)$$

Burada ϕ_k^+ , ϕ_k sözlüğünün Moore-Penrose sözde tersidir. Bu ifadeyle birlikte problemin bilinmeyenleri seyrek katsayı vektörleri yerine morfolojik bileşenler olmuştur. MBA algoritması (4.6) ile ifade edilen optimizasyon problemini Block Coordinate Relaxation (BCR) yöntemini kullanarak iteratif olarak ve her iterasyonda eşikleme işlemi yaparak çözmektedir [55].

4.2 Analitik Sözlükler Kullanılarak MBA Yöntemiyle Kargaşa Giderme

YNR verileri Bölüm 3'te anlatıldığı gibi kargaşa, hedef ve sistem gürültüsü olmak üzere üç farklı bileşenden oluşmaktadır. Sistem gürültüsü, kargaşa kadar büyük bir sorun oluşturmadığından YNR verilerinin kargaşa ve hedef olmak üzere iki bileşenden oluştuğu düşünülebilir. MBA algoritması her bir bileşenin bir sözlükle seyrek olarak ifade edilebildiğini varsaymaktadır. Bu varsayım altında kargaşa ve hedef bileşenleri sırasıyla (4.7) ve (4.8) denklemleriyle ifade edilmektedir.

$$x_{kargaşa} = x_k = \phi_k \alpha_k \quad (4.7)$$

$$x_{hedef} = x_h = \phi_h \alpha_h \quad (4.8)$$

Burada ϕ_k kargaşa için ϕ_h ise hedef için kullanılan sözlüklerdir. α_k ve α_h sırasıyla kargaşa ve hedefe ait seyrek katsayı vektörleridir. MBA yönteminin YNR verilerindeki kargaşa giderme başarımı diğer problemlerde olduğu gibi her bir bileşen için kullanılacak sözlüklere bağlıdır. Hedef bileşenini seyrek olarak iyi bir şekilde temsil

etmesi için seçilen ϕ_h sözlüğünün diğer bileşen olan kargaşayı seyrek olarak iyi temsil etmemesi gerekir. Aynı durum kargaşa bileşenini seyrek olarak iyi bir şekilde temsil etmesi için seçilen kargaşa sözlüğü için de geçerlidir. Kargaşa sözlüğünün de hedef bileşenini seyrek olarak iyi temsil etmemesi gerekir. Yöntemin başarımı bu şartın sağlanmasına bağlıdır. (4.6) ile ifade edilen MBA denklemi kargaşa gidermek için düzenlenerek (4.9) denkleminde dönüşmektedir [55].

$$\{x_k^{opt}, x_h^{opt}\} = \arg \min_{\{x_k, x_h\}} \|\phi_k^+ x_k\|_1 + \|\phi_h^+ x_h\|_1 + \lambda \|X - x_k - x_h\|_2^2 \quad (4.9)$$

Tanımlanan optimizasyon problemi kargaşa gidermek için kullanılan MBA algoritması tarafından çözülmektedir. YNR verilerinde kargaşa gidermek için kullanılan MBA algoritması Algoritma 1’de özetlenmiştir.

Seyrek gösterim ile ifade edilen problemlerde yöntemin başarısı kullanılan sözlüğe göre değişmektedir. Gürültü giderme uygulamalarında bir adet sözlük kullanılmaktadır ancak MBA yönteminde ayrıştırılmak istenen her bir bileşen için ayrı bir sözlük kullanılmaktadır. Bu sebeple MBA yönteminin başarımı tek bir sözlüğe değil birden fazla sözlüğe bağlıdır. Literatürde analitik sözlükler ve öğrenilmiş sözlükler olmak üzere 2 farklı sözlük çeşidi vardır. Analitik sözlükler matematiksel bir ifadenin farklı parametreler için elde edilen çıktılarıyla oluşturulmaktadır. Analitik sözlükler de görüntüdeki farklı yapıları seyrek olarak ifade etmelerine göre gruplara ayrılmaktadır. Genellikle doğrusal bileşenler için ridgelet ve curvelet dönüşümleri, izotropik bileşenler için dalgacık dönüşümü (wavelet), doku bileşenler için Ayrık Kosinüs Dönüşümü (AKD, Discrete Cosine Transform, DCT), Ayrık Sinüs Dönüşümü (ASD, Discrete Sine Transform (DST)), Gabor Dönüşümü (GD), bruslets kullanılmaktadır. Analitik sözlüklerin kullanıldığı alandaki veriyi temsil etme kabiliyeti sınırlıdır ve analitik sözlükler ile seyrek olarak ifade edilemeyen bileşenler için öğrenilmiş sözlükler kullanılmaktadır. Veriye ve probleme özgü sözlükler oluşturmak için veri setinde yer alan görüntülerden yamalar elde edilmektedir. Küçük görüntü parçaları yama olarak adlandırılmaktadır. Çok sayıda yama elde edildikten sonra bu yamalar sözlük öğrenme algoritmalarına verilmektedir ve sözlük öğrenme algoritmaları aldığı çok sayıda yamayı işleyerek çıktı olarak öğrenilmiş sözlüğü vermektedir [91]. Öğrenilmiş sözlükler ile gürültü giderme yapıldığında analitik sözlükler ile elde edilen sonuçlara göre daha iyi sonuç elde edilmektedir [92]. Öğrenilmiş sözlükler

Algoritma 1 MBA Yöntemiyle YNR Verilerinde Kargaşa Giderme

Amaç: (4.9) formülünü çözerek YNR verilerinde kargaşa giderme yapmak.

Girdi:

X : YNR verisi
 ϕ_k : kargaşa sözlüğü
 ϕ_h : hedef sözlüğü
 N_{iter} : iterasyon sayısı
 λ_{min} : minimum eşik değeri

Başlangıç:

Başlangıç çözümü: $x_k^{(0)} = x_h^{(0)} = 0$.
Başlangıç kalanı: $r^{(0)} = X$
Başlangıç eşik değeri: $m^* = \max_m \|\phi_m^+ X\|_\infty$ için $\lambda^{(0)} = \max_{m \neq m^*} \|\phi_m^+ X\|_\infty$

Ana iterasyon: N_{iter} defa uygula

Kalanı hesapla, $r = X - x_k - x_h$

Kısım A: Kargaşa bileşenini (x_k) güncelle, hedef bileşeninin (x_h) değişmediğini kabul et.

Kargaşa katsayılarını hesapla, $\alpha_k = \phi_k^+(x_k + r)$
Kargaşa katsayılarının eşiklenerek güncellenmesi, $\hat{\alpha}_k$
Kargaşa bileşenini eşiklenen katsayılar ile yeniden oluşturulması, $x_k = \phi_k \hat{\alpha}_k$

Kısım B: Hedef bileşenini (x_h) güncelle, kargaşa bileşeninin (x_k) değişmediğini kabul et.

Hedef katsayılarını hesapla, $\alpha_h = \phi_h^+(x_h + r)$
Hedef katsayılarının eşiklenerek güncellenmesi, $\hat{\alpha}_h$
Hedef bileşeninin eşiklenen katsayılar ile yeniden oluşturulması, $x_h = \phi_h \hat{\alpha}_h$

Eşik değerini güncelle, λ

Eğer $\lambda \leq \lambda_{min}$, ise dur.

Çıktı:

x_k : elde edilen kargaşa bileşeni
 x_h : elde edilen hedef bileşeni


kullanılacağı veri setine daha iyi adapte olduğu için temsil kabiliyeti analitik sözlüklere göre daha iyidir ve analitik sözlüklerin temsil etmekte zorlandığı bileşenleri daha kolay ifade etmektedirler.

Seyrek gösterim ile ifade edilen bir çok problemde sözlüğün kullanılacağı alandaki veriyi seyrek olarak iyi ifade edebilmesi beklenirken MBA algoritmasında her bir bileşen için kullanılacak sözlüğün, o bileşeni seyrek olarak iyi ifade etmesinin yanında diğer bileşenleri de seyrek olarak ifade edememesi beklenmektedir. Sözlükler içerisinde birbirine benzemeyen atomlar içermelidir. MBA algoritmasının başarımı hem sözlüklerin ilgili bileşeni seyrek olarak temsil etmesine hem de diğer bileşenleri seyrek olarak ifade edememesine bağlıdır.

YNR verilerinde kargaşa gidermek amacıyla MBA algoritması kullanılmak istendiğinde hem kargaşa bileşeni için hem de hedef bileşeni için iki farklı birbirine benzemeyen atomlar içeren sözlükler gerekmektedir. MBA yönteminin başarılı bir şekilde YNR verilerinde kargaşa giderme yapması için öncelikle bu bileşenlere ait uygun sözlükler belirlenmelidir. Analitik sözlükler kullanılarak yapılan ilk çalışmada kargaşa bileşeninin doğrusal yapılar içerdiği gözlenmiştir ve buna uygun olarak curvelet dönüşümü analitik sözlük olarak seçilmiştir [54,55]. Hedef bileşeni incelendiğinde izotropik yapılar içerdiği görülmüştür ve bu bileşeni seyrek olarak temsil etmesi için dalgacık dönüşümlerinden Kesintisiz Ayırık Dalgacık Dönüşümü (KADD, Undecimated Discrete Wavelet Transform, UDWT) seçilmiştir.

4.3 Önerilen Öğrenilmiş Sözlükler Kullanılarak MBA Yöntemiyle Kargaşa Giderme

Analitik Sözlükler (AS) ile çalışan MBA yöntemi (MBA-AS), YNR görüntüsünü bir bütün halinde alarak bu görüntüyü bileşenlerine ayırırken; Öğrenilmiş Sözlükler (ÖS) ile çalışan MBA yöntemi (MBA-ÖS), YNR görüntüsünü bir bütün halinde almak yerine yama olarak adlandırılan küçük görüntü parçalarını alır ve bu küçük görüntü parçalarını bileşenlerine ayırır. YNR görüntüsünden alınan her bir yama, Dik Eşleme Takibi (DET, Orthogonal Matching Pursuit, OMP) yöntemi ve öğrenilmiş sözlükler yardımıyla bileşenlerine ayrılır ve bileşenlerine ayrılan yamalar birleştirilerek hedef ve kargaşa görüntülerini oluşturmaktadır. MBA-ÖS yöntemiyle YNR verilerinde kargaşa giderme işlemi Şekil 4.4'te gösterilmektedir.



Şekil 4.4 : MBA-ÖS yöntemiyle kargaşa giderme işlemlerinin gösterimi

Ham B-tarama verisine $X \in \mathbb{R}^{M \times N}$ ait yama seti $Y = [y_1, y_2, \dots, y_n]$ olarak tanımlanmaktadır. Burada $y_k \in \mathbb{R}^{\sqrt{m} \times \sqrt{m}} (k = 1, 2, \dots, n)$, X verisinden 1 veri miktarı kadar kaydırılarak $\sqrt{m} \times \sqrt{m}$ boyutlarında elde edilen k 'inci yamayı göstermektedir. Herhangi bir yama için hedef (h_k) ve kargaşa (k_k) bileşenlerinin, kargaşa seyrek katsayı vektörünün (α_{k_k}) ve hedef seyrek katsayı vektörünün (α_{h_k}) sırasıyla kargaşa sözlüğü (D_k) ve hedef sözlüğü (D_h) ile çarpılarak seyrek olarak elde edilebileceği varsayılmaktadır. YNR verisinden alınan her bir yama (4.10) denklemi ile ifade edilebilir.

$$y_k = k_k + h_k = D_k \cdot \alpha_{k_k} + D_h \cdot \alpha_{h_k} \quad (4.10)$$

Ayrıştırma aşamasında kargaşa sözlüğü (D_k) ve hedef sözlüğü (D_h) birleştirilerek kullanılmaktadır. (4.10) denklemi yeniden düzenlenerek (4.11) denklemindeki gibi ifade edilmektedir.

$$y_k = [D_k \mid D_h] \cdot \begin{bmatrix} \alpha_{k_k} \\ \alpha_{h_k} \end{bmatrix} = D \cdot \alpha_k \quad (4.11)$$

Burada D ardı ardına birleştirilen kargaşa ve hedef sözlüklerini, α_k ise birleştirilen seyrek katsayı vektörlerini göstermektedir.

DET algoritması 2 farklı şekilde sonlandırılmaktadır. Ya algoritma belirlenen hata oranına ulaşıncaya sonlanmaktadır ya da sabit sayıda seyrek katsayı kullanması kullanıcı

tarafından belirlenir ve bu sayıya ulaşınca algoritma sonlanmaktadır. Belirlenen hataya ulaşması algoritmanın bazı durumlarda işlem süresini uzatabileceğinden dolayı bu çalışmada kullanıcı tarafından sabit sayıda seyrek katsayı seçmesi tercih edilmiştir. Verilen yama için uygun seyrek katsayı vektörünü sabit sayıda seyrek katsayı seçerek bulan DET (4.12) denklemi ile verilmiştir.

$$\hat{\alpha}_k = \min_{\{\alpha_k\}} \|y_k - D \cdot \alpha_k\|_2^2 \quad \text{öyle ki:} \quad \|\alpha_k\|_0 \leq k_0 \quad (4.12)$$

Burada k_0 her bir ayrıştırma için izin verilen maksimum seyreklik katsayısını ifade etmektedir.

4.3.1 Dik eşleme takibi (DET, orthogonal matching pursuit, OMP) algoritması

DET algoritması iteratif bir algoritmadır. Aynı zamanda açgözlü (greedy) bir algoritmadır. Aç gözlü algoritma; problemi, global optimum bulma umuduyla her aşamada mevcut bilgilere göre en uygun (optimum) seçimi yaparak çözmeye çalışır. DET algoritmasında, sözlüğün her bir sütunu ile sinyal arasında korelasyon hesabı yapılır ve hangi sütunun en yüksek korelasyona sahip olduğu bulunur. Bu katsayı vektöründeki hangi indeksin sıfır olmayacağını gösterir. Bu adım DET algoritmasının "eşleme" adımıdır. İzin verilen maksimum seyreklik katsayısının 1'den büyük olduğu durum ($k_0 > 1$) için, bir önceki adımda sinyal ile en yüksek korelasyona sahip sözlüğün atomu sonraki adımlar için sözlükten bir daha seçilmemesi için çıkarılır. Bir atom birden fazla seçilemez, bu özellik de DET algoritmasının dik (orthogonal) özelliğidir.

DET algoritmasının uygulanmasında ihtiyaç duyulan 2 farklı kavram vardır. Bunlar katsayı vektörünün desteği ve karşılıklı tutarlılık kavramlarıdır. Katsayı vektörü için, katsayı vektöründeki sıfır olmayan elemanların tüm indekslerinin kümesine katsayı vektörünün desteği (support) denir ve $supp(x)$ olarak gösterilir. N adet vektör için $(x_1, x_2, \dots, x_N)$ karşılıklı tutarlılık, bu vektörler arasındaki normleştirilmiş korelasyonun en büyük mutlak değeridir (4.13) denklemi ile hesaplanır.

$$M = \max_{i \neq j} \frac{|\langle x_i, x_j \rangle|}{\|x_i\|_2 \|x_j\|_2} \quad (4.13)$$

Eğer sözlüğün karşılıklı tutarlılık değeri (4.14) denkleminde tanımlanan eşitsizliği sağladığı sürece seyrek katsayı vektörü α_k DET ile elde edilebilir.

$$M < \frac{1}{2k_0 - 1} \quad (4.14)$$

DET algoritmasının adımları Algoritma 2’de anlatılmaktadır.

