

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YERE NÜFUZ EDEN RADAR VERİLERİNDE
ÖZNİTELİK ÇIKARIMI VE SINIFLANDIRILMASI

Beşaret KOÇAK

YÜKSEK LİSANS

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

Danışman

Prof. Dr. Aydın YEŞİLDİREK

Eş Danışman

Prof. Dr. Mehmet SEZGİN

Şubat, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YERE NÜFUZ EDEN RADAR VERİLERİNDE
ÖZNİTELİK ÇIKARIMI VE SINIFLANDIRILMASI

Beşaret KOÇAK tarafından hazırlanan tez çalışması 03.02.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği Anabilim Dalı, Mekatronik Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Aydın YEŞİLDİREK
Yıldız Teknik Üniversitesi
Danışman

Prof. Dr. Mehmet SEZGİN
İstanbul Ticaret Üniversitesi
Eş-Danışman

Jüri Üyeleri

Prof. Dr. Aydın YEŞİLDİREK, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Kadir ERKAN, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Ahmet SERTBAŞ, Üye
İstanbul Üniversitesi

Danışmanım Prof. Dr. Aydın YEŞİLDİREK ve Eş-Danışmanım Prof. Dr. Mehmet SEZGİN sorumluluğunda tarafımda hazırlanan “Yere Nüfuz Eden Radar Verilerinde Öznitelik Çıkarımı ve Sınıflandırılması” başlıklı çalışmada diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Beşaret KOÇAK

İmza

Canım Aileme

ve

Emeęi Geen Kıymetli Hocalarıma

TEŞEKKÜR

Bu tez çalışmasında konunun belirlenmesinden savunma sürecine kadar her aşamada bana rehberlik eden, değerli eş-danışmanım Prof. Dr. Mehmet Sezgin'e ve danışmanım Prof. Dr. Aydın Yeşildirek'e, sabırlı ve yol gösterici destekleri için içtenlikle teşekkür ederim. Onların akademik birikimleri ve rehberlikleri, bu çalışmanın şekillenmesinde büyük bir paya sahiptir.

Ayrıca, bana her zaman güç veren, sevgi ve ilgiyle yolumu aydınlatan babama, anneme ve kardeşlerime özellikle ablam Sultan Koçak'a, kardeşim Şeyma Koçak'a her türlü desteği sunmaları ve moral kaynağı olmaları nedeniyle sonsuz teşekkürlerimi sunarım. Onların varlığı, bu zorlu sürecin sonuca ermesini mümkün kılmıştır.

Beşaret KOÇAK

İÇİNDEKİLER

SİMGE LİSTESİ	viii
KISALTMALAR	x
ŞEKİL LİSTESİ	xi
TABLO LİSTESİ	xiii
ÖZET	xiv
ABSTRACT	xv
1 GİRİŞ	1
1.1 GPR Tarihi	2
1.1.1 1950-1980: İlk Dönemler.....	2
1.1.2 1980-1995: Uygulamaların Geliştirilmesi	2
1.1.3 1995- Günümüz: Dijital İşleme ve İleri Analiz	2
1.2 GPR Temelleri	3
1.2.1 Maxvell Denklemi	3
1.2.2 Malzemelerin Elektromanyetik Alanlara Tepkisi	4
1.3 Çalışma Prensibi	5
1.4 GPR Donanımı (Hardware)	6
1.4.1 Antenler	7
1.4.2 Kontrol Ünitesi	10
1.5 GPR Karakteristiği.....	10
1.5.1 Merkez Frekansı (Center Frequency)	11
1.5.2 Bant Genişliği (Bandwidth)	12
1.5.3 Çözünürlük (Resolution).....	13
1.5.4 Nüfuz Derinliği (Penetration Depth)	16
2 GPR VERİLERİNİN İŞLENMESİ	17
2.1 GPR Verisini Elde Etme.....	19
2.2 Gürültü Kaldırma	22
2.2.1 Filtreleme	23
2.2.2 Gabor Filtresi	28
2.2.3 Dalgacık Dönüşüm (Wavelet Transform)	29
2.2.4 Fourier Dönüşüm	30