Algoritma 2 Dik Eşleme Takibi (DET, Orthogonal Matching Pursuit, OMP) Algoritması

Amaç: (4.12) formülünde tanımlanan problemin yaklaşık çözümü

Girdi:

D : Sözlük

y : Yama

Çıktı:

$\hat{\alpha}$: seyrek katsayı vektörü

Başlangıç:

Kalanın başlangıç değeri : $r_0 = y$

Sözlükten seçilen atomları indekslerinin tutulduğu vektörün başlangıç değeri :
 $supp_0 = \emptyset$

Ana iterasyon:

for i = 1,2,...,k₀ **do**

Adım-1: Sözlükten atom seçme : $\lambda_i = \arg \max_{j \notin supp_{i-1}} |\langle d_j, r_{i-1} \rangle|$

Adım-2: Seçilen indeksleri destek vektörüne ekleme : $supp_i = supp_{i-1} \cup \{\lambda_i\}$

Adım-3: Seyrek katsayının kestirilmesi : $\alpha_i(k \in supp_i) = \arg \min_{\alpha} \|D_{supp_i} \alpha - y\|_2$, $\alpha_i(k \notin supp_i) = 0$

Adım-4: Kalanın güncellenmesi : $r_i = y - D\alpha_i$

end for

4.3.2 Kargaşa ve hedef bileşenleri için sözlük öğrenme

YNR verisinden alınan her bir yamanın (4.12) denklemi ile bileşenlerine ayrılabilmesi için sözlüklerin biliniyor olması gerekmektedir. Bahsedilen öğrenilmiş sözlükler, YNR verisinden elde edilen çok sayıda yamanın K-SVD [91] algoritmasında işlenmesiyle elde edilebilir. Kargaşa ve hedef sözlükleri ayrı ayrı öğrenilmelidir. YNR verisinden alınan yamanın başarılı bir şekilde bileşenlerine ayrılabilmesi için bu 2 sözlük mümkün olduğunca birbirinden ayrık olmalıdır ve sadece ilgili bileşeni seyrek olarak ifade edebilmelidir.

K-SVD verilerden sözlük öğrenmek için yaygın olarak kullanılan bir yöntemdir. K-SVD, verilerin mümkün olan en seyrek gösterimini bularak sözlükteki atomları öğrenen iteratif bir yöntemdir. K-SVD yöntemi ile iyi bir öğrenilmiş sözlük elde edebilmek için çok sayıda veri gerekmektedir.

Sözlük öğrenmek için öncelikle veri matrisi hazırlamak gerekir. Veri matrisinin her bir sütununda bir işaret yer almaktadır. N adet işareten oluşan veri matrisi, $Y \in \mathbb{R}^{K \times N}$, $Y = \{y_i\}_{i=1}^N$ olarak ifade edilir. Matristeki işaret sayısının (N) işaretin boyutundan (K) oldukça büyük olduğu varsayılır ($N \gg K$). K-SVD algoritması, (4.15) ile ifade edilen optimizasyon problemini çözerek en iyi sözlüğü (D) ve seyrek gösterimi (X) bulmayı hedefler.

$$\min_{\{D, X\}} \|Y - DX\|_F^2 \quad \text{öyle ki:} \quad \forall i, \|x_i\|_0 \leq T_0 \quad (4.15)$$

Burada T_0 her bir ayrıştırma için izin verilen maksimum seyreklik katsayısını ifade etmektedir. (4.15) denklemi ile verilen ifade iteratif olarak minimize edilmektedir. K-SVD algoritması seyrek kodlama ve sözlük güncelleme olmak üzere 2 ana bölümden oluşmaktadır. Seyrek kodlama aşamasında sözlüğün sabit olduğu varsayılarak seyrek gösterim bulunur. Seyrek gösterim için DET gibi açgözlü algoritmalar kullanılabilir. Orjinal K-SVD algoritmasında DET algoritması kullanılmaktadır. (4.15) denklemi ile verilen ifade, (4.16) denkleminde olduğu gibi N farklı probleme ayrıştırılabilir

$$\min_{\{x_i\}} \|y_i - Dx_i\|_2^2 \quad \text{öyle ki:} \quad \|x_i\|_0 \leq T_0 \quad i = 1, 2, \dots, N \quad (4.16)$$

Sözlük güncelleme aşamasında her adımda sözlüğün bir atomu güncellenmektedir. Bunun için bir atom dışında diğer tüm atomlar sabit tutulmaktadır. Sözlük güncelleme aşaması için (4.15) denklemindeki ceza terimi (4.17) denkleminde olduğu gibi yeniden yazılır.

$$\begin{aligned} \|Y - DX\|_F^2 &= \|Y - \sum_{j=1}^K d_j x_T^j\|_F^2 \\ &= \|(Y - \sum_{j \neq k} d_j x_T^j) - d_k x_T^k\|_F^2 \\ &= \|E_k - d_k x_T^k\|_F^2 \end{aligned} \quad (4.17)$$

Burada x_T^k ifadesi X matrisinin k. satırını ifade etmektedir. d_k ise sözlüğün k. sütununu ifade etmektedir. E_k matrisi ise k atomu dışarda bırakıldığında N adet örnek için hatayı temsil eder. Sözlüğün k. atomunu kullanan (d_k) örneklerin (y_i) indekslerini tutan değişken w_k (4.18) denkleminde tanımlanmıştır.

$$w_k = \{i \mid 1 \leq i \leq K, x_T^k(i) \neq 0\} \quad (4.18)$$

K-SVD algoritmasının adımları Algoritma 3'te anlatılmaktadır.

Algoritma 3 K-SVD Algoritması

Amaç: (4.15) formülünde tanımlanan problemi çözerek en iyi sözlüğü bulmak

Girdi:

$Y = \{y_i\}_{i=1}^N$: Veri seti

T_0 : İzin verilen maksimum seyreklik katsayısı

M : İterasyon sayısı

Çıktı:

D : Öğrenilen sözlük

X : Seyrek gösterim

Başlangıç:

Başlangıç sözlüğünün $D^{(0)}$ Y 'den rastgele seçilen örneklerle başlatılması

Sözlüğün atomlarının normalize edilmesi

Ana iterasyon:

for $j = 1, 2, \dots, M$ **do**

Seyrek Kodlama Aşaması

$$\min_{\{x_i\}} \|y_i - Dx_i\|_2^2 \quad \text{öyle ki:} \quad \|x_i\|_0 \leq T_0 \quad i = 1, 2, \dots, N$$

Sözlük Güncelleme Aşaması : Sözlükteki her bir sütun için gerçekleştirilir

(a) Bu atomu kullanan örneklerin tanımlanması : $w_k = \{i \mid 1 \leq i \leq N, x_T^k(i) \neq 0\}$


(b) Genel gösterim hata matrisinin hesaplanması : $E_k = Y - \sum_{j \neq k} d_j x_T^j$

(c) w_k da belirlenen indekslere karşı düşen sütunların E_k matrisinden seçilerek E_k^R matrisinin elde edilmesi

(d) SVD ayrıştırmasının uygulanması. $E_k^R = U \Delta V^T$. U matrisinin ilk sütunu sözlüğün k . atomunu (d_k) vermektedir. V matrisinin ilk sütununun $\Delta(1,1)$ ile çarpımından katsayı vektörü (x_R^k) elde edilir.

end for


Kargaşa sözlüğü elde etmek için veri setinde bulunan hedef içermeyen arkaplan verilerinden elde edilen yamalar kullanılmıştır. Veri setinde 7 farklı toprak tipi ve 4 farklı senaryo olduğu için toplam 28 tane arkaplan verisi vardır. Öncelikle, 28 tane arkaplan verisinden $\sqrt{mx}\sqrt{m}$ boyutlarında yamalar örtüşme olmadan elde edilmiştir. Elde edilen yamalar daha sonra $mx1$ boyutunda vektöre dönüştürülmektedir ve bu vektöre dönüştürülen her bir yama bir matrisin sütunlarına sırasıyla yerleştirilmektedir.



Şekil 4.5 : K-SVD algoritması için veri hazırlama işlemleri

K tane yamadan elde edilen matris K-SVD algoritmasına girdi olarak verilmektedir. Yapılan işlemler Şekil 4.5'te gösterilmektedir.

Hedef sözlüğü elde etmek için yapılan işlemler kargaşa sözlüğü için yapılan işlemlere benzese de yamaların sadece hedef içeren bölgelerden alınması için B-tarama verisi içerisinde hedefin olduğu bölgenin belirlenmesi gerekmektedir. Veri setinde bulunan B-tarama verileri 256×80 boyutundadır ve hedefe ait veriler bu boyuttan çok daha küçüktür. B-tarama verilerinde gereksiz bölgelerden kurtularak sadece hedef imzasının olduğu yeri seçmek için hedefin yatay ve dikey eksenindeki konumlarının bilinmesi gerekmektedir. Veri setinde bulunan her bir veri elde edilirken; hedef, her zaman yatay eksen doğrultunun (antenin ilerleme doğrultusu) merkezine gömüldüğü için hedefin yatay eksenindeki konumu bilinmektedir ve bu konum 40. A-tarama işaretine denk gelmektedir. Hem hedef farklı derinliklere gömüldüğü için hem de toprak tipine göre hedeften geri dönen dalga'nın mesafesi değiştiği için hedefin dikey eksenindeki konumu bilinmemektedir ama yapılacak olan bir kaç işlem ile bu konum yaklaşık olarak kestirilebilir. Hedefin dikey eksenindeki konumunu kestirebilmek için öncelikle 40. A-tarama işaretinin filtrelenmiş enerji değerleri hesaplanır. Daha sonra en yüksek enerji değerine sahip 2 tepe noktasından yeryüzüne yakın olan tepe noktası hedefin



Şekil 4.6 : Hedef imza çıkarma işlemi


dikey eksen konumu olarak belirlenir. Hedefin, hem yatay hem de dikey eksenindeki konumu belirlendikten sonra 80x32 boyutunda pencere kullanılarak hedefe ait bölge elde edilir. Yapılan bu işlemler hedef imza çıkarma işlemi olarak adlandırılmaktadır. Yapılan işlemler Şekil 4.6'da gösterilmektedir.

Hedef imza çıkarma işlemi veri setinde yer alan 336 tane referans veriye uygulandıktan sonra bu hedef imzalarından yama çıkarma, yamaları vektöre dönüştürme ve K-SVD algoritması için eğitim matrisi oluşturma işlemleri gerçekleştirilir. Sözlükler eğitilirken başlangıç sözlüğü olarak AKD kullanılmıştır.




5. ÖNERİLEN EVRİŞİMSEL OTOKODLAYICILAR İLE YNR VERİLERİNDE KARGAŞA GİDERME

Otomatik kodlama; bir insan tarafından tasarlanmak yerine örneklerden otomatik olarak öğrenilen, kayıplı ve verilere özgü bir veri sıkıştırma algoritmasıdır. Otokodlayıcı teriminin kullanıldığı hemen hemen her yerde sıkıştırma (compression) ve çözümleme (decompression) fonksiyonları yapay sinir ağları ile gerçekleştirilmektedir. Otokodlayıcılar gözetimsiz (unsupervised) öğrenme yöntemidir ve gösterim verilerden otomatik olarak öğrenildiğinden dolayı öğrenilen gösterim o veriye özgüdür. Otokodlayıcıları uygulamak için kodlayıcı (encoding) fonksiyon, kod çözücü (decoding) fonksiyon ve girdiler ile çıktılar arasındaki kaybı hesap edebilmek için kayıp fonksiyonu olmak üzere 3 fonksiyona ihtiyaç vardır. Kodlayıcı ve kod çözücü fonksiyonlar kayıp fonksiyonunda kullanılan mesafe fonksiyonuna göre türevi alınabilen Yapay Sinir Ağları (YSA) gibi parametrik fonksiyonlardır. Böylece kodlayıcı ve kod çözücü fonksiyonlar Rastgele Gradyan İnişi (RGİ, Stochastic Gradient Descent (SGD)) ile yeniden oluşturma (reconstruction) kaybını minimuma indirecek şekilde optimize edilebilirler. Otokodlayıcı akış diyagramı Şekil 5.1’de gösterilmiştir. Kodlayıcı bloğuna verilen girdi ile kod çözücü bloğunun çıktısı olan yeniden oluşturulan verinin boyutları aynıdır.



Şekil 5.1 : Otokodlayıcı akış diyagramı

Günümüzde uzaktan algılama alanında görüntü işleme; sınıflandırma, anomali tespiti, füzyon, süper çözünürlük, gürültü azaltma, iç-boyama gibi birçok uygulamada makine öğrenmesi ve özellikle derin öğrenme kullanılmaktadır [99]. YNR verilerinde hedef tespiti veya sınıflandırması için çok sayıda makine öğrenmesi veya Evrışimsel Yapay Sinir Ağları (EYSA, Convolutional Neural Networks, CNN) kullanan çalışma yapılmıştır [96,97,100]–[111]. Otomatik kodlayıcı, denetimsiz öğrenme görevleri için kullanılan tipik bir sinir ağıdır ve Yığılan Otomatik Kodlayıcılar (YOK, Stacked Autoencoder, SAE), çok katmanlı kodlayıcılar ve kod çözücüler içeren bir tür derin sinir ağı olarak düşünülebilir [112]. Otomatik kodlayıcılar, veri boyutu indirgeme [113], gürültü giderme [112], öznitelik çıkarma [114], duvar arkası görüntüleme bozucu etkileri azaltma [115,116], YNR verilerinde anomali tespiti [117], multispektral görüntü füzyonu [118], kargaşa bastırma [119], Sentetik Açıklıklı Radarda (SAR) görüntü sınıflandırma [120], Hiperspektral görüntü sınıflandırma [121] gibi birçok alanda kullanılmıştır. Otomatik kodlayıcılar, tüm bu uygulamalarda ağa girdi olarak verilen veri, ağ yapısı ve ağı eğitilmesi açısından farklı şekilde kullanılmaktadır. Duvar arkası görüntüleme uygulamasında, [115] yayınında görüntülere gürültü giderici (denosing) otokodlayıcı uygulanırken, [116] yayınında otokodlayıcı kargaşa giderme yapılan verilere uygulanmaktadır. [117] yayınında YNR görüntüsü yamalara bölünmüştür ve Evrışimsel Otokodlayıcı (EOK) ile hedef içermeyen yamalar ile anomali tespiti için eğitilmiştir. Hedef olmayan konumlar EOK ile başarılı bir şekilde modellenirken, hedef olan konumlarda hata yüksek olacaktır. Böylece hedefler bu hesaplanan hata kullanılarak kolayca tespit edilebilir. Görüntü keskinleştirme (pansharpening) uygulamalarında EOK düşük çözünürlüklü multispektral görüntüleri alır ve yüksek çözünürlüklü multispektral görüntüler üretir [118]. [119] yayınında YNR görüntülerinde kargaşa gidermek için GTBA yöntemi yerine düşük dereceli ve seyrek matris gösterim problemini çözmek için Gürbüz Otokodlayıcı (GOK) yöntemi önerilmiştir. GTBA yöntemi doğrusal bir çözüm sunarken, otokodlayıcının doğrusal olmayan gösterim kabiliyetinden yararlanılmıştır. [120] yayınında EOK farklı bir şekilde uygulanmıştır. Görüntüler, doku öznitelikleri çıkarmak için Gabor filtreleriyle evrışim işlemine tabi tutulur ve otokodlayıcıya bu çıkartılan öznitelikler girdi olarak verilir. Evrışim katmanı ve otokodlayıcı



Şekil 5.2 : Tamamen bağlı basit YSA otokodlayıcı mimarisi

birbiri ardına uygulanır. [121] yayınında otokodlayıcılar, etiketlenmemiş hiperspektral görüntülerden öznetelik çıkarmak için kendi kendine öğrenilen bir öğrenme yöntemi olarak kullanılır.