2.3	Arka Plan Çıkarımı	32
2.3.1	Sabit Arka Plan Çıkarımı	33
2.3.2	Dinamik Arka Plan Çıkarımı	34
2.4	Eşikleme.....	35
2.5	İkili (Binary) Görüntülerde Filtreleme Yöntemleri	36
2.5.1	Morfolojik İşlemler.....	36
2.6	Öznitelik Çıkarımı	44
2.6.1	Kenar Tespiti (Edge Detection)	45
2.6.2	Parabol Uydurma	45
2.6.3	Nesne Alanına Yönelik Öznitelikler	46
2.6.4	Fourier Dönüşümünden Elde Edilen Öznitelik.....	46
2.7	Makine Öğrenmesi.....	47
2.7.1	Denetimli Öğrenme (Supervised Learning).....	48
2.7.2	Denetimsiz Öğrenme (Unsupervised Learning)	49
2.7.3	Pekiştirmeli Öğrenme (Reinforcement Learning)	50
2.7.4	Model Başarısı Değerlendirme Yöntemleri	51
2.7.5	Karar Ağaçları.....	55
2.7.6	Random Forest.....	57
2.7.7	K-Nearest Neighbors (K-NN).....	58
2.7.8	Support Vector Machine	61
2.8	Yapay Sinir Ağları.....	63
2.8.1	Derin Öğrenme	65
3	MATLAB ARAYÜZÜ	66
3.1	Matlab Appdesigner’da Görüntü İşleme ve Makine Öğrenmesi Uygulamaları	66
3.2	GPR verilerinin işlenmesi.....	67
4	GPR VERİLERİNİN İKİLİ VE ÇOKLU SINIFLANDIRMASI	76
4.1	İkili Sınıflandırmaya Yönelik GPR Verilerinin İşleme Süreci.....	77
4.2	Çoklu Sınıflandırmaya Yönelik GPR Verilerinin İşleme Süreci ...	80
5	DENEYSEL SONUÇLAR	87
5.1	İkili Sınıflandırmaya Yönelik Deneysel Sonuçlar	87
5.2	Çoklu Sınıflandırmaya Yönelik Deneysel Sonuçlar	88
6	SONUÇ	94

6.1	GPR Verilerinin İşlenmesi ve Öznitelik çıkarımı	94
6.2	İkili Sınıflandırma.....	94
6.3	Çoklu Sınıflandırma.....	95
6.4	Sınıflandırma Algoritmaların Performans Karşılaştırması	96
6.5	Sonuçların Değerlendirilmesi	96
KAYNAKÇA		97
TEZDEN ÜRETİLMİŞ YAYINLAR		109



SİMGE LİSTESİ

f_l	Alt kesim frekansı
$b(z)$	A-tarama arka plan sinyal tahmini
N	A-tarama sinyal uzunluğu
P	Arka plan hesaplama penceresi uzunluğu
M	B-tarama görüntüde bulunan A-tarama sinyal sayısı
B_z	B yapısal elemanının z konumunda kaydırılmasını ifade eder
B	Bant genişliği
R	Bant genişliği ile merkez frekans arasındaki oran
λ	Dalga boyu
Δt	Dalgaların yayılma süresindeki fark
Δr	Dikey çözünürlük
$\vec{E}$	Elektrik alan kuvveti vektörü
q	Elektrik yükü yoğunluğu
$\vec{J}$	Elektrik akımı yoğunluk vektörü
σ	Elektrik iletkenliği
q	Elektrik yükü yoğunluğu
$\ominus$	Erozyon işlemi
$G(x, y)$	Filtre çekirdeğinde bulunan her bir eleman
$f(i, j)$	Filtre fonksiyonu
σ	Gauss fonksiyonunun standart sapması
$\oplus$	Genişleme işlemi
$h(i, j)$	Girdi görüntüsü
c	Işık hızı
K	İlişkilendirilecek A-tarama sinyallerinin sayısı

$\bar{B}$	Manyetik akı yoğunluk vektörü
H	Manyetik alan yoğunluğu
μ	Manyetik geçirgenlik
f_c	Merkez frekansı
b_k	Pay katsayıları
a_k	Payda katsayıları
$H(z)$	Sistem transfer fonksiyonu
$\hat{y}_i$	Tahmin edilen değer
f_h	Üst kesim frekansı
γ	Uzaysal en boy oranı
$H(D)$	Veri kümesinin entropisi
W	Verici darbesinin genişliği
$a_x(z)$	x pozisyonunda ham A-tarama sinyali
$s_x(z)$	x pozisyonunda ham A-tarama hedef sinyali tahmini
Δl	Yanal çözünürlük
θ	Yönlülük
z^{-n}	Z-domain gecikme terimleri

KISALTMALAR

AP	Anti-Personel
AT	Anti-Tank
BMS	Arka Plan Matris Çıkarımı (Background Matrix Subtraction)
CART	Classification And Regression Trees
CNNs	Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
EM	Elektromanyetik
FIR	Finite Impulse Response
FN	Yanlış Negatifler (False Negatives)
FP	Yanlış Pozitifler (False Positives)
GPR	Yere Nüfuz Eden Radar (Ground Penetration Radar)
GUI	Kullanıcı Dostu Grafiksel Arayüzü (Graphical User Interface)
ICA	Bağımsız Bileşen Analizi (Independent Component Analysis)
IIR	Infinite Impulse Response
K-NN	K-Nearest Neighbors
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MAPE	Ortalama Yüzde Hata (Mean Absolute Percentage Error)
MSE	Ortalama Kare Hatası (Mean Squared Error)
NLP	Doğal Dil İşleme (Natural Language Processing)
PCA	Temel Bileşen Analizi (Principal Component Analysis)
RMSE	Karekök Ortalama Kare Hatası (Root Mean Squared Error)
RNNs	Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
SVM	Destek Vektör Makineleri (Support Vector Machines)
t-SEN	T-Dağılımlı Stokastik Komşu Yerleştirme
TN	Doğru Negatifler (True Negatives)
TP	Doğru Pozitifler (True Positives)