Bu doktora çalışmasında EOK yönteminin YNR verilerinde kargaşa gidermek için kullanılması önerilmiştir. Önerilen yaklaşım, 2-boyutlu YNR verilerindeki kargaşayı gidermek için EOK yöntemini kullanan literatürdeki ilk çalışmadır. Önerilen yöntem, hem hedef hem de kargaşa bileşenlerini içeren ham YNR görüntülerindeki kargaşanın nasıl giderileceğini öğrenmektedir. Önerilen model, benzetim programı ile elde edilen veri seti ile eğitilmektedir ve kayıp hesabı aşamasında referans verilere ihtiyaç duymaktadır. Sonuç olarak, algoritma girdi olarak aldığı hem kargaşa hem de hedef bileşenlerinden oluşan YNR verilerini yalnızca hedef içeren referans verilere benzetmeye çalışır. Daha güçlü bir model eğitebilmek için benzetim modeli ile oluşturulan veri seti, veri çoğaltma teknikleri uygulanarak çoğaltılmıştır ve uygun parametre seçenekleri araştırılmıştır. Önerilen yöntemin başarımı gerçek YNR sisteminden alınan veriler üzerinden de gösterilmiştir [98].

5.1 Otokodlayıcılar ile YNR Verilerinde Kargaşa Giderme

İlk olarak kodlayıcı ve kod çözücü için tamamen bağlı basit bir YSA kullanılmıştır. Kullanılan yapı Şekil 5.2’de gösterilmektedir. Kodlayıcı girdi olarak $x \in \mathbb{R}^d$ verisini almaktadır ve bu girdiyi sıkıştırılmış gösterime h dönüştürmektedir.

$$h = \phi_1(W_1x + b_1) \quad (5.1)$$

Burada ϕ_1 sigmoid veya Doğrultulmuş Doğrusal Birim (DDB, Rectified Linear Unit (RELU)) gibi aktivasyon fonksiyonudur. h , girdi x verisinin sıkıştırılmış gösterimi olarak adlandırılır. W_1 ağırlık matrisi, b_1 ise sapma (bias) vektörüdür. Kod çözücü ise girdi olarak sıkıştırılmış gösterimi (h) alır ve girdinin yeniden oluşturulan versiyonuna (y) çıktı olarak dönüştürür (5.2).

$$y = \phi_2(W_2h + b_2) \quad (5.2)$$

Burada ϕ_2 , W_2 ve b_2 sırasıyla kod çözücüye ait aktivasyon fonksiyonu, ağırlık matrisi ve sapma vektörüdür. Ağırlık matrisleri ve sapma vektörleri başlangıçta rastgele sayılarla başlatılırlar ve eğitim sırasında her bir iterasyonda güncellenmektedirler. Otokodlayıcılar yeniden oluşturma hatasını minimize etmeyi hedeflerler ve girdi-çıkı arasındaki benzerliği ölçebilmek için kayıp fonksiyonuna ihtiyaç duyarlar [112]. Ortalama Kare Hatası (OKH, Mean Squared Error, MSE) kayıp fonksiyonu olarak kullanılabilir (5.3).

$$\|e\|_2^2 = \|x - y\|_2^2 = \|x - \phi_2(W_2(\phi_1(W_1x + b_1)) + b_2)\|_2^2 \quad (5.3)$$

Burada amaç yeniden oluşturma hatasını minimize eden ağırlık matrislerini (W_1, W_2) ve sapma vektörlerini (b_1, b_2) öğrenmektir.

Veri setinde yer alan YNR verileri 256x80 boyutundadır. Eğitim aşamasında 336 adet orijinal veri hiç kullanılmamıştır. Bunun yerine veri çoğaltma yöntemi ile elde edilen 3360 adet verinin %90’ı eğitim verisi, %10’u eğitim aşamasında doğrulama (validation) verisi olarak kullanılmıştır. Eğitilen modelin performansı orijinal veri seti üzerinden test edilmiştir. Tamamen bağlı basit YSA ağ mimarisine YNR görüntüleri


Çizelge 5.1 : Tamamen bağlı tek katmanlı YSA otokodlayıcı sonuçları

Sıkıştırılan Veri Boyutu	Ortalama TİGO (dB)
32	37.64
64	38.80
128	39.53
256	38.47
512	39.43
1024	39.64

2 boyutlu değil, tek boyutlu dizi olarak verilmektedir. Elde edilen çıktı da tek boyutlu dizi olmaktadır. Veri daha sonra 256x80 boyutlarına dönüştürülmektedir. Kayıp hesabı için OKH fonksiyonu kullanılmıştır. Eğitim aşamasında adaptif öğrenme oranı kullanan Adadelta algoritması kullanılmıştır [122]. Grup boyutu (batch size) 16, devir sayısı 100 olarak seçilmiştir. Farklı sıkıştırma oranları ile elde edilen modeller 336 adet orijinal veriden oluşan veri seti üzerinde test edilerek her bir veri için TİGO hesabı yapılmıştır. Daha sonra tüm veri seti için hesaplanan TİGO değerlerinin ortalaması alınarak Çizelge 5.1’de gösterilmektedir.

Çizelge 5.1’de yer alan sonuçlar incelendiğinde tamamen bağlı tek katmanlı YSA otokodlayıcı ile yapılan kargaşa giderme sonuçları başarısızlıkla sonuçlanmıştır. Tek katmanlı otokodlayıcı ile YNR görüntülerinde kargaşa giderme yapılamamaktadır.

Tamamen bağlı tek katmanlı YSA ile kargaşa giderme işlemi başarısız olduktan sonra katman sayısı artırılarak her katmandaki sıkıştırma oranlarında farklı değerler kullanılarak model eğitme işlemi gerçekleştirilmiştir. Bu ağ modelinde de tek katmanlı yapıda kullanılan üst değişkenler (hyperparameter) kullanılmıştır. Kullanılan otokodlayıcı ağ mimarisi Şekil 5.3’te gösterilmektedir. Elde edilen modellerin test veri seti ile test edilmesi sonucunda hesaplanan ortalama TİGO değerleri Çizelge 5.2’de gösterilmektedir. Otokodlayıcı mimari modeli için daha büyük bir ağ kullanılmasına rağmen YNR görüntülerinde kargaşa gidermek için uygun değildir.




Şekil 5.3 : Tamamen bağlı derin YSA otokodlayıcı mimarisi

Çizelge 5.2 : Tamamen bağlı üç katmanlı YSA otokodlayıcı sonuçları

Sıkıştırılan Veri Boyutu			Ortalama TİGO (dB)
Katman-1	Katman-2	Katman-3	
64	32	16	40.45
128	64	32	39.79
256	128	64	39.68
512	256	128	39.57
1024	512	256	39.38

5.2 Evrişimsel Otokodlayıcılar ile YNR Verilerinde Kargaşa Giderme

YNR görüntüleri 2 boyutlu olduğu için otokodlayıcı ağ mimarisinde kodlayıcı ve kod çözücü olarak evrişimsel YSA kullanılabilir. Genelde görüntülerde Evrişimsel Otokodlayıcılar (EOK, Convolutional Autoencoders, CAE) kullanılmaktadır ve daha iyi performans göstermektedirler. Model eğitimi sırasında referans veri ile yeniden oluşturulan veri arasında kayıp fonksiyonunda ortalama kare hatası hesaplanacaktır. Otokodlayıcı, ortalama kare hatasını azaltacak ve girdileri referans veriye benzetecek şekilde eğitilecektir. EOK yönteminin YNR görüntülerinde kargaşa gidermek için kullanılması Şekil 5.4’te gösterilmiştir. Önerilen EOK ağ mimarisine B-tarama olarak



Şekil 5.4 : Evrimsel Otokodlayıcılar ile kargaşa giderme modeli

adlandırılan 2-boyutlu YNR verisi girdi olarak verilmektedir. B-tarama verisi X_{ij} olarak ifade edildiğinde ($i = 1, 2, \dots, M; j = 1, 2, \dots, N$ i derinlik indeksini, j ise anten pozisyonunu (ilerleme doğrultusunu) ifade etmektedir. B-tarama verisi (X), kargaşa (X_k) ve hedef (X_h) bileşenlerinden oluşmaktadır ve (5.4) ile ifade edilmektedir.

$$X = X_k + X_h \quad (5.4)$$

EOK, B-tarama verisinden kargaşa bileşenini yok etmek ve sadece hedef bileşenini içeren veri elde etmek için önerilmiştir. Önerilen model; girdi olarak verilen ham B-tarama verisini, girdi olarak verilen kargaşa içermeyen referans verilere benzetmeye çalışmaktadır. Böylelikle önerilen model kargaşayı nasıl yok edeceğini öğrenmektedir.

Önerilen model, kodlayıcı ve kod çözücü aşamalarından oluşmaktadır. Kodlayıcı ham B-tarama verisini $X \in \mathbb{R}^{M \times N}$ girdi olarak alır ve boyutları $F_1 \times F_1$ olan K adet filtre ($W_1^1, W_1^2, \dots, W_1^K$) ile evrişim işlemine tabi tutar. Bu filtreler V_1 ($V_1 \in \mathbb{R}^{F_1 \times F_1 \times K}$) olarak ifade edilebilir. Aktivasyon fonksiyonundan geçirildikten sonra kodlanmış gösterim ($H \in \mathbb{R}^{M \times N \times K}$) (5.5) ile elde edilmektedir.

$$H = \phi_1(X * V_1 + b_1) \quad (5.5)$$

burada, $*$ 2-boyutlu evrişim işlemi, b_1 sapma parametresini ifade etmektedir. Evrişim işleminde sıfır ekleme uygulanmıştır ve kaydırma adımı 1 olarak seçilmiştir. Elde

edilen kodlanmış veri, kod çözücü aşamasına girdi olarak verilmektedir. Kod çözücü aşamasında, kodlanmış veri $F_2 \times F_2$ boyutlarında L adet filtre ($W_2^1, W_2^2, \dots, W_2^L$) ile evrişim işlemine tabi tutulur. Bu aşamada kullanılan filtreler V_2 ($V_2 \in \mathbb{R}^{F_2 \times F_2 \times L}$) olarak ifade edilmektedir. Kod çözücü çıktı olarak yeniden oluşturulan ($X_h \in \mathbb{R}^{M \times N}$) veriyi (5.6) formülü ile vermektedir.

$$X_h = \phi_2(H * V_2 + b_2) \quad (5.6)$$

Yeniden oluşturulan veri, kargaşa bileşeni içermeyen hedef veri olarak adlandırılabilir. Kayıp fonksiyonu yeniden oluşturulan veri ile referans veri ($Z \in \mathbb{R}^{M \times N}$) arasındaki benzerliği ölçmektedir. OKH, kayıp fonksiyonu olarak kullanılır ve (5.7) ile gösterilmektedir.

$$OKH(Z, X_h) = \frac{1}{M \times N} \|Z - X_h\|_2^2 \quad (5.7)$$

Amaç fonksiyonu; (5.7) formülüne, (5.5) ve (5.6) formülleri yerleştirilerek yeniden yazıldığında

$$J(V_1, V_2) = \min_{V_1, V_2} \frac{1}{M \times N} \|Z - \phi_2(\phi_1(x - V_1) * V_2)\|_2^2 \quad (5.8)$$

olarak elde edilmektedir. İfadeyi sadeleştirmek için sapma parametreleri denklemden çıkarılmıştır. Amaç fonksiyonunu en aza indirmek için optimum filtre katsayıları (V_1, V_2) gradyan inişi (gradient descent) kullanılarak model eğitimi ile elde edilir. Önerilen otokodlayıcı tabanlı kargaşa giderme yöntemi Algoritma 4'te özetlenmiştir.

5.2.1 Önerilen EOK ağ mimarisinde parametre seçimi

Kodlayıcı ve kod çözücü yapılarından oluşan önerilen EOK ağ mimarisi Şekil 5.5'te gösterilmektedir. Kodlayıcı bloğu evrişim (Conv-n) ve örnekleme (pooling-n) katmanlarından oluşmaktadır. Aktivasyon fonksiyonu evrişim katmanından sonra uygulanmaktadır. Kod çözücü blok ise evrişim ve üst örnekleme (Up sampling-n) katmanlarından oluşmaktadır. Gösterilen ağ mimarisinde bazı değerler parametrik olarak yazılmıştır. Bu parametrelerin optimum değerini bulmak için farklı sayısal değerler kullanılarak ağ mimarisinin kargaşa giderme performansı hesaplanacaktır. Böylelikle en yüksek performansı veren parametreler seçilecektir.

Öncelikle kullanılan evrişimsel filtre boylarının (kernel size, C1, C2, vb.) performansa etkileri incelenecektir. Diğer tüm parametreler sabit tutulmuştur. Kayıp hesabı

Algoritma 4 Önerilen EOK Yöntemiyle Kargaşa Giderme Algoritması

Girdi:

X : Ham YNR B-tarama verisi ($X \in \mathbb{R}^{M \times N}$)
 Z : Referans YNR B-tarama verisi ($Z \in \mathbb{R}^{M \times N}$)
 F_1 : Kodlayıcı aşamasında kullanılan filtrelerin boyutu
 K : Kodlayıcı aşamasında kullanılan filtre sayısı
 F_2 : Kod çözücü aşamasında kullanılan filtrelerin boyutu
 L : Kod çözücü aşamasında kullanılan filtre sayısı
 N : İterasyon (yineleme) sayısı
 ϕ_1, ϕ_2 : Aktivasyon fonksiyonları
 l_r : Öğrenme oranı

Çıktı:

V_1 : Kodlayıcı aşaması için filtre katsayıları ($V_1 \in \mathbb{R}^{F_1 \times F_1 \times K}$)
 V_2 : Kod çözücü aşaması için filtre katsayıları ($V_2 \in \mathbb{R}^{F_2 \times F_2 \times L}$)
 X_t : Yeniden oluşturulan hedef verisi ($X_t \in \mathbb{R}^{M \times N}$)


Eğitim aşaması:

```
for i = 1, 2, ..., N do
     $H = \phi_1(X * V_1 + b_1)$ 
     $X_t = \phi_2(H * V_2 + b_2)$ 
     $MSE(Z, X_t) = \frac{1}{M \times N} \|Z - X_t\|_2^2$ 
     $V'_1 = \frac{\partial MSE(Z, X_t)}{\partial V_1}$ 
     $V'_2 = \frac{\partial MSE(Z, X_t)}{\partial V_2}$ 
    Katsayıları güncelle :
     $V_1 = V_1 - l_r * V'_1$ 
     $V_2 = V_2 - l_r * V'_2$ 
```

end for**Test aşaması:**

$X_t = \phi_2(\phi_1(X * V_1) * V_2)$

için OKH fonksiyonu kullanılmıştır. Eğitim aşamasında adaptif öğrenme oranı kullanan Adadelta algoritması kullanılmıştır. Grup boyutu (batch size) 32, devir sayısı 50 olarak seçilmiştir. Evrişimsel katmanda adım kaydırma aralığı (stride) 1 olarak seçilmiştir. Evrişimsel katmanda dolgulama (padding) işlemi yapıldığı için giren ve çıkan görüntü boyutları aynıdır. Evrişimsel katmanlardan sonra DDB aktivasyon fonksiyonu kullanılmıştır. Eğitim aşamasında 336 adet orijinal veri hiç kullanılmamıştır. Bunun yerine veri çoğaltma yöntemi ile elde edilen 3360 adet verinin %90'ı eğitim verisi, %10'u eğitim aşamasında doğrulama (validation) verisi olarak kullanılmıştır. Eğitilen modelin performansı orijinal veri seti üzerinden test edilmiştir. Tüm testlerde filtre sayıları $K_1=32$, $K_2=16$, $K_3=16$ ve $K_4=32$ olarak




Şekil 5.5 : EOK parametrik ağ mimarisi

Çizelge 5.3 : Evrişimsel katmanlarda kullanılan farklı filtre boyutları için eğitim süreleri ve ortalama TİGO değerleri

C1	C2	C3	C4	C5	Eğitim süresi (dk)	Ortalama TİGO (dB)
3	3	3	3	3	2.38	47.16
4	4	4	4	4	2.94	51.86
5	5	5	5	5	3.08	59.22
8	8	8	8	8	5.14	62.63
16	8	8	8	16	11.35	67.79
16	16	16	16	16	13.20	70.73

seçilmiştir. Çizelge 5.3'te evrişimsel otokodlayıcıda kullanılan filtre boylarının performansa olan etkileri gösterilmektedir. Filtre boyları 16x16 olarak seçildiğinde en yüksek performans elde edilmektedir. Ayrıca evrişimsel katmanda kullanılan filtre boyları arttırıldığında eğitim süresinin uzadığı görülmektedir. Çizelge 5.3'te kullanılan filtre boyları ile elde edilen modellerin çıktıları görsel olarak analiz etmek için senaryo-1'de, karışım toprakta, alüminyum silindirin 0 cm derinliğe gömülmesiyle elde edilen ham veri, TİGO değeri hesaplanırken kullanılan referans veri ve model çıktıları Şekil 5.6'da gösterilmiştir. Burada sadece fikir vermesi açısından 336 tane test verisinden sadece 1 tanesi için görsel çıktılar verilmiştir. Hangi parametrenin daha yüksek performans gösterdiğine tüm veri seti için elde edilen ortalama TİGO değerine göre karar verilmektedir.

En yüksek performans sağlayan filtre boyları (16x16) kullanılarak filtre sayılarında (K1, K2, vb.) en iyi performans gösteren değerler araştırılmıştır. Benzer şekilde Çizelge 5.4'te gösterilen değerler için modeller eğitilmiştir ve eğitilen modelin



Şekil 5.6 : Evrişimsel otokodlayıcı ağ mimarisinde kullanılan farklı filtre boylarının görsel çıktıları. (a) Ham YNR verisi (girdi), (b) referans veri (girdi), farklı filtre boyları için yeniden oluşturulan veriler (c) 3x3, (d) 4x4, (e) 5x5, (f) 8x8, (g) 16x16/8x8, ve (h) 16x16.

performansı ortalama TİGO değeri ile ölçülmektedir. Aynı zamanda model eğitim süreleri de ilgili tabloda gösterilmektedir. Elde edilen sonuçlar değerlendirildiğinde filtre sayılarının artmasıyla model eğitim süresinin belirgin bir şekilde arttığı gözlenmiştir. En yüksek performans, filtre sayılarının 128 tane seçildiği durum için elde edilmiştir ancak diğer filtre sayıları ile olan fark çok azdır. Model eğitim sırasında

Çizelge 5.4 : Evrişimsel katmanlarda kullanılan filtrelerin farklı sayıları için eğitim süresi ve ortalama TİGO değerleri

K1	K2	K3	K4	Eğitim süresi (dk)	Ortalama TİGO (dB)
8	8	8	8	5.24	70.18
16	8	8	16	7.72	68.40
16	16	16	16	8.22	67.62
32	16	16	32	13.20	70.73
32	32	32	32	14.87	71.87
64	32	32	64	27.33	70.28
64	64	64	64	33.56	71.80
128	64	64	128	62.34	72.34
128	128	128	128	83.88	72.55

kullanılan devir sayısı ve grup boyutu (batch size) değerleri arttırıldığında bu farkın artacağı öngörülmektedir.

Devir sayısı, grup sayısı ve filtre sayılarında farklı parametreler kullanılarak toplamda 45 farklı model eğitilmiştir. Her bir model için elde edilen ortalama TİGO değeri ve model eğitim süresi Çizelge 5.5’te verilmiştir. 25, 50 ve 100 olmak üzere 3 farklı devir sayısı kullanılmıştır. Sonuçlar incelendiğinde devir sayısı artmasıyla birlikte eğitim süresi artmaktadır ve daha yüksek performans elde edilmektedir. Grup sayısında 1, 4, 16, 32 ve 64 olmak üzere 5 farklı değer kullanılmıştır. Grup sayısı için düşük değerler kullanıldığında eğitim süresi artarken model performansı da artmaktadır. Grup sayısı için yüksek değerler kullanıldığında modelin genelleştirme yeteneği azalır ve performans düşer. Ayrıca grup sayısı için yüksek değerler kullanıldığında hafıza problemleri ortaya çıkmaktadır. Grup sayısının küçük tutulmasının düzenleyici etkisi (regularizing effect) vardır çünkü model eğitiminde ağ, tek seferde az sayıda örnekle karşılaşır bu da çok çeşitli örneklerle eğitilme fırsatı sağlar ve genelleştirme hatasını minimuma indirdiğinden performansa olumlu etkisi vardır. En yüksek performans devir sayısının 100, grup boyutunun 1, filtre sayılarının 128 olduğu durumda elde edilmiştir. Bu modelin eğitilmesi yaklaşık 9.5 saat sürmüştür. En yüksek ikinci performans devir sayısının 100, grup boyutunun 4, filtre sayılarının 128 olduğu durumda elde edilmiştir. Bu modelin eğitim süresi yaklaşık 4.5 saat sürmüştür.

Çizelge 5.5 : Farklı devir sayısı, grup boyutu ve filtre sayısı için eğitim süresi ve ortalama TİGO değerleri

Devir sayısı	Grup boyutu	Eğitim süresi (dk)			Ortalama TİGO (dB)		
		K1=K2=K3=K4			K1=K2=K3=K4		
		8	32	128	8	32	128
25	1	13.21	28.46	142.84	77.10	81.83	84.72
25	4	6.36	14.29	70.26	72.35	74.94	77.67
25	16	3.24	8.62	45.29	68.25	70.43	73.63
25	32	2.63	7.48	42.05	42.15	65.32	62.34
25	64	2.37	7.12	39.76	44.42	56.75	64.04
50	1	28.10	56.92	285.90	80.88	84.10	86.95
50	4	12.94	28.43	140.51	78.92	81.23	80.94
50	16	6.35	17.31	90.54	71.19	74.90	77.11
50	32	5.18	14.89	83.93	67.21	67.50	70.48
50	64	4.56	14.08	79.08	59.06	64.55	65.17
100	1	57.36	115.62	572.53	81.40	88.83	95.25
100	4	26.27	57.23	280.20	80.88	83.24	89.05
100	16	12.71	34.48	179.96	75.50	77.90	81.45
100	32	10.36	29.76	167.38	72.54	75.31	75.35
100	64	9.08	28.25	157.89	68.20	70.60	71.85

Elde edilen modelin performansı literatürde yaygın olarak kullanılan yöntemlerle Bölüm 6’da karşılaştırılmıştır.

Ağdaki katman sayısının, yöntemin performansı üzerindeki etkisini incelemek için önerilen EOK ağ mimarisinin katman sayısı artırılmıştır. Evrişimsel ve örnekleme katmanları kod çözücü bloğuna, evrişimsel ve üst-örnekleme katmanları ise kod çözücü bloğuna eklenerek Derin EOK (DEOK) ağ mimarisi oluşturulmuştur. Yeni eklenen katmanlarda kullanılan parametreler EOK yöntemi için yapılan testler sonucunda elde edilen parametrelerle aynı kullanılmıştır. Hem EOK hem de DEOK ağ mimarileri için katmanlar, karar verilen parametreler, her katman sonucunda elde edilen çıktının boyutu Çizelge 5.6’da gösterilmektedir.

Çizelge 5.6 : Önerilen EOK ve DEOK yöntemlerine ait ağ mimarileri


EOK Ağ Mimarisi			DEOK Ağ Mimarisi		
Katman	(Boyut, Adım)	Çıktı	Katman	(Boyut, Adım)	Çıktı
Girdi	-	256x80x1	Girdi	-	256x80x1
Conv-1 + ReLU	(16x16, 1)	256x80x128	Conv-1 + ReLU	(16x16, 1)	256x80x128
Pooling-1	(2x2, 2)	128x40x128	Pooling-1	(2x2, 2)	128x40x128
Conv-2 + ReLU	(16x16, 1)	128x40x128	Conv-2 + ReLU	(16x16, 1)	128x40x128
Pooling-2	(2x2, 2)	64x20x128	Pooling-2	(2x2, 2)	64x20x128
Kodlanmış (64x20x128)			Conv-3 + ReLU	(16x16, 1)	64x20x128
			Pooling-3	(2x2, 2)	32x10x128
Kodlanmış (64x20x128)			Kodlanmış (32x10x128)		
Conv-3 + ReLU	(16x16, 1)	64x20x128	Conv-4 + ReLU	(16x16, 1)	32x10x128
Up-Sampling-1	(2x2, 2)	128x40x128	Up-Sampling-1	(2x2, 2)	64x20x128
Conv-4 + ReLU	(16x16, 1)	128x40x128	Conv-5 + ReLU	(16x16, 1)	64x20x128
Up-Sampling-2	(2x2, 2)	256x80x128	Up-Sampling-2	(2x2, 2)	128x40x128
Conv-5	(16x16, 1)	256x80x1	Conv-6 + ReLU	(16x16, 1)	128x40x128
			Up-Sampling-3	(2x2, 2)	256x80x128
			Conv-7	(16x16, 1)	256x80x1
			Yeniden oluşturulan (256x80x1)		
Yeniden oluşturulan (256x80x1)			Yeniden oluşturulan (256x80x1)		

6. DENEYSEL SONUÇLAR

Bu bölümde YNR verilerinde kargaşa gidermek için Bölüm 4.3'te önerilen öğrenilmiş sözlükler ile çalışan MBA yöntemi ve Bölüm 5'te önerilen EOK yöntemi için elde edilen detaylı analiz sonuçları paylaşılmıştır. Her 2 yöntemde hem literatürde yaygın olarak kullanılan klasik kargaşa giderme yöntemleriyle hem de son yıllarda geliştirilen literatürdeki en yeni yöntemlerle karşılaştırılmıştır. Her 2 yönteminde güçlü ve zayıf noktaları objektif olarak değerlendirilmiştir. Karşılaştırma için kullanılan GTBA, GNMA ve NMA yöntemleri için kullanılan üst değişkenler (hyperparameter) [67] yayınında kullanılan üst değişkenler ile aynı seçilmiştir. TBA, TDA ve klasik MBA yöntemleri [54] yayınında tanımlandığı gibi kullanılmıştır.

6.1 Öğrenilmiş Sözlükler Kullanan MBA ile YNR Verilerinde Kargaşa Giderme Sonuçları

Bölüm 4.3'te önerilen öğrenilmiş sözlükler kullanarak YNR verilerinde ayrıştırma yapan MBA yöntemi ile en iyi sonucu elde etmek için kullanılan parametrelerde optimizasyon yapılması gerekmektedir. K-SVD yöntemi ile 4×4 , 8×8 ve 16×16 olmak üzere 3 farklı yama boyutu için hedef ve kargaşa sözlükleri öğrenilmiştir. Ayrıca (4.12) denkleminde tanımlanan her bir ayrıştırma için izin verilen maksimum seyreklik katsayısı (k_0) için 1, 3 ve 5 değerleri için sonuçlar elde edilerek bu parametrenin performansa olan etkisi incelenmiştir. Önerilen yöntem için en iyi sonucu veren parametrelere karar verebilmek ve parametrelerin performansa etkisini ölçmek için AİK eğrileri çizdirilecektir. Önerilen yöntem bir kargaşa giderme yöntemidir ve ham YNR B-tarama verisini girdi olarak almaktadır ve çıktı olarak verilen B-tarama verisi ile aynı boyutlarda olan kargaşa bileşeninin giderildiği sadece hedef bileşen içeren B-tarama verisi vermektedir. Bu hedef verisi üzerinden AİK grafiği elde edebilmek için bir tespit algoritmasına ihtiyaç vardır. [123] yayınında önerilen En Küçük Ortalama Kare (EKOK, Least Mean Square, LMS) yaklaşımı tespit algoritması



Şekil 6.1 : Öğrenilmiş sözlükler ile MBA yönteminde farklı parametreler için elde edilen sonuçlar


olarak kullanılmıştır. Böylelikle hedef ve yanlış alarm bölgelerinden alınan tespitlere göre AİK eğrileri elde edilebilmektedir. Hedef bölgesi ve yanlış alarm bölgesi ve AİK eğrilerine ait tanımlamalar Bölüm 2.5.3'te verilmiştir. Farklı yama boyutları ve farklı seyreklik katsayısı için elde edilen AİK grafikleri Şekil 6.1'de gösterilmektedir.

Şekil 6.1 incelendiğinde en yüksek tespit oranı ve aynı zamanda en düşük yanlış alarm oranının 8x8 boyutunda yamalara sahip olan sözlüklerle ayrıştırma aşamasında kullanılan izin verilen en yüksek seyrekliklik sayısının (k_0) 1 olduğu durumda elde edildiği görülmektedir. En kötü performansın 16x16 boyutunda yamalara sahip olan sözlüklerle k_0 parametresinin 3 ve 5 olduğu durumlarda olduğu görülmektedir.