ŞEKİL LİSTESİ

Şekil 1.1	GPR donanım Mimarisi.....	7
Şekil 1.2	GPR Antenlerinde Mevcut Elektromanyetik Sinyallerin Yayılması ve Etkileşimleri.....	9
Şekil 1.3	GPR antenleri ile kalkanlar arasındaki elektromanyetik etkileşimler. ..	9
Şekil 1.4	GPR sisteminde dikey çözünürlük	14
Şekil 1.5	GPR sisteminde yanlamasına çözünürlük	15
Şekil 2.1	GPRVAT veri işleme genel görünümü.....	18
Şekil 2.2	Robotik tarama sistemi ve veri toplama senaryosu	19
Şekil 2.3	GPR B-tarama görüntüsündeki A-tarama verilerini gösteren sayfa (GPRVAT Arayüzü).....	21
Şekil 2.4	GPR veri toplama senaryosu	22
Şekil 2.5	A-tarama verisine bant geçiren filtre uygulaması	24
Şekil 2.6	Bant geçiren filtrenin GPR verisi üzerindeki etkisi.....	25
Şekil 2.7	Yatay bant geçiren filtre uygulaması	25
Şekil 2.8	GPRVAT uygulamasında yatay bant geçiren filtre analiz penceresi	26
Şekil 2.9	Yatay bant geçiren filtrenin GPR verisi üzerindeki etkisi	27
Şekil 2.10	Gabor filtresinin GPR görüntüsüne uygulanması	29
Şekil 2.11	GPR arka plan çıkarma senaryosu.....	33
Şekil 2.12	GPR sabit arka plan çıkarımı.....	34
Şekil 2.13	GPR dinamik arka plan çıkarımı	34
Şekil 2.14	İkili GPR B-tarama verileri	36
Şekil 2.15	Temel yapısal elementler	37
Şekil 2.16	İkili GPR B-tarama verilerine erozyon işlemi uygulanması	38
Şekil 2.17	İkili görüntüye iskeletleştirme uygulama örneği.....	39
Şekil 2.18	Konvolüsyon matrisleri	40
Şekil 2.19	3x3 filtre boyutunda ortalama filtresi uygulanması	41
Şekil 2.20	GPR verilerine ortalama (mean) filtresi uygulanması.....	41
Şekil 2.21	3x3 filtre boyutunda medyan filtresi uygulanması.....	42
Şekil 2.22	GPR verilerine medyan (median) filtresi uygulanması.....	43
Şekil 2.23	GPR verilerine Gauss filtresi uygulanması	44
Şekil 2.24	GPR görüntüsüne parabol uydurma	46
Şekil 2.25	Fourier dönüşümünden elde edilen öznelik	47
Şekil 2.26	Makine öğrenmesi denetimli öğrenme modeli.....	49
Şekil 2.27	Makine öğrenmesi denetimsiz öğrenme modeli.....	50
Şekil 2.28	Makine öğrenmesi yaparken eğitim aşamasında aşırı öğrenmeye başlama noktası.....	55
Şekil 2.29	Karar ağaçları genel yapısı	56
Şekil 2.30	Random Forest algoritması yapısı	58
Şekil 2.31	K-NN sınıflandırma algoritması yeni değer sınıf seçme işlemi	59
Şekil 2.32	K-NN mesafe ölçüt yöntemleri	60

Şekil 2.33	Support Vector Machine	62
Şekil 2.34	Biyolojik Sinir Hücre Yapısı	63
Şekil 2.35	Yapay Sinir Hücresi.....	64
Şekil 2.36	Yapay sinir ağları katmanları.....	64
Şekil 3.1	GPRVAT arayüzü ana sayfası	68
Şekil 3.2	GPRVAT arayüzünün GPR analiz sayfaları.....	72
Şekil 3.3	GPRVAT arayüzünün görüntü bölütleme sayfaları	75
Şekil 4.1	GPR verilerini sınıflandırmaya yönelik temel adımlar	77
Şekil 4.2	İkili Sınıflandırmada arka plan çıkarımı	78
Şekil 4.3	Çoklu sınıflandırmada kullanılan örnek GPR görüntüleri	82



TABLO LİSTESİ

Tablo 4.1 İkili sınıflandırma 1080 veri seti	78
Tablo 4.2 İkili sınıflandırma 520 seri seti	78
Tablo 4.3 İkili sınıflandırma yöntem-6'da Gabor filtresi parametreleri.....	79
Tablo 4.4 İkili sınıflandırmada veri işleme süreçleri ve öznitelik çıkarma yöntemleri	80
Tablo 4.5 Çoklu sınıflandırma aşamasında kullanılan Veri setinin içeriği.....	81
Tablo 4.6 Çoklu sınıflandırma veri işleme adımları ve öznitelik çıkarma yöntemleri	83
Tablo 4.7 Çoklu sınıflandırma Öznitelik kümesi	83
Tablo 5.1 İkili sınıflandırmada 520 veri seti için performans değerleri.....	87
Tablo 5.2 İkili sınıflandırmada 1080 veri seti için performans değerleri.....	88
Tablo 5.3 Çoklu sınıflandırmada 1040 veri seti için performans değerleri.....	89
Tablo 5.4 Çoklu sınıflandırma En iyi Öznitelik Kümesi.....	90
Tablo 5.5 SVM algoritması için en iyi yöntemin (çoklu-28) sınıf bazlı performans değerleri	91
Tablo 5.6 SVM algoritması için en iyi yöntemin (çoklu-28) sınıf bazlı ortalama performans değerleri	91
Tablo 5.7 KNN algoritması için en iyi yöntemin (çoklu-28) sınıf bazlı performans değerleri	92
Tablo 5.8 KNN algoritması için en iyi yöntemin (çoklu-28) sınıf bazlı ortalama performans değerleri	92
Tablo 5.9 Random Forest algoritması için en iyi yöntemin (çoklu-5) sınıf bazlı performans değerleri	92
Tablo 5.10 Random Forest algoritması için en iyi yöntemin (çoklu-5) sınıf bazlı ortalama performans değerleri	93

YERE NÜFUZ EDEN RADAR VERİLERİNDE ÖZNİTELİK ÇIKARIMI VE SINIFLANDIRILMASI

Beşaret KOÇAK

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

Yüksek Lisans

Danışman: Prof. Dr. Aydın YEŞİLDİREK

Eş-Danışman: Prof. Dr. Mehmet Sezgin

Bu tez çalışmasında, yeraltı görüntüleme teknolojilerinden biri olan GPR kullanılarak, taklit mayın ve diğer gömülü nesnelerin ikili ve çoklu sınıflandırılması üzerine bir çalışma gerçekleştirilmiştir. Çalışma, GPR verilerinin işlenmesi, öznitelik çıkarımı ve sınıflandırma aşamalarını içermektedir. GPR verilerinin işlenmesinde; gürültü azaltma, arka plan çıkarımı, bölütleme ve çeşitli filtreleme teknikleri gibi yöntemler kullanılmıştır. Bu işlemler, GPR verilerinin daha temiz ve analiz edilebilir hale getirilmesini sağlamıştır. Öznitelik çıkarımı aşamasında; Fourier dönüşümü, parabol uydurma, nesne alanına yönelik öznitelikler, ikili GPR görüntüsündeki beyaz bölge alanları, beyaz bölge ortalamaları ve beyaz bölge momentleri gibi özellikler elde edilmiştir.

Tez kapsamında, MATLAB AppDesigner kullanılarak GPRVAT (GPR Visual Analysis Tool) isimli bir arayüz geliştirilmiştir. Bu arayüz, veri işleme ve sınıflandırma sürecini kolaylaştırmış ve sistematik bir şekilde gerçekleştirilmesini sağlamıştır. Gerçek GPR verileri üzerinde yapılan deneyler, ikili ve çoklu sınıflandırmada yüksek başarı oranları elde edildiğini göstermiştir.

DeneySEL sonuçlar, GPR verilerinin doğru bir şekilde işlenmesinin ve öznitelik çıkarımı süreçlerinin optimize edilmesinin, sınıflandırma performansını önemli ölçüde artırdığını göstermiştir. İkili sınıflandırma ile mayın diğer cisimlerden ayırıtılırken, çoklu sınıflandırma ile farklı gömülü nesne türleri başarıyla sınıflandırılmıştır.

Anahtar Sözcükler: Yere Nüfuz Eden Radar, görüntü işleme arka plan çıkarımı, özellik çıkarımı, sınıflandırma

FEATURE EXTRACTION AND CLASSIFICATION OF GROUND PENETRATION RADAR DATA

Beşaret KOÇAK

Department of Mechatronic Engineers

Master of Science Thesis

Supervisor: Prof. Dr. Aydın YEŞİLDİREK

Co-supervisor: Prof. Dr. Mehmet SEZGİN

In this thesis, a study was conducted on the dual-class and multiclass classification of surrogate mines and other buried objects using GPR, one of the subsurface imaging technologies. The study encompasses the stages of GPR data processing, feature extraction, and classification. For GPR data processing, methods such as noise reduction, background removal, segmentation, and various filtering techniques were utilized. These processes enhanced the clarity and analyzability of the GPR data. During the feature extraction phase, characteristics such as Fourier transform features, parabolic fitting, object area features, white region areas in binary GPR images, white region averages, and white region moments were derived.

As part of the thesis, an interface named GPRVAT (GPR Visual Analysis Tool) was developed using MATLAB AppDesigner. This tool facilitated the systematic execution of the data processing and classification workflow, making the entire process more efficient. Experiments conducted on real GPR data demonstrated high success rates in both dual-class and multiclass classification tasks.

The experimental results revealed that accurately processing GPR data and optimizing feature extraction processes significantly enhance classification performance. While dual-class classification successfully detected the presence of mines, multiclass classification effectively differentiated between various types of buried objects.