AİK grafikleri üzerinden yöntemleri sayısal değer olarak karşılaştırmak da mümkündür. Bunun için AİK Eğri Altındaki Alan (EAA) hesaplanmaktadır. Çizelge 6.1'de MBA-ÖS yönteminin farklı parametreleri için elde edilen AİK-EAA

Çizelge 6.1 : MBA-ÖS yönteminin farklı parametreleri için elde edilen AİK Eğri Altındaki Alan (EAA) değerleri

MBA-ÖS Parametreler	AİK-EAA
Yama-boyutu 4x4, $k_0 = 1$	0.99005
Yama-boyutu 4x4, $k_0 = 3$	0.98996
Yama-boyutu 4x4, $k_0 = 5$	0.99131
Yama-boyutu 8x8, $k_0 = 1$	0.99980
Yama-boyutu 8x8, $k_0 = 3$	0.98559
Yama-boyutu 8x8, $k_0 = 5$	0.98268
Yama-boyutu 16x16, $k_0 = 1$	0.97991
Yama-boyutu 16x16, $k_0 = 3$	0.97936
Yama-boyutu 16x16, $k_0 = 5$	0.97885



Şekil 6.2 : Öğrenilmiş sözlükler ile MBA yönteminin diğer kargaşa giderme yöntemleriyle karşılaştırılması

değerleri gösterilmektedir. AİK-EAA metriğine göre de en iyi sonuç 8x8 boyutunda yama kullanıldığında ve k_0 değeri 1 alındığında elde edilmektedir.

En iyi parametrelerine karar verilen MBA-ÖS yönteminin; TBA, TDA, NMA, MBA-AS [54], GTBA [57], GNMA [67] yöntemleriyle AİK grafikleri üzerinden yapılan karşılaştırma sonucu Şekil 6.2’de verilmiştir. NMA dışındaki tüm yöntemler %100 tespit oranına ulaşmaktadır ancak yanlış alarm oranı en düşük yöntem, önerilen MBA-ÖS yöntemidir. TBA ve TDA yöntemlerinin yanlış alarm oranları çok yüksektir. Önerilen MBA-ÖS yönteminden sonra en düşük yanlış alarm oranına GTBA ve GNMA yöntemleri sahiptirler. Her bir yönteme ait AİK grafiğinde kullanılan Doğru Tespit Oranı (DTO) ve Yanlış Alarm Oranı (YAO) değerleri Çizelge 6.4’te verilmiştir. Yöntemlerin sadece %100 tespit oranına ulaştıklarındaki Yanlış Alarm Oranı (YAO) değerleri, önerilen yöntemin YAO değerinin diğer yöntemlerin YAO değerlerine oranı ve AİK-EAA metriğine ait sonuçlar Çizelge 6.2’de verilmiştir. Yöntemlerin %100 tespit oranına ulaştıklarındaki yanlış alarm oranları karşılaştırıldığında; önerilen yöntemin yanlış alarm oranı MBA-AS yönteminin yanlış alarm oranından 42 kat, GTBA ve GNMA yöntemlerinin yanlış alarm oranlarından 13 kat daha azdır. AİK-EAA metriğine göre de en iyi sonuç önerilen MBA-ÖS yöntemiyle elde edilmektedir.

Çizelge 6.2 : %100 tespit oranı için yöntemlerin Yanlış Alarm Oranları (YAO), bu oranların önerilen yöntem ile karşılaştırılması ve AİK Eğri Altındaki Alan (EAA)


Yöntem	%100 tespit için YAO	Yöntem YAO/MBA-ÖS YAO	AİK-EAA
MBA-ÖS	0.0033	1.0	0.99980
MBA-AS	0.1389	42.1	0.99859
GTBA	0.0439	13.3	0.99865
GNMA	0.0439	13.3	0.99855
NMA	0.1669	50.6	0.99688
TDA	0.0827	25.1	0.99933
TBA	0.2225	67.4	0.98497

Önerilen MBA-ÖS yönteminin tüm senaryolar göz önüne alındığında ortalama TİGO metriği açısından performansı düşük kalmaktadır ancak bazı zorlu senaryolarda diğer yöntemlere üstünlük sağlamaktadır. Engebeli yüzey ve yüzeyde su birikintisinin olduğu 4. senaryoya ait kuru killi toprağa gömülü alüminyum hedefin 4 cm derinlikte olduğu veriye ait karşılaştırmalı görsel sonuçlar Şekil 6.3’te verilmiştir. Diğer tüm kar-

gaşa giderme yöntemleri engebeli yüzeyden kaynaklanan kargaşayı temizleyemezken önerilen MBA-ÖS yöntemi kargaşayı başarılı bir şekilde temizlemiştir. Bu sonuçlara ait TİGO değerleri Çizelge 6.3'te verilmiştir. Önerilen MBA-ÖS yönteminin bu zor senaryoya ait veri için diğer yöntemlere üstünlük sağladığı görülmüştür. En iyi ikinci sonucu GNMA (RNMF) yöntemi, üçüncü en iyi sonucu ise MBA-AS yöntemi vermiştir.

Çizelge 6.3 : Engebeli yüzey ve yüzeyde su birikintisi (4. senaryo) varken kuru killi toprak 4 cm derinliğe gömülen alüminyum cisim için farklı yöntemlerle elde edilen TİGO değerleri

Yöntem	TİGO (dB)
TBA (PCA)	49.87
TDA (SVD)	66.86
NMA (NMF)	65.49
GNMA (RNMF)	73.87
GTBA (RPCA)	63.72
MBA-AS (MCA)	70.52
MBA-ÖS	82.49




Şekil 6.3 : Engelibeli yüzey ve yüzeyde su birikintisi (4. senaryo) varken kuru killi toprak 4 cm derinliğe gömülen alüminyum cisim için (a) Ham veri, (b) referans veri, kargaşa giderme sonuçları (c) TBA (PCA), (d) TDA (SVD), (e) NMA (NMF), (f) GNMA (RNMF), (g) GTBA (RPCA), (h) MBA-AS (MCA), ve (i) MBA-ÖS.

Çizelge 6.4 : AİK eğrisinde gösterilen yöntemlere ait doğru tespit oranı ve yanlış alarm oranı değerleri

Eşik	TBA		TDA		NMA		GNMA		GTBA		MBA-AS		MBA-ÖS	
	DTO	YAO	DTO	YAO	DTO	YAO	DTO	YAO	DTO	YAO	DTO	YAO	DTO	YAO
0.10	1.00	0.223	1.00	0.209	0.99	0.167	1.00	0.112	1.00	0.115	1.00	0.139	1.00	0.022
0.20	0.98	0.098	1.00	0.083	0.98	0.061	1.00	0.044	1.00	0.044	0.99	0.046	1.00	0.009
0.30	0.84	0.049	0.99	0.036	0.98	0.026	0.99	0.032	0.99	0.032	0.99	0.026	1.00	0.003
0.40	0.78	0.001	0.99	0.005	0.98	0.009	0.99	0.020	0.99	0.020	0.99	0.002	0.99	0.002
0.50	0.72	0	0.99	0	0.98	0.002	0.99	0.011	0.99	0.011	0.99	0.001	0.87	0
0.60	0.64	0	0.94	0	0.96	0	0.95	0	0.95	0	0.94	0	0.68	0
0.70	0.17	0	0.32	0	0.35	0	0.84	0	0.84	0	0.32	0	0.46	0
0.80	0.04	0	0.11	0	0.09	0	0.39	0	0.40	0	0.13	0	0.20	0
0.90	0	0	0	0	0.01	0	0.11	0	0.11	0	0.02	0	0	0
0.99	0	0	0	0	0	0	0	0	0	0	0	0	0	0


6.2 Evrişimsel Otokodlayıcılar ile YNR Verilerinde Kargaşa Giderme Sonuçları

Önerilen EOK ve DEOK ağ mimarileriyle YNR verilerinde kargaşa giderme yapan yöntem hem literatürde yaygın olarak kullanılan geleneksel yöntemler TBA, TDA, NMA yöntemleriyle hem de son zamanlarda yayınlanan MBA-AS [54], GTBA [57], GNMA [67] yöntemleriyle karşılaştırılmıştır. Yöntemler veri setinde bulunan hedeflerin gömüldükleri derinliklere, farklı toprak tiplerine ve oluşturulan senaryolara göre incelenmiştir. Bölüm 4.3'te önerilen MBA-ÖS yöntemi, Bölüm 6.1'de verilen sonuçlarda görüldüğü gibi kargaşayı başarılı bir şekilde temizleyerek diğer yöntemlere göre düşük yanlış alarm oranına sahip olsa da hedef imzası bozulduğu için TİGO parametresi ile değerlendirildiğinde diğer yöntemlerin gerisinde kaldığı için bu bölümde TİGO parametresi ile verilen sonuçlarda bu yönteme yer verilmemiştir.



Şekil 6.4 : Hedeflerin gömülme derinliğine göre ortalama TİGO değerleri.

Şekil 6.4'te test veri seti için elde edilen ortalama TİGO değerleri, veri setinde bulunan her bir hedef gömülme derinliği için çizdirilmiştir. Önerilen EOK ve DEOK




Şekil 6.5 : Farklı toprak tiplerine göre ortalama TİGO değerleri

ağ mimarileri tüm gömülme derinlikleri için en yüksek sonucu vererek diğer tüm yöntemlere üstünlük sağlamışlardır. GNMA ve MBA-AS yöntemleri sırasıyla en iyi üçüncü ve dördüncü performansı göstermişlerdir.

YNR sistemi yerin altındaki düzensizlikleri tespit etmektedir, bu sebeple veri toplanan toprak tipi YNR sistemleri için çok önemlidir. Yöntemlerin performansı toprak tipine göre değiştiğinden, yöntemlerin farklı toprak tiplerine göre dayanıklılıkları analiz edilmiştir ve sonuçlar Şekil 6.5'te gösterilmektedir. Sonuçlar incelendiğinde önerilen EOK ve DEOK ağ mimarileri diğer tüm yöntemlere 7 farklı toprak tipi için de üstünlük sağlamıştır. Kuru kum toprak tipinin elektromanyetik özellikleri gömülü cisim için kullanılan plastik malzeme ile benzer olduğundan dolayı diğer toprak tiplerine göre bu toprak tipinde önerilen yöntemin performansı biraz düşüktür ama yine de diğer yöntemlere bu toprak tipinde de üstünlük sağlamıştır. Hedef gömülme derinliği analizinde olduğu gibi GNMA ve MBA-AS yöntemleri önerilen yöntemin gerisinde kalsa da diğer yöntemlerden daha iyi performans göstermişlerdir.


Kargaşa giderme yöntemlerinin senaryo bazlı karşılaştırma sonuçları Şekil 6.6'da



Şekil 6.6 : Farklı senaryolara göre ortalama TİGO değerleri

gösterilmektedir. Önerilen yöntem tüm senaryolar için benzer performans göstermiştir. GNMA, GTBA, ve MBA-AS yöntemleri en basit senaryoda (Senaryo-1) önerilen yöntemi geçmelerine rağmen zorlu senaryolarda (Senaryo-3 ve Senaryo-4) önerilen yöntem diğer yöntemlere açık ara üstünlük sağlamaktadır. Önerilen yöntem öğrenme tabanlı bir yöntem olduğu için karşılaşılabileceği zorlu senaryoları içeren veri seti ile eğitildiğinden test aşamasında daha önce hiç karşılaşmadığı senaryolarda yüksek performans göstermektedir. Önerilen yöntemin dayanıklılığı özellikle zorlu senaryolarda gösterdiği performansla doğrulanmıştır. Önerilen yöntem zorlu koşullardan olumsuz etkilenmemektedir. Diğer yöntemlerin performansı zorlu senaryolarda düşmektedir.


Kodlayıcı ve kod çözücü bloklardaki katman sayısı fazla olan DEOK ağ mimarisi de EOK ağ mimarisine hedeflerin gömüldükleri derinliklere, farklı toprak tiplerine ve oluşturulan senaryolara göre yapılan tüm testlerde üstünlük sağlamıştır. Bu sonuçlar bize derin ağ mimarisinin önerilen yöntemin performansını arttırdığını göstermektedir.




Şekil 6.7 : Önerilen yöntemin hedef içermeyen B-tarama verisi ile test edilmesi. (a) Ham hedef içermeyen arkaplan verisi, (b) EOK yöntemi ile elde edilen kargaşa giderme sonucu ve (c) DEOK yöntemi ile elde edilen kargaşa giderme sonucu.

Önerilen yöntem, eğitildiği veri setinde yer almayan senaryolar ile test edilerek bu senaryolara karşı gösterdiği performans da incelenmiştir. Önerilen yöntemin hem eğitildiği hem de test edildiği veri setinde yer alan tüm B-tarama verileri sadece 1 tane hedef içeren verilerdir. Bu sebeple önerilen yöntem hiç hedef içermeyen B-tarama verisi ile test edilmiştir. Önerilen EOK ve DEOK modelleri hiç hedef içermeyen veri ile test edildiğinde Şekil 6.7’de görüldüğü gibi başarılı bir şekilde kargaşayı gidermiştir ve önerilen yöntem ile elde edilen çıktılarda herhangi bir bozukluk olmamıştır. Burada veri seti üretimi aşamasında referans veri oluşturmak için kullanılan kuru kum senaryo-1’e ait arkaplan verisi kullanılmıştır.

Önerilen yöntem, aynı zamanda B-tarama verisinde 2 tane hedef içeren veri ile test edilmiştir. Bunun için kuru kum’a 5 cm ve 2 cm derinliklerine alüminyum hedef gömülmüştür. EOK – DEOK modelleri; sadece 1 tane hedef içeren verilerden oluşan veri seti ile eğitilmesine karşın, farklı derinliklerde 2 tane hedefin olduğu senaryoda da hedef imzalarını bozmadan kargaşayı başarılı bir şekilde gidermiştir. Üretilen veri ve EOK – DEOK modelleri ile elde edilen kargaşa giderme sonuçları Şekil 6.8’de gösterilmektedir.



Şekil 6.8 : Önerilen yöntemin farklı derinliklerde 2 tane hedef içeren B-tarama verisi ile test edilmesi. (a) Ham farklı derinliklerde 2 tane hedef içeren veri, (b) EOK yöntemi ile elde edilen kargaşa giderme sonucu ve (c) DEOK yöntemi ile elde edilen kargaşa giderme sonucu.



Şekil 6.9 : Önerilen yöntemin hedef imzasının bozulduğu zorlu senaryo ile test edilmesi. (a) Ham hedef imzasının bozulduğu veri, (b) EOK yöntemi ile elde edilen kargaşa giderme sonucu ve (c) DEOK yöntemi ile elde edilen kargaşa giderme sonucu.

Üretilen veri setinde özellikle Senaryo-3 ve Senaryo-4 diğer senaryolara göre hedef tespitini zorlaştıran doğa koşulları içermektedir ve bu durumlarda hedef imzası kargaşa tarafından bozulmaktadır. Üretilen veri seti zorlu senaryolar içermesine rağmen farklı koşul oluşturmak adına senaryo-3 baz alınarak toprak yüzeyi engebeli yapılmış,

karışım toprak türünde alüminyum hedef 0 cm derinliğe gömülerek veri üretilmiştir. Yeryüzündeki dalgalanma 2 cm olarak ayarlanmıştır. Üretilen YNR verisi ve EOK – DEOK modelleri ile elde edilen sonuçlar Şekil 6.9’da gösterilmiştir. Hedef imzasının bozulduğu bu zorlu senaryo için DEOK modelinin, EOK modeline göre kargaşayı daha iyi temizlediği gözükmemektedir.

Önerilen yöntem Bölüm 2.3’te bahsedilen gerçek YNR sisteminden alınan veriler ile de test edilmiştir ve literatürde yer alan yöntemlerle karşılaştırılmıştır. Sonuçlar hem görsel olarak hem de Bölüm 2.5.2’de bahsedilen İşaret Kargaşa Oranı (İKO) parametresi üzerinden verilmiştir. Gerçek YNR verilerinde referans veri olmadığı için TİGO parametresine ait sonuç elde edilememektedir. Kuru toprak ve ıslak toprak için elde edilen algoritmaların kargaşa giderme sonuçları sırasıyla Şekil 6.10 ve Şekil 6.11’de gösterilmektedir. Gerçek verilerden oluşan veri seti olmadığı için önerilen yöntem simülasyon verileriyle eğitilmiştir ve bu kısıta rağmen ulaşılan sonuç diğer yöntemlere göre daha iyidir. Her 2 toprak durumu için de kargaşa başarılı bir şekilde giderilmiştir. Islak toprak durumunda diğer yöntemlerden elde edilen sonuçlarda hedefin sol bölgesinde yer alan kargaşa tam olarak temizlenememiştir. Her 2 toprak durumu için sonuçlar karşılaştırıldığında kuru toprak durumu için elde edilen sonuçların daha temiz olduğu söylenebilir.

Görsel incelemenin ardından nicel sonuçlar Çizelge 6.5 ve Çizelge 6.6’da sırasıyla kuru toprak ve ıslak toprak durumları için verilmiştir. Buna ek olarak tablolarda yer alan değerleri daha iyi yorumlayabilmek için bu sonuçlar Şekil 6.12 ve Şekil 6.13 ile desteklenmiştir. Tablolarda yer alan değerler (2.3)-(2.5) denklemleri kullanılarak HTB ve YAB için hesaplanmıştır. HTB ilerleme doğrultusunda 25-45 indeksleri arasında yer alan bölge olarak tanımlanmıştır. Geri kalan bölgeler YAB olarak tanımlanmıştır. Tüm yöntemler, HTB içerisinde en yüksek (1.0) HEF değerini vermektedirler. Bu sebeple algoritmaların başarımını YAB içerisindeki kargaşayı ne kadar temizledikleri belirleyecektir. Önerilen yöntem kuru toprak durumu (Çizelge 6.5, Şekil 6.12) için en yüksek değerlere yakın değerler elde etmiştir. MBA-AS ve GTBA yöntemleri kuru toprak durumu için en iyi sonuçları vermiştir. Zor senaryo olarak adlandırılan ıslak toprak durumunda önerilen yöntem (EOK) diğer yöntemleri geride bırakarak en iyi


Çizelge 6.5 : Kuru toprak verisi için İşaret-Kargaşa Oranı (İKO) değerleri

Yöntem	Kargaşa (maks)	İKO (maks)	Kargaşa (ort)	İKO (ort)
TBA	0.915	1.09	0.420	2.38
TDA	0.145	6.89	0.060	16.58
NMA	0.206	4.85	0.110	9.09
MBA-AS	0.115	8.69	0.042	23.79
GTBA	0.140	7.13	0.045	21.99
GNMA	0.121	8.27	0.049	20.24
EOK	0.139	7.18	0.053	18.97
DEOK	0.146	6.86	0.070	14.24


Çizelge 6.6 : Islak toprak verisi için İşaret-Kargaşa Oranı (İKO) değerleri

Yöntem	Kargaşa (maks)	İKO (maks)	Kargaşa (ort)	İKO (ort)
TBA	0.627	1.59	0.234	4.27
TDA	0.564	1.77	0.187	5.35
NMA	0.508	1.97	0.183	5.46
MBA-AS	0.354	2.83	0.118	8.48
GTBA	0.601	1.66	0.175	5.70
GNMA	0.704	1.42	0.209	4.79
EOK	0.274	3.65	0.119	8.37
DEOK	0.511	1.96	0.197	5.07


sonucu vermiştir. MBA-AS ise ikinci en iyi sonucu vermiştir. MBA-AS yöntemi diğer yöntemlere göre işlem yükü fazla olan uygun sözlük seçimi gerektiren bir yöntemdir.




Şekil 6.10 : Kuru toprak durumu için gerçek veri sonuçlarının karşılaştırılması. (a) Ham veri, kargaşa giderme sonuçları (b) TBA (PCA), (c) TDA (SVD), (d) NMA (NMF), (e) MBA-AS(MCA), (f) GTBA (RPCA), (g) GNMA (RNMF), (h) EOK ve (i) DEOK.



Şekil 6.11 : Islak toprak durumu için gerçek veri sonuçlarının karşılaştırılması. (a) Ham veri, kargaşa giderme sonuçları (b) TBA (PCA), (c) TDA (SVD), (d) NMA (NMF), (e) MBA-AS(MCA), (f) GTBA (RPCA), (g) GNMA (RNMF), (h) EOK ve (i) DEOK.



Şekil 6.12 : Kuru toprak verisi için normalize edilmiş HEF değerleri ile yöntemlerin karşılaştırılması.



Şekil 6.13 : Islak toprak verisi için normalize edilmiş HEF değerleri ile yöntemlerin karşılaştırılması.



7. SONUÇ VE ÖNERİLER

Yere Nüfuz Eden Radar (YNR) yerin altını görüntülemek için kullanılan ve bir çok farklı kullanım alanına sahip bir teknolojidir. Bu tez kapsamında yapılan çalışma YNR teknolojisinin askeri alanda yeryüzüne yakın gömülen mayınların tespit edilmesine yöneliktir. YNR sistemi, metal içeriği çok az olan ya da hiç olmayan mayınların tespit edilmesinde metal dedektörlerine üstünlük sağlasa da YNR sisteminin yerin altındaki herşeyi görebilme yeteneği ile mayınlar dışındaki yer altındaki düzensizlikler, ağaç kökleri, taşlar vb. cisimleri de görüyor olması ilgili bölgede mayın olmamasına rağmen mayın olduğu algısı oluşturarak yanlış alarmlara yol açmaktadır. Alıcı-verici antenler arasındaki kuplaj, yeryüzünden geri yansıyan yüksek enerjili dalga ve toprak içerisinde bulunan istenmeyen cisimlerden gelen yansımalar kargaşa olarak adlandırılmaktadır ve kargaşa, özellikle yeryüzüne yakın gömülen plastik içerikli mayınların tespit edilmesini zorlaştırmaktadır. İnsanların ölmesine veya yaralanmasına sebep olan böyle bir konuda literatüre katkı sağlayacak bir çalışma yapılması hedeflenmiştir ve 2 farklı kargaşa giderme yöntemi önerilmiştir.

Yıllar içerisinde YNR verilerindeki kargaşayı gidermek için farklı yaklaşımlar önerilmiştir. Bu yaklaşımlar incelenerek en iyi sonucu veren ve en yaygın olarak kullanılan yöntemlerin, Temel Bileşen Analizi (TBA, PCA), Tekil Değer Ayrışımı (TDA, SVD), Bağımsız Bileşen Analizi (BBA, ICA), Gürbüz TBA (GTBA, RPCA), Negatif Olmayan Matris Ayrışımı (NMA, NMF) ve Gürbüz NMA (GNMA, RNMF) olduğu görülmüştür ve bu tez kapsamında karşılaştırma yöntemleri olarak kullanılmıştır. Karşılaştırma yöntemlerine ait teknik detaylar Bölüm 3'te verilmiştir.

Önerilen ilk yaklaşım, Analitik Sözlükler (AS) kullanan Morfolojik Bileşen Analizi (MBA-AS) yönteminin hızlandırılması ve iyileştirilmesi için Öğrenilmiş Sözlükler (ÖS) kullanan MBA (MBA-ÖS) yöntemidir. Bu yöntemin ihtiyaç duyduğu sözlükleri öğrenebilmek için K-SVD sözlük öğrenme algoritmasından yararlanılmıştır. Bu yöntemde, YNR verisi bir bütün olarak değil yama olarak adlandırılan küçük verilerle

ayırıştırma yapmaktadır ve ayırıştırma aşamasında Dik Eşleme Takibi (DET, OMP) kullanılmaktadır. Önerilen MBA-ÖS yöntemi, MBA-AS yöntemine göre 6.8 kat hızlı çalışmaktadır ve elde edilen Alıcı İşletim Karakteristiği (AİK, ROC) eğrilerine göre MBA-AS yöntemine üstünlük sağlamıştır. Önerilen yöntemin yanlış alarm oranı MBA-AS yöntemine göre 42 kat daha azdır.

Önerilen MBA-ÖS yönteminin başarımını doğrudan etkileyen iki temel bileşen vardır. Sözlük öğrenmek için kullanılan algoritma ve kullanılan veriler ilk temel bileşeni oluşturmaktadır. İkinci temel bileşen ise ayırıştırma aşamasında kullanılan algoritmadır. K-SVD sözlük öğrenme yöntemi literatürdeki en başarılı sözlük öğrenme yöntemi olduğu için tercih edilmiştir. İlerleyen zamanda daha iyi sözlük öğrenme yöntemleri önerilirse, daha iyi sözlükler öğrenilerek önerilen MBA-ÖS yönteminin başarımı artırılabilir. Ayrıca ayırıştırma aşamasında literatürde yaygın olarak kullanılan DET (OMP) algoritması tercih edilmiştir, literatürde bu alanda önerilecek yeni yöntemler önerilen yöntemin başarımını iyileştirebilir.

Önerilen ikinci yaklaşım, öğrenme tabanlı bir yöntem olan Evrimsel Otokodlayıcılar (EOK) yönteminin YNR verilerinde kargaşa giderme için kullanılmasıdır. EOK yöntemi için 2 farklı ağ mimarisi önerilmiştir. Önerilen yöntem, hem gerçek veri seti hem de benzetim programı ile elde edilen veri seti kullanılarak test edilmiştir. Önerilen yöntem, farklı toprak tiplerine, farklı derinliklerde bulunan hedeflere, farklı senaryolara göre yapılan testler sonucunda literatürde varolan tüm yöntemlere üstünlük sağlamıştır. Özellikle zorlu senaryolarda mevcut yöntemlere bariz üstünlük sağlamaktadır. Bu yöntemin geliştirilmesinde eğitim aşaması önemli bir yer tutmaktadır. Eğitim aşaması için benzetim programı yardımıyla oluşturulan veri seti kullanılmaktadır. Bu veri setinde yer alan veriler, yöntemin başarımını arttırmak için veri çoğaltma teknikleri ile çoğaltılmıştır. Eğitim aşamasında hiç gerçek veri kullanılmamasına rağmen önerilen yöntem ile diğer yöntemlere üstünlük sağlayacak sonuçlar elde edilmiştir.

Önerilen yöntem ile daha da iyi sonuçlar elde edilebileceği öngörülmektedir. Benzetim programı ile elde edilen veri seti çoğaltılarak veri setindeki çeşitlilik artırıldığında yöntemin başarımının da artacağı öngörülmektedir. Ayrıca varolan gerçek verilerin

sayısı çok az olduđu için önerilen yöntem eğitilirken bu veriler kullanılamamıştır. Gerçek bir YNR sistemi ile kapsamlı bir veri seti oluşturularak eğitim yapıldığında çok daha iyi sonuçlar elde edilebilir.

Önerilen yöntem öğrenme tabanlı bir yöntemdir ve yöntemin başarımı eğitim aşamasında kullanılan veri seti ile doğrudan ilişkilidir. Sadece veri setini çeşitlendirmek mevcut yöntemin başarımını arttıracaktır ancak veri setindeki veri sayısı artırıldığında önerilen yöntemin kodlayıcı ve kod çözücü aşamalarında daha derin ağ mimarilerinin kullanılmasının önü de açılacaktır. Ayrıca tüm bunlara ek olarak literatürde derin öğrenme alanında hızlı bir şekilde yeni ve farklı ağ mimarileri önerilmektedir. Önerilen yöntemin başarımını arttırmak için ağ mimarisinde önerilen farklı yaklaşımlardan da yararlanılabilir.



KAYNAKLAR

- [1] **URL-1.** <<http://www.malags.com/GPR-Explained/MALA-GPR-principle.jpg>>, erişim tarihi: 01.04.2015.
- [2] **Ratto R., C., Torrione, P.A. ve Collins, L.M.** (2011). Exploiting ground-penetrating radar phenomenology in a context-dependent framework for landmine detection and discrimination, *IEEE Transactions on Geoscience and Remote Sensing*, 49(5), 1689 – 1700.
- [3] **Scheers, B.** (2001). *Ultra-wideband ground penetrating radar, with application to the detection of anti personnel landmines*, Royal Military Academy.
- [4] **Starck, J.L., Elad, M. ve Donoho, D.** (2004). Redundant multiscale transforms and their application for morphological component separation, *Advances in Imaging and Electron Physics*, 132, 287–348.
- [5] **Starck, J.L., Elad, M. ve Donoho, D.** (2005). Image decomposition via the combination of sparse representations and a variational approach, *IEEE Transactions on Image Processing*, 14(10).
- [6] **Fadili, J.M., Starck, J.L., Elad, M. ve Donoho, D.** (2010). MCALab: reproducible research in signal and image decomposition and inpainting, *IEEE Computing in Science and Engineering*, 12(1), 44–63.
- [7] **VanderGaast, B., McFee, J., Russell, K. ve Faust, A.** (2015). Design and validation of inert homemade explosive simulants for ground penetrating radar, *Proceedings of SPIE Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XX*, cilt-945412.
- [8] **Szynkarczyk, P., Wrona, J., Pasternak, M., Rubiec, A. ve Serafin, P.** (2021). Unmanned ground vehicle equipped with ground penetrating radar for improvised explosive detection, *Journal of Automation, Mobile Robotics and Intelligent Systems*, 15(2), 20–31.
- [9] **Brito-da Costa, A.M., Martins, D., Rodrigues, D., Fernandes, L., Moura, R. ve Madureira-Carvalho, A.** (2022). Ground penetrating radar for buried explosive devices detection: a case studies review, *Australian Journal of Forensic Sciences*, 54(4), 559–578.
- [10] **Daniels, D.J.** (1996). *Surface penetrating radar*, IEE Radar, Sonar, Navigation and Avionics Series 6.