Keywords: Ground Penetrating Radar, image processing, background removal, feature extraction, classification

1

GİRİŞ

Toprak altı, insanlık için hala birçok sırrı barındıran gizemli bir alan olarak kalmaya devam etmektedir. Ancak modern teknoloji, bu gizemli katmanları ortaya çıkarmak için güçlü araçlar sunuyor. Bu alanda kullanılan araçlardan biri de Ground Penetrating Radar (GPR) olarak bilinen yeraltı görüntüleme radarıdır. Gömülü cisim tespiti günümüzün önemli sorunlarından olup pek çok uygulama alanlarında ihtiyaç duyulmaktadır [1]. Örneğin Arkeolojik kazılarda, inşaat denetimlerinde ve askeri alanlarda, vb. alanlarda ihtiyaç duyulmaktadır. Gömülü cisim tespitinde birçok teknik kullanılmaktadır. Bu tekniklere termografi, elektromanyetik yöntemler (Ground Penetrating Radar, vb.) örnek olarak verebiliriz [2]. GPR çıktılarının yorumlanması, diğer tekniklere kıyasla daha karmaşık olabilir. Ancak, geniş bir kullanım alanına sahip olması ve farklı türdeki materyalleri tespit edebilme yeteneği sayesinde, GPR birçok uygulamada tercih edilen bir algılama yöntemidir.

Bu tezin konusu, GPR ile elde edilen veriler kullanılarak gömülü cisimlerin ikili ve çoklu sınıflandırması yapılması üzerinedir. Mayın tespitinin temassız ve tahribatsız şekilde yapılması zorunluluktur. Bu zorunluluktan ötürü GPR ve metal dedektör gibi dedektörler kullanılmaktadır. Mayın tespitinde geleneksel olarak metal dedektörleri tercih edilse de bu dedektörler plastik mayınları veya derinde bulunup az metal içeren mayınları tespit edemez [2]. Son araştırmalara göre [3] dünyada hala 59 farklı alanda 110 milyon adet gömülü mayın bulunmakta olup, bu mayınlar dolayısıyla günde ortalama 20 insan ölmekte veya yaralanmaktadır. Dünya çapında 2022 yılı boyunca 152 kilometrekare alandan fazla mayınlı bölge temizlenmiş ve 157.000 anti-personel mayını imha edilmiş durumdadır [4]. Bu çalışmada, GPR'ın mayın tespiti ve teşhisinde kullanımı üzerinde çalışılacak, taklit mayınlı bölgelerden elde edilen veriler çeşitli ön işleme ve analiz teknikleri ile işlenerek, mayınların ikili ve çoklu sınıflandırılması gerçekleştirilecektir. Bu bölümde GPR'ı ve diğer bölümlerde yapılan çalışmaları daha iyi anlayabilmek için GPR'ın temellerinden, çalışma prensibinden ve kısaca tarihinden bahsedilecektir.

1.1 GPR Tarihi

GPR, düşük kayıplı dielektrik malzemeleri içeren herhangi bir ortamı incelemek amacıyla radyo dalgalarını kullanan bir jeofizik tekniği olarak günümüzde kabul gören bir yöntemdir. İlk olarak doğal jeolojik malzemelere uygulanan GPR, şu anda ahşap, beton ve asfalt gibi bir dizi diğer ortama da uygulanmaktadır. Yüksek kayıplı dielektrik malzeme ortamlarının varlığı, geniş radyo frekans spektrumu ile birleştiğinde, GPR için geniş bir uygulama yelpazesi sunar.

El Said'in [5] 1950'lerdeki çalışmaları sonuç vermeden önce, yeraltını radyo dalgalarıyla keşfetme fikri uzun bir süre boyunca teorik düzeyde tartışılıyordu. Waite'in [5] radar altimetreleriyle buz tabakalarından geri yansıyan sinyallerin tespiti, dünyanın çeşitli yerlerinde bu yöntemin daha geniş bir şekilde kullanılmasına yol açtı. İlk keşiflerin ardından, bu teknolojiye olan ilgi toprak ve kayaların sondajına yöneldi ve 1960'larda hız kazandı. Yere Nüfuz Eden Radarın (GPR) ilk günlerinden bu yana, uygulamaların sayısı hızla artarken, temel fizik ve malzeme özellikleri konusundaki anlayışımız da önemli ölçüde derinleşti [6]. GPR'ın yıllar içinde geçirdiği değişiklikler genel olarak üç önemli döneme ayrılabilir: 1950- 1980, 1980- 1995 ve 1995- günümüz.

1.1.1 1950-1980: İlk Dönemler

GPR, 1950'li yıllarda radyo dalgalarını kullanarak yer altı özelliklerini belirlemek için kullanılmaya başlandı. Bu dönemdeki öncü çalışmalar arasında, 1961'de Waite ve Schmidt'in Grönland buz tabakasında radar altimetrelerle elde ettiği başarı örnek verilebilir [6, 5]. Apollo programı [7], GPR çalışmalarını hızlandıran bir diğer önemli faktördü. Bu süreçte, GPR, geniş bir uygulama yelpazesine yönelik potansiyelini göstermeye başladı.

1.1.2 1980-1995: Uygulamaların Geliştirilmesi

1980'lerde taşınabilirlik ve dijital veri işlemedeki gelişmelerle birlikte GPR, çeşitli endüstrilerde uygulama alanı buldu. Jeoloji, çevre mühendisliği, arkeoloji ve inşaat gibi alanlarda daha geniş kabul gördü. Bu dönemde özellikle ekipman ağırlığı ve güç tüketimi konusunda karşılaşılan zorluklar, yeni teknolojilerin geliştirilmesi ihtiyacını ortaya çıkardı [6, 5, 8].

1.1.3 1995- Günümüz: Dijital İşleme ve İleri Analiz

Bilgisayar teknolojisinin gelişimi, GPR'ın 1995'ten günümüze kadar olan gelişimini hızlandırdı. 3D dijital modelleme, veri yönetimi ve işleme yeteneklerindeki artışlar, GPR'ın daha güçlü ve hassas olmasına olanak sağladı. Bu dönemde GPR, jeofizik ve mühendislik uygulamalarında vazgeçilmez bir araç haline geldi. Artan sayıda araştırmacı GPR'ın potansiyelini daha iyi anlamak ve etkili bir şekilde kullanmak için çalışıyor [6, 5].

Yere Nüfuz Eden Radarın (GPR), mayın tespiti alanında çok önemli bir teknoloji olduğu ve jeolojik uygulamaların ötesinde kullanım alanları olduğu kanıtlanmıştır. GPR'ın radyo dalgalarını kullanarak toprağa nüfuz etme yeteneği, onu gömülü

mayınların ve patlayıcı maddelerin tanımlanmasında değerli bir araç olarak konumlandırmıştır. GPR'ın 1950'lerdeki ilk günlerinden günümüze kadar uzanan tarihsel evrimi, onun sürekli iyileştirilmesini ve farklı amaçlara uyarlanmasını yansıtmaktadır. Özellikle 1990'ların ortasından bu yana dijital işleme ve gelişmiş veri analizi tekniklerindeki gelişmeler, GPR'ın yeteneklerini önemli ölçüde geliştirmiş ve onu mayın temizleme operasyonlarında vazgeçilmez bir unsur haline getirmiştir. Teknoloji ilerlemeye devam ettikçe GPR, mayın tespitinin doğruluğunu ve verimliliğini daha da artırma ve kara mayınlarından etkilenen bölgelerde daha güvenli ortamlar oluşturma hedefine katkıda bulunma konusunda umut vaat etmektedir.

1.2 GPR Temelleri

Ground Penetrating Radar bir tahribatsız görüntüleme teknikliğidir. GPR'ın çalışma prensibi Maxwell denklemlerini kullanan elektromanyetik alan (EM) teorisine dayanmaktadır [9]. Maxwell denklemleri [10], elektromanyetik alanlarının fiziğini matematiksel olarak tanımlarken, malzemelerin elektriksel ve manyetik özelliklerini tanımlayan matematiksel ifadeler, bu özellikleri sayısal olarak belirlemeye olanak tanır. Bu iki yaklaşımın bir araya gelmesi, GPR sinyallerinin malzemelerle etkileşimlerini ve yer altı özelliklerini niceliksel olarak tanımlamak için temel oluşturur [5].

1.2.1 Maxwell Denklemi

Maxwell denklemleri matematiksel olarak aşağıdaki gibi tanımlanmaktadır [10].

$$\nabla \times \vec{E} = - \frac{\partial \vec{B}}{\partial t} \quad (1.1)$$

$$\nabla \times \vec{H} = \vec{J} + \frac{\partial \vec{D}}{\partial t} \quad (1.2)$$

$$\nabla \cdot \vec{D} = q \quad (1.3)$$

$$\nabla \cdot \vec{B} = 0 \quad (1.4)$$

Buradaki denklemlerde bulunan değişkenler şu şekilde tanımlanmıştır.

$\vec{E}$ - Elektrik alan kuvveti vektörü. [V/m].

q - Elektrik yükü yoğunluğu [C/m^3].

$\vec{B}$ - Manyetik akı yoğunluk vektörü [T].

$\vec{J}$ - Elektrik akımı yoğunluk vektörü [A/m^2].

$\vec{D}$ - Elektrik yer değiştirme vektörü [C/m^2].

$\vec{H}$ - Manyetik alan yoğunluğu [A/m].

Maxwell'in bu denklem kümesi ile tüm elektromanyetik olayları (indüksiyon, radyo dalgaları, devre teorisi vb.) ifade edebilmek ve malzemenin elektriksel özelliklerini karakterize edebilmek için kullanılabilir [6].

1.2.2 Malzemelerin Elektromanyetik Alanlara Tepkisi

Malzemelerin elektromanyetik (EM) alanlara tepkisi, o malzemenin fiziksel özelliklerini ölçmenin bir yoludur [10]. Diğer bir deyişle, malzemenin elektromanyetik alanına tepkisi, onun özelliklerini tanımlar [6]. Hem EM hem de GPR için elektriksel ve manyetik özellikler önemlidir, zira elektronların, atomların ve moleküllerin bir EM alanına nasıl tepki verdikleri o malzemeyi karakterize etmektedir.