- [11] **Daniels, D.J.** (2004). *Ground penetrating radar*, London: Institution of Electrical Engineers.
- [12] **Abujarad, F., Jöstingmeier, A. ve Omar, A.** (2004). Clutter removal for landmine using different signal processing techniques, *Tenth International Conference on Ground Penetrating Radar*, Delft, Netherlands.
- [13] **Abujarad, F., Nadim, G. ve Omar, A.** (2005). Clutter reduction and detection of landmine objects in ground penetrating radar data using singular value decomposition (SVD), *Proceedings of the 3rd International Workshop on Advanced Ground Penetrating Radar*.
- [14] **Abujarad, F. ve Omar, A.** (2006). GPR data processing using the component-separation methods PCA and ICA, *International Workshop on Imaging Systems and Techniques*, Minori, Italy.
- [15] **Abujarad, F.** (2014). Independent factor analysis for clutter reduction in GPR data for landmine detection, *15th International Conference on Ground Penetrating Radar*.
- [16] **Abujarad, F., Nadim, G. ve Omar, A.** (2005). Wavelet packets for GPR detection of non-metallic anti-personnel land mines based on higher-order-statistics, *Proceedings of the 3rd International Workshop on Advanced Ground Penetrating Radar*.
- [17] **Abujarad, F., Nadim, G. ve Omar, A.** (2005). Combining wavelet packets with higher-order-statistics for GPR detection of non-metallic anti-personnel land mines, *Proceedings of SPIE Image and Signal Processing for Remote Sensing XI*.
- [18] **Karlsen, B., Larsen, J., Sorensen, H. ve Jakobsen, K.** (2001). Comparison of PCA and ICA based clutter reduction in GPR systems for anti-personal landmine detection, *11th IEEE Signal Processing Workshop on Statistical Signal Processing*.
- [19] **Karlsen, B., Sorensen, H., Larsen, J. ve Jakobsen, K.** (2002). Independent component analysis for clutter reduction in ground penetrating radar data, *SPIE Detection and Remediation Technologies for Mines and Minelike Targets VII*.
- [20] **Bell, A.J. ve Sejnowski, T.J.** (1995). An information-maximisation approach to blind separation and blind deconvolution, *Neural Computation*, 7(6), 1129–1159.
- [21] **Molgedey, L. ve Schuster, H.G.** (1994). Separation of a mixture of independent signals using time delayed correlations, *Physical Review Letters*, 72(23), 3634–3637.
- [22] **Bach, F.R. ve I, J.M.** (2002). Kernel independent component analysis, *Journal of Machine Learning Research*, 3, 1–48.

- [23] **Tjora, S., Eide, E. ve Lundheim, L.** (2004). Evaluation of methods for ground bounce removal in GPR utility mapping, *Tenth International Conference on Ground Penetrating Radar*, Delft, Netherlands.
- [24] **Tebchrany, E., Sagnard, F., Baltazart, V., Tarel, j.P. ve X, D.** (2014). Assessment of statistical-based clutter reduction techniques on ground-coupled GPR data for the detection of buried objects in soils, *15th International Conference on Ground Penetrating Radar*.
- [25] **Zhao, A., Jiang, Y. ve Wang, W.** (2005). Exploring independent component analysis for GPR signal processing, *Progress In Electromagnetics Research Symposium*, Hangzhou, China.
- [26] **Brunzell, H.** (1999). Detection of shallowly buried objects using impulse radar, *IEEE Transactions on Geoscience and Remote Sensing*, 37(2).
- [27] **Tesfamariam, G., Mali, D. ve Zoubir, A.** (2011). Clutter reduction techniques for GPR based buried landmine detection, *International Conference on Signal Processing, Communication, Computing and Network Technologies (ICSCCN)*.
- [28] **Zoubir, A., Chant, I.J., Brown, C., Barkat, B. ve Abeynayake, C.** (2002). Signal processing techniques for landmine detection using impulse ground penetrating radar, *IEEE Sensors Journal*, 2(1).
- [29] **Carevic, D.** (1999). Kalman filter-based approach to target detection and target-background separation in ground penetrating radar data, *SPIE Conference on Detection and Remediation Technologies for Mines and Minelike Targets IV*, Orlando, Florida.
- [30] **Luo, Y. ve Fang, G.Y.** (2005). GPR clutter reduction and buried target detection by improved kalman filter technique, *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics*, Guangzhou.
- [31] **Kempen, L. ve Sahli, H.** (2001). Signal processing techniques for clutter parameters estimation and clutter removal in GPR data for landmine detection, *11th IEEE Signal Processing Workshop on Statistical Signal Processing*.
- [32] **Carevic, D.** (1999). Clutter reduction and target detection in ground penetrating radar data using wavelets, *SPIE Conference on Detection and Remediation Technologies for Mines and Minelike Targets IV*, Orlando, Florida.
- [33] **Yoldemir, A., Gürcan, R., Kaplan, G. ve Sezgin, M.** (2011). Comparative analysis of clutter suppression techniques for landmine detection using ground penetrating radar, *SPIE Detection and Sensing of Mines, Explosive Objects and Obscured Targets XVI*.

- [34] **Nadim, G.** (2008). Clutter reduction and detection of landmine objects in ground penetrating radar data using likelihood method, *International Conference on Signal Processing, Communication, Computing and Network Technologies (ICSCCN)*, Malta.
- [35] **Potin, D., Duflos, E. ve Vanheeghe, P.** (2006). Landmines ground-penetrating radar signal enhancement by digital filtering, *IEEE Transactions on Geoscience and Remote Sensing*, 44(9).
- [36] **Ting, L., Ling, K. ve Zheng, Z.** (2008). Symmetry filtering method for GPR clutter reduction, *International Conference on Microwave and Millimeter Wave Technology (ICMMT)*.
- [37] **Lopera, O., Slob, E., Milisavljevic, N. ve Lambot, S.** (2007). Filtering soil surface and antenna effects from GPR data to enhance landmine detection, *IEEE Transactions on Geoscience and Remote Sensing*, 45(3).
- [38] **Merwe, A.v.d. ve Gupta, I.** (2000). A novel signal processing technique for clutter reduction in GPR measurements of small, shallow land mines, *IEEE Transactions on Geoscience and Remote Sensing*, 38(6).
- [39] **URL-2.** <<http://tr.wikipedia.org/wiki/Mayin-sorunu>>, erişim tarihi: 29.06.2006.
- [40] **URL-3.** <<https://www.paraview.org/>>, erişim tarihi: 01.01.2018.
- [41] **URL-4.** <<http://www.minedet.etro.vub.ac.be.>>, erişim tarihi: 01.09.2011.
- [42] **Riaz, M.M. ve Ghafoor, A.** (2012). Information theoretic criterion based clutter reduction for ground penetrating radar, *Progress In Electromagnetics Research B*, 45, 147–164.
- [43] **Riaz, M.M. ve Ghafoor, A.** (2013). Ground penetrating radar image enhancement using singular value decomposition, *IEEE International Symposium on Circuits and Systems (ISCAS)*.
- [44] **Hyvarinen, A.** (1999). Fast and robust fixed-point algorithms for independent component analysis, *IEEE Transactions on Neural Networks*, 10(3), 626–634.
- [45] **Cardoso, J.F. ve A, S.** (1993). Blind beamforming for non-gaussian signals, *IEE Proceedings-F*, 140(6), 362–370.
- [46] **Liu, J., Zhang, B. ve Wu, R.** (2006). GPR ground bounce removal methods based on blind source separation, *Progress In Electromagnetics Research Symposium*, Cambridge, USA.
- [47] **Liu, J., Wu, R. ve Zhang, B.** (2006). Novel ground bounce removal algorithms based on non-homogeneous detector, *International Conference on Radar (CIE)*, Shanghai.
- [48] **Gao, Q., Li, T. ve Wu, R.** (2006). A novel KICA method for ground bounce removal with GPR, *International Conference on Radar (CIE)*, Shanghai.

- [49] **Verma, P., Gaikwad, A., Singh, D. ve Nigam, M.** (2009). Analysis of clutter reduction techniques for through wall imaging in UWB range, *Progress In Electromagnetics Research B*, 17, 29–48.
- [50] **Warren, C., Giannopoulos, A. ve Giannakis, I.** (2016). gprMax: Open source software to simulate electromagnetic wave propagation for ground penetrating radar, *Computer Physics Communications*, 209, 163–170.
- [51] **Giannakis, I., Giannopoulos, A. ve Warren, C.** (2016). A realistic FDTD numerical modeling framework of ground penetrating radar for landmine detection, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(1), 37–51.
- [52] **Warren, C. ve Giannopoulos, A.** (2011). Creating finite-difference time-domain models of commercial GPR antennas using taguchi’s optimisation method, *Geophysics*, 76(2), 37–47.
- [53] **Giannakis, I., Giannopoulos, A. ve Warren, C.** (2019). Realistic FDTD GPR Antenna Models Optimized Using a novel linear/nonlinear full-waveform inversion, *IEEE Transactions on Geoscience and Remote Sensing*, 57(3), 1768–1778.
- [54] **Temlioglu, E. ve Erer, I.** (2016). Clutter removal in ground-penetrating radar images using morphological component analysis, *IEEE Geoscience and Remote Sensing Letters*, 13(12), 1802–1806.
- [55] **Temlioglu, E.,** (2015). Yere nüfuz eden radar görüntülerinde morfolojik bileşen analizi yöntemi ile kargaşa giderme, (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi.
- [56] **Candes, E.J., Li, X., Ma, Y. ve Wright, J.** (2011). Robust principal component analysis?, *Journal of Association for Computing Machinery (ACM)*, 58(3), 11:1–11:37.
- [57] **Song, X., Xiang, D., Zhou, K. ve Su, Y.** (2017). Improving RPCA-Based Clutter Suppression GPR Detection of Antipersonnel Mines, *IEEE Geoscience and Remote Sensing Letters*, 14(8), 1338–1342.
- [58] **Beck, A. ve Teboulle, M.** (2009). A fast iterative shrinkage-thresholding algorithm for linear inverse problems, *SIAM Journal of Imaging Sciences*, 2(1), 183–202.
- [59] **Zhou, T. ve Tao, D.** (2011). GoDec: Randomized Low-rank & Sparse Matrix Decomposition in Noisy Case, *Processing 28th International Conference Machine Learning (ICML)*.
- [60] **Song, X., Xiang, D., Zhou, K. ve Su, Y.** (2019). Fast prescreening for GPR antipersonnel mine detection via go decomposition, *IEEE Geoscience and Remote Sensing Letters*, 16(1), 15–19.

- [61] **Kumlu, D. ve Erer, I.** (2020). Ground penetrating radar clutter removal via randomized low rank and sparse decomposition for missing data case, *International Journal of Remote Sensing*, 41(19), 7680–7699.
- [62] **Shu, X., Porikli, F. ve Ahuja, N.** (2014). Robust orthonormal subspace learning: efficient recovery of corrupted low-rank matrices, *IEEE Conference Computer Vision and Pattern Recognition (CVPR)*.
- [63] **Kumlu, D. ve Erer, I.** (2020). GPR clutter reduction by robust orthonormal subspace learning, *IEEE Access*, 8, 74145–74156.
- [64] **Berry, M.W., Browne, M., Langville, A.N., Pauca, V.P. ve Plemmons, R.J.** (2007). Algorithms and applications for approximate nonnegative matrix factorization, *Computational statistics & data analysis*, 52(1), 155–173.
- [65] **Kumlu, D. ve Erer, I.** (2018). Clutter removal in GPR images using non-negative matrix factorization, *Journal of Electromagnetic Waves and Applications*, 32(16), 2055–2066.
- [66] **Zhang, L., Chen, Z., Zheng, M. ve He, X.** (2011). Robust non-negative matrix factorization, *Frontiers of Electrical and Electronic Engineering in China*, 6(2), 192–200.
- [67] **Kumlu, D. ve Erer, I.** (2020). Improved clutter removal in GPR by robust nonnegative matrix factorization, *IEEE Geoscience and Remote Sensing Letters*, 17(6), 958–962.
- [68] **Kumlu, D.** (2018). *New clutter removal methods for through obstacle target detection*, İstanbul Teknik Üniversitesi.
- [69] **Kumlu, D. ve Erer, I.** (2018). The multiscale directional neighborhood filter and its application to clutter removal in GPR data, *Signal, Image and Video Processing*, 12, 1237–1244.
- [70] **Wang, X. ve Liu, S.** (2017). Noise suppressing and direct wave arrivals removal in GPR data based on Shearlet transform, *Signal Processing*, 132, 227–242.
- [71] **Zhang, L., Tang, J., Li, Y., Liu, Z., Chen, W. ve Li, G.** (2022). GPR denoising via shearlet transformation and data-driven tight frame, *Near Surface Geophysics*, 20, 398–418.
- [72] **Qian-Zong, B., Qing-Chun, L. ve Wen-Chao, C.** (2014). GPR data noise attenuation on the curvelet transform, *Applied Geophysics*, 11(3), 301–310.
- [73] **Terrasse, G., Nicolas, J.M., Trouve, E. ve Drouet, E.** (2017). Application of the curvelet transform for clutter and noise removal in GPR data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(10), 4280–4294.

- [74] **Peng, W., Hongling, X. ve Pengcheng, X.** (2016). Research on ground penetrating radar image denoising using nonsubsampling contourlet transform and adaptive threshold algorithm, *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 9(5), 219–228.
- [75] **Ni, Z.K., Pan, J., Shi, C., Ye, S., Zhao, D. ve Fang, G.** (2022). DL-based clutter removal in migrated GPR data for detection of buried target, *IEEE Geoscience and Remote Sensing Letters*, 19.
- [76] **Feng, D., Liu, S., Yang, J., Wang, X. ve Wang, X.** (2021). The noise attenuation and stochastic clutter removal of ground penetrating radar based on the K-SVD dictionary learning, *IEEE Access*, 9, 74879 – 74890.
- [77] **Fadili, M.J., Starck, J.L., Bobin, J. ve Moudden, Y.** (2009). Image decomposition and separation using sparse representations: an overview, *Proceedings of the IEEE*, 98(6).
- [78] **Elad, M., Starck, J.L., Querre, P. ve Donoho, D.** (2005). Simultaneous cartoon and texture image inpainting using morphological component analysis (MCA), *Applied and Computational Harmonic Analysis*, 19, 340–358.
- [79] **Starck, J.L., Moudden, Y., Bobin, J., Elad, M. ve Donoho, D.** (2005). Morphological component analysis, *SPIE Wavelets XI*.
- [80] **Bobin, J., Moudden, Y., Starck, J.L. ve Elad, M.** (2006). Morphological diversity and source separation, *IEEE Signal Processing Letters*, 13(7).
- [81] **Bobin, J., Moudden, Y. ve Starck, J.L.** (2006). Enhanced source separation by morphological component analysis, *IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP) Proceedings*.
- [82] **Yong, X., Ward, R.K. ve Birch, G.E.** (2009). Artifact removal in EEG using morphological component analysis, *IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP) Proceedings*.
- [83] **Yong, X., Ward, R.K. ve Birch, G.E.** (2009). Generalized morphological component analysis for EEG source separation and artifact removal, *IEEE 4th International Conference on Neural Engineering*, Antalya, Turkey.
- [84] **Peyre, G., Fadili, J. ve Starck, J.L.** (2010). Learning the morphological diversity, *SIAM Journal on Imaging Sciences*, 3(3).
- [85] **Bobin, J., Starck, J.L., Fadili, J.M., Moudden, Y. ve Donoho, D.** (2007). Morphological component analysis: an adaptive thresholding strategy, *IEEE Transactions on Image Processing*, 16(11), 2675–2681.
- [86] **Dubois, S., Peteri, R. ve Menard, M.** (2012). Decomposition of dynamic textures using morphological component analysis, *IEEE Transactions on Circuits and Systems for Video Technology*, 22(2), 188–201.