GPR için üç yapısal denklem tanımlanmıştır [6, 10]:

Elektrik iletkenliği $\tilde{\sigma}$, bir elektriksel alan oluştuğunda serbest yük hareketini karakterize eder. Şarj akışına direnç enerji kaybına yol açar.

$$\vec{J} = \tilde{\sigma} \vec{E} \quad (1.5)$$

Dielektrik geçirgenlik $\tilde{\epsilon}$, bir elektrik alanına yanıt olarak malzeme yapısında sınırlandırılmış yükün elektrik alanına doğru hareket etmesini karakterize eder. Yükün yer değiştirmesi, malzemede enerji depolanmasıyla sonuçlanır.

$$\vec{D} = \tilde{\epsilon} \vec{E} \quad (1.6)$$

Manyetik geçirgenlik $\tilde{\mu}$, atomik ve moleküler manyetik momentlerin manyetik alana nasıl tepki verdiğini tanımlar. Basit malzemeler için, içsel manyetik momentlerin bozulması, malzemede enerji depolar.

$$\vec{B} = \tilde{\mu} \vec{H} \quad (1.7)$$

Yere Nüfuz Eden Radar (GPR) uygulamaları tipik olarak dielektrik geçirgenlik ($\tilde{\epsilon}$) ve elektrik iletkenliği ($\tilde{\sigma}$) değişikliklerine karşı daha yüksek hassasiyet sergilerken, manyetik geçirgenlik ($\tilde{\mu}$) değişikliklerine nispeten daha düşük hassasiyet gösterir [11, 12, 13]. GPR'ın en iyi performansının düşük elektrik kaybı olan malzemelerde gözlemlendiği ortaya konmuştur. İdeal olarak, eğer bağıl geçirgenlik (ϵ) sıfıra eşitse, GPR derinliklere nüfuz ederek yaygın uygulanabilirlik sunacaktır. Ancak pratik senaryolar nadiren düşük elektrik kaybı koşullarını içerir. Kıl açısından zengin bileşimlere veya yeraltı suyunda yüksek tuzluluğa sahip bölgeler, GPR sinyal penetrasyonunu kısıtlayan zorluklar oluşturmaktadır.

Toprak içeriği çeşitli bileşenlerden oluşan karmaşık kompozitlerdir. Su ve buz, tek bir bileşenin hâkim olduğu durumları oluşturan istisnalardır. Örneğin, temel bir plaj kumu toprak taneleri, hava, su ve çözünmüş iyonlardan oluşur ve toprak taneleri

tipik olarak toplam hacmin %60-80'ini oluşturur. Bu tür karışımların fiziksel özelliklerinin kapsamlı olarak anlaşılması, GPR yanıtlarının doğru şekilde yorumlanması için çok önemlidir.

1.3 Çalışma Prensibi

Ground Penetrating Radar, elektromanyetik dalgalar kullanarak yeryüzündeki veya yapı içindeki nesnelerin detaylı bir şekilde görüntülenmesini sağlayan bir görüntüleme tekniğidir [10]. GPR'ın çalışma prensibi, yüzeyden yollanan elektromanyetik dalgaların nesnelerle etkileşip geri dönmesine dayanır.

GPR, ultra geniş bantlı radarın bir örneğidir ve geleneksel radarlarla benzer şekilde çalışır ancak bazı önemli farklılıkları vardır [14, 15]. Birincisi geleneksel radarların çalışma alanı 10 veya 100'lerce kilometre olabilirken tipik bir GPR'ın çalışma alanı en çok metreler civarındadır. İkinci farklılık GPR'ın çözünürlüğü, geleneksel radarlara göre daha yüksektir. Yani geleneksel radarların çözünürlüğü metrelerle ifade edilirken GPR'ın çözünürlüğü milimetrelerle ifade edilebilmektedir.