- [87] **Xue, Z., Li, J., Cheng, L. ve Du, P.** (2015). Spectral-spatial classification of hyperspectral data via morphological component analysis-based image separation, *IEEE Transactions on Geoscience and Remote Sensing*, 53(1), 70–84.
- [88] **Gao, X., Wang, Y., Li, X. ve Tao, D.** (2010). On combining morphological component analysis and concentric morphology model for mammographic mass detection, *IEEE Transactions on Information Technology in Biomedicine*, 14(2), 266–273.
- [89] **Yu, C., Qiu, Q., Zhao, Y. ve Chen, X.** (2013). Satellite image classification using morphological component analysis of texture and cartoon layers, *IEEE Geoscience and Remote Sensing Letters*, 10(5), 1109–1113.
- [90] **Grosdidier, S. ve Baussard, A.** (2012). Ship detection based on morphological component analysis of high-frequency surface wave radar images, *IET Radar, Sonar and Navigation*, 6(9), 813–821.
- [91] **Aharon, M., Elad, M. ve Alfred, B.** (2006). K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation, *IEEE Transactions on Signal Processing*, 54(11), 4311–4322.
- [92] **Elad, M. ve Aharon, M.** (2006). Image denoising via sparse and redundant representations over learned dictionaries, *IEEE Transactions on Image Processing*, 15(12), 3736–3745.
- [93] **Candes, E., Demanet, L., Donoho, D. ve Ying, L.** (2006). Fast discrete curvelet transforms, *SIAM Multiscale Modeling and Simulation*, 5(3).
- [94] **Chen, S., Donoho, D. ve Saunderson, M.** (1998). Atomic decomposition by basis pursuit, *SIAM Journal on Scientific Computing*, 20(1).
- [95] **Goodfellow, I., Bengio, Y. ve Courville, A.** (2016). *Deep Learning*, MIT Press.
- [96] **Reichman, D., Collins, L.M. ve Malof, J.M.** (2017). Some good practices for applying convolutional neural networks to buried threat detection in Ground Penetrating Radar, *IEEE 9th International Workshop on Advanced Ground Penetrating Radar (IWAGPR)*, s.1–5.
- [97] **Besaw, L.E.** (2016). Detecting buried explosive hazards with handheld GPR and deep learning, *Proceedings of SPIE Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXI*, cilt-9823.
- [98] **Temlioglu, E. ve Erer, I.** (2021). A novel convolutional autoencoder-based clutter removal method for buried threat detection in ground-penetrating radar, *IEEE Transactions on Geoscience and Remote Sensing*, 60.
- [99] **Ball, J.E., Anderson, D.T. ve Chan, C.S.** (2017). Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community, *Journal of Applied Remote Sensing*, 11(4).

- [100] **Malof, J.M., Reichman, D., Karem, A., Frigui, H., Ho, K.C., Wilson, J.N., Lee, W., Cummings, W.J. ve Collins, L.M.** (2019). A large-scale multi-institutional evaluation of advanced discrimination algorithms for buried threat detection in ground penetrating radar, *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6929–6945.
- [101] **Williams, R.M., Ray, L.E., Lever, J.H. ve Burzynski, A.M.** (2014). Crevasse detection in ice sheets using ground penetrating radar and machine learning, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(12), 4836–4848.
- [102] **Giannakis, I., Giannopoulos, A. ve Warren, C.** (2019). A machine learning-based fast-forward solver for ground penetrating radar with application to full-waveform inversion, *IEEE Transactions on Geoscience and Remote Sensing*, 57(7), 4417–4426.
- [103] **Giannakis, I., Giannopoulos, A. ve Warren, C.** (2021). A machine learning scheme for estimating the diameter of reinforcing bars using ground penetrating radar, *IEEE Geoscience and Remote Sensing Letters*, 18(3), 461–465.
- [104] **Nieto, X.N. ve Solla, M.** (2014). GPR signal characterization for automated landmine and UXO detection based on machine learning techniques, *Remote Sensing*, 6(10), 9729–9748.
- [105] **Moalla, M., Frigui, H., Karem, A. ve Bouzid, A.** (2020). Application of Convolutional and Recurrent Neural Networks for Buried Threat Detection Using Ground Penetrating Radar Data, *IEEE Transactions on Geoscience and Remote Sensing*, 58(10), 7022–7034.
- [106] **Pham, M.T. ve Lefevre, S.** (2018). Buried object detection from b-scan ground penetrating radar data using faster-rcnn, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Valencia, Spain, s.6804–6807.
- [107] **Sonoda, J. ve Kimoto, T.** (2018). Object identification from GPR images by deep learning, *Asia-Pacific Microwave Conference (APMC)*, Valencia, Spain, s.1298–1300.
- [108] **Lameri, S., Lombardini, F., Bestagini, P., Lualdi, M. ve Tubaro, S.** (2017). Landmine detection from GPR data using convolutional neural networks, *25th European Signal Processing Conference (EUSIPCO)*, s.508–512.
- [109] **Bralich, J., Reichman, D., Collins, L.M. ve Malof, J.M.** (2017). Improving convolutional neural networks for buried target detection in ground penetrating radar using transfer learning via pretraining, *Proceedings of SPIE Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXII*, cilt-10182.

- [110] **Malof, J.M., Bralich, J., Reichman, D. ve Collins, L.M.** (2018). Improving the histogram of oriented gradient feature for threat detection in ground penetrating radar by implementing it as a trainable convolutional neural network, *Proceedings of SPIE Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXIII*, cilt-10628.
- [111] **Sakaguchi, R.T., Morton, K.D., Collins, L.M. ve Torrione, P.A.** (2015). Recognizing subsurface target responses in ground penetrating radar data using convolutional neural networks, *Proc. SPIE*, cilt9454.
- [112] **Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y. ve Manzagol, P.A.** (2010). Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion, *The Journal of Machine Learning Research*, 11, 3371–3408.
- [113] **Hinton, G.E. ve Salakhutdinov, R.R.** (2006). Reducing the dimensionality of data with neural networks, *Science*, 313(5786), 504–507.
- [114] **Masci, J., Meier, U., Cireşan, D. ve Schmidhuber, J.** (2011). Stacked convolutional auto-encoders for hierarchical feature extraction, *Springer International Conference on Artificial Neural Networks and Machine Learning (ICANN)*, Berlin, Heidelberg, s.52–59.
- [115] **Vishwakarma, S. ve Ram, S.S.** (2020). Mitigation of through-wall distortions of frontal radar images using denoising autoencoders, *IEEE Transactions on Geoscience and Remote Sensing*, 58(9), 6650–6663.
- [116] **Tivive, F.H.C. ve Bouzerdoun, A.** (2021). Clutter removal in through-the-wall radar imaging using sparse autoencoder with low-rank projection, *IEEE Transactions on Geoscience and Remote Sensing*, 59(2), 1118–1129.
- [117] **Bestagini, P., Lombardi, F., Lualdi, M., Picetti, F. ve Tubaro, S.** (2021). Landmine detection using autoencoders on multipolarization gpr volumetric data, *IEEE Transactions on Geoscience and Remote Sensing*, 59(1), 182–195.
- [118] **Azarang, A., Manoochehri, H.E. ve Kehtarnavaz, N.** (2019). Convolutional Autoencoder-Based Multispectral Image Fusion, *IEEE Access*, 7, 35673–35683.
- [119] **Ni, Z.K., Ye, S., Shi, C., Li, C. ve Fang, G.** (accepted for publication, 2020). Clutter suppression in GPR B-Scan images using robust autoencoder, *IEEE Geoscience and Remote Sensing Letters*.
- [120] **Geng, J., Fan, J., Wang, H., Ma, X., Li, B. ve Chen, F.** (2015). High-resolution SAR image classification via deep convolutional autoencoders, *IEEE Geoscience and Remote Sensing Letters*, 12(11), 2351–2355.
- [121] **Kemker, R. ve Kanan, C.** (2017). Self-taught feature learning for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 55(5), 2693–2705.

- [122] **Zeiler, M.D.** (2012). ADADELTA: An adaptive learning rate method, *arXiv preprint*, (arXiv:1212.5701).
- [123] **Temlioglu, E., Erer, I. ve Kumlu, D.** (2017). A least mean square approach to buried object detection in ground penetrating radar, *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Forth Worth, USA, s.4833–4836.
- [124] **Ni, Z.K., Shi, C., Pan, J., Zheng, Z., Ye, S. ve Fang, G.** (2022). Declutter-GAN: gpr b-scan data clutter removal using conditional generative adversarial nets, *IEEE Geoscience and Remote Sensing Letters*, 19.
- [125] **Sun, H.H., Cheng, W. ve Fan, Z.** (2022). Learning to remove clutter in real-world gpr images using hybrid data, *IEEE Transactions on Geoscience and Remote Sensing*, 60.
- [126] **Zhou, H., Wang, Y., Liu, Q. ve Wang, Y.** (2022). RNMF-guided deep network for signal separation of GPR without labeled data, *IEEE Geoscience and Remote Sensing Letters*, 19.
- [127] **Feng, D., Wang, X., Wang, X., Ding, S. ve Zhang, H.** (2021). Deep convolutional denoising autoencoders with network structure optimization for the high-fidelity attenuation of random gpr noise, *Remote Sensing*, 13(9), 1761.



EKLER

EK A : Norm İfadeleri





EK A : Norm İfadeleri

Matematikte norm, vektör değerlerinin gösterimi amacıyla kullanılmaktadır. Gerçek sayılar için tek norm mutlak değerdir ancak vektörler için norm aşağıdaki 3 özelliğe sahip herhangi bir fonksiyon olabilir.

1. Ölçekleme ile değişir: $p(ax) = |a|p(x)$
2. Üçgen eşitsizliğini sağlar: $p(x+y) \leq p(x) + p(y)$
3. Sadece orijindeyken sıfırdır: $p(x) = 0$ ancak ve ancak $x = 0$

x vektörünün **p-normu** (l_p) (A.1) denklemi ile ifade edilir.

$$||x||_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p} = \sqrt[p]{x_1^p + x_2^p + \dots + x_n^p} \quad (\text{A.1})$$

Bazı istisna normlar dışında diğer normlar bu ifadeden türetilmektedir.

l_0 -normu bir vektörde bulunan sıfır olmayan elemanların sayısıdır. Aslında yarı-norm olarak değerlendirilir. Norm olma şartlarının hepsini sağlamaz.

l_1 -normu Manhattan uzaklığı veya Taxicab normu olarak da bilinir. Bir uzaydaki vektörlerin büyüklüklerinin toplamıdır. Bir başka ifadeyle mutlak değerlerin toplamıdır ve (A.2) denklemi ile ifade edilir.

$$||x||_1 = \sum_{i=1}^n |x_i| = |x_1| + |x_2| + \dots + |x_n| \quad (\text{A.2})$$

l_2 -normu öklid (euclidean) uzaklığı olarak da bilinmektedir ve (A.3) denklemi ile ifade edilir.

$$||x||_2 = \sqrt{\sum_{i=1}^n x_i^2} = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2} \quad (\text{A.3})$$

l_∞ -normu sonsuz veya maksimum norm olarak bilinmektedir. Vektördeki en büyük genliğe sahip değeri verir. Bir başka ifadeyle vektördeki en büyük mutlak değere eşittir ve (A.4) denklemi ile ifade edilir.

$$||x||_\infty = \max_i |x_i| = \max(|x_1|, |x_2|, \dots, |x_n|) \quad (\text{A.4})$$

l_* -normu nükleer normu bazen Schatten 1-norm bazen de trace-norm olarak adlandırılmaktadır ve bir matrisin tekil değerlerinin toplamına eşittir. Bir matrisin nükleer normu (A.5) denklemi ile ifade edilir.

$$||A||_* = \sum_{i=1} \sigma_i(A) \quad (\text{A.5})$$

Frobenius norm öklid normunun matrisler için uygulanmasıdır ve matrisin karelerinin toplamının kareköküne eşittir. Frobenius norm (**A.6**) denklemi ile ifade edilir.

$$\|A\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{i,j}|^2} \quad (A.6)$$



ÖZGEÇMİŞ

Adı SOYADI: Eyyup TEMLİOĞLU

ÖĞRENİM DURUMU:

- **Lisans:** 2013, İstanbul Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Telekomünikasyon Mühendisliği Bölümü
- **Y. Lisans:** 2015, İstanbul Teknik Üniversitesi, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Telekomünikasyon Mühendisliği Programı.

MESLEKİ DENEYİMLER VE ÖDÜLLER:

- 2013-2016 yılları arasında TÜBİTAK BİLGEM’de araştırmacı olarak çalıştı.
- 2018 yılından itibaren Nokta Mühendislik A.Ş. firmasında yazılım geliştirici olarak çalışıyor.
- 2022 yılında Nokta Mühendislik A.Ş. firmasının çıkardığı "The Legend" adlı eş zamanlı çoklu frekans çalışan metal dedektörünün işaret işleme ve algoritma geliştirme görevlerinde yer aldı.
- "IEEE Transactions on Geoscience and Remote Sensing" ve "IEEE Geoscience and Remote Sensing Letters" dergilerinde hakemlik yapmaktadır.

DOKTORA TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Temlioglu E.**, Erer I., 2021. A Novel Convolutional Autoencoder-Based Clutter Removal Method for Buried Threat Detection in Ground-Penetrating Radar. *IEEE Transactions on Geoscience and Remote Sensing*, 60.
- **Temlioglu E.**, Erer I., Kumlu D., 2017. A Least Mean Square Approach to Buried Object Detection in Ground Penetrating Radar. *IEEE International Geoscience and Remote Sensing Symposium (IGRASS)*, 23-28 Temmuz, Fort Worth, TX, USA.

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

- **Temlioglu E.**, Erer I., 2015. Sparse Representations Based Clutter Removal In GPR Images. *IEEE 23rd Signal Processing and Communications Applications Conference (SIU)*, 16-19 Mayıs, Malatya, Türkiye.
- **Temlioglu E.**, Nazli H., Aksoy S., 2016. Comparative Analysis of Short and Long GPR Pulses for Landmine Detection. *SPIE Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXI*, 3 Mayıs, Baltimore, Maryland, USA.
- **Temlioglu E.**, Dağ M., Gürçan R., 2016. Comparison of Feature Extraction Methods for Landmine Detection using Ground Penetrating Radar. *IEEE 24th Signal Processing and Communications Applications Conference (SIU)*, 16-19 Mayıs, Zonguldak, Türkiye.
- **Temlioglu E.**, Erer I., Kumlu D., 2017. Histograms of Dominant Orientations for Anti-personnel Landmine Detection using Ground Penetrating Radar. *4th International Conference on Electrical and Electronic Engineering (ICEEE)*, 8-10 Nisan, Ankara, Türkiye.
- **Temlioglu E.**, Erer I., 2016. Clutter Removal in Ground-Penetrating Radar Images Using Morphological Component Analysis. *IEEE Geoscience and Remote Sensing Letters*, 13(12), 1802-1806.