Yere nüfuz eden radar (GPR), yer altı malzemeleri ve yapıları keşfetmek için kullanılan bir jeofizik yöntemidir. Bu bağlamda elektriksel iletkenlik ve geçirgenlik kritik elektriksel özellikler arasında yer alır. Geçirgenlik yeteneği özellikle, yüksek frekansta herhangi bir maddenin dielektrik gibi davranmasını belirleyen önemli bir rol oynar. Bir GPR sistemi verici (transmitter), alıcı (receiver) antenler, control ünitesi ve gösterge panelinden oluşmaktadır. Verici anten, elektromanyetik enerji darbelerini yere veya incelenen yapıya gönderir. Dalgalar, farklı malzemelerle etkileşime girerken malzeme sınırlarında dielektrik sabitindeki değişiklikler nedeniyle hızda farklılıklar oluşur. Bu değişiklikler, alıcı anten tarafından toplanır ve dalgaların bir kısmı, materyalin geçirgenliğine bağlı olarak ilerlemeye devam eder. Elektromanyetik dalganın gönderme ve geri gelme süreleri arasındaki zaman farkı ise materyalin konumu ve derinliği hakkında bilgi verir [6, 16, 12]. GPR sistemleri 10 MHz ile 2.6 GHz arasındaki frekanslar aralığında çalışabilmektedir [17]. GPR'ın çalışma frekansı, uygulama amacına ve kullanılacak olan ortama bağlı olarak değişebilir. GPR sistemleri genellikle düşük frekanstan yüksek frekansa kadar çeşitli frekanslarda çalışabilir. Frekans seçimi, derinlik çözünürlüğü ve yüksek çözünürlüklü detay elde etme yeteneği üzerinde etkilidir. Düşük frekanslar (genellikle 100 MHz altı), daha derin penetrasyon sağlar, ancak bu durumda çözünürlük düşer. Yüksek frekanslar (genellikle 1 GHz ve üstü), daha yüksek çözünürlük sağlar, ancak penetrasyon derinliği azalır. Dolayısıyla, uygulamanın gereksinimlerine bağlı olarak uygun frekans seviyesi seçilir. Örneğin, altyapı taramalarında daha yüksek frekanslar, yapı içindeki küçük detayları belirlemek için daha uygun olabilirken, arkeolojik kazılarda veya yer altı su kaynaklarının belirlenmesinde daha derin penetrasyon sağlayan düşük frekanslar tercih edilebilir.

1.3.1.1 Yayılma Hızı (Velocity)

GPR yayılma hızı, elektromanyetik dalgaların ortamda ilerleme hızını ifade eder. Bu hız, ortamın özelliklerine ve elektromanyetik dalga frekansına bağlı olarak değişiklik gösterir.

Elektromanyetik dalgaların yayılma hızı, ortamın dielektrik geçirgenliğine (ϵ) bağlıdır. Dielektrik geçirgenliğin göreceli değeri, elektromanyetik dalga yayılma hızını belirler. Bu faktör, serbest uzaydaki ışık hızına göre bir oran oluşturur. Dolayısıyla, GPR verisi toplanırken, ortamın dielektrik özelliği olan geçirgenliğin (permittivity) değeri, yayılma hızını belirlemede kritik öneme sahiptir. Yayılma hızı, aşağıdaki denklemle ifade edilir [12, 18, 19]:

$$v = \frac{c}{\sqrt{\epsilon_r}} \quad (1.8)$$

Denklemdeki değişkenler şu şekilde tanımlanmıştır:


v - Elektromanyetik dalga'nın ortamda yayılma hızı

c - Serbest uzaydaki ışık hızı

ϵ_r - Ortamın göreceli dielektrik geçirgenliği

1.4 GPR Donanımı (Hardware)

GPR'ın çalışma prensibini daha iyi anlamak için, sistemin ana bileşenlerini incelemek gerekir. Bir GPR sistemi genellikle iki anten, bir verici modül (transmitter), bir alıcı modül (receiver), bir kontrol ünitesi ve bir ekran/arayüz/veri depolama biriminden oluşur [18, 19, 20]. Şekil 1.1'de GPR'ı oluşturan bileşenlerin bağlantısı görülmektedir. Genellikle, GPR sistemleri bu bileşenler arasında elektriksel ve veri iletişimi sağlamak için kablolar kullanır ancak bazı durumlarda optik kablolar da kullanılabilir [13]. Bu, elektriksel/elektromanyetik sorunlardan izolasyon sağlar ve sistemin güvenilirliğini artırır. Ayrıca, antenler genellikle ilgili modüllere gömülüdür, bu da taşınabilirlik ve kullanım kolaylığı sağlar ve sistem performansını iyileştirir. Bu bileşenlerin bir araya gelmesi, GPR'ın etkin ve hassas bir şekilde çalışmasını sağlar ve yeraltı yapılarını görüntülemek için kullanılabilir veriler sağlar.



Şekil 1.1 GPR donanım Mimarisi

1.4.1 Antenler


GPR’da kullanılan antenler, elektromanyetik dalgaları yaymak ve almak için kullanılır. Tipik olarak, biri verici (transmitter) olarak diğeri alıcı (receiver) olarak kullanılan iki anten bulunur. Antenler genellikle yüksek frekanslı elektromanyetik dalgalarla çalışır ve çoğu zaman yeraltındaki hedeflerin algılanması için uygun frekans aralıklarında tasarlanır.

Antenler, GPR sistemi tasarımcılarına bazı önemli kısıtlamalar getirmektedir [18]. Bu kısıtlamaların başında kullanılabilecek anten türleri gelir. Antenden çıkan sinyallerin yayılması esnasında genellikle kayıplı ve homojen olmayan bir dielektrik bulunur [18, 21]. Bu dielektrik, bazen anizotropik [22] olabilmektedir. Yani bu anizotropik antenin farklı yönlere göre tepki vermesidir. Örneğin, bir antenin bir yönde daha fazla yönlendirme yeteneğine sahip olması, diğere yönler göre daha güçlü bir sinyal alması veya iletimi sağlayabilir. Bu durum, antenin anizotropik özellik gösterdiğini gösterir. Dielektrik anten [18, 21], anizotropik olmasının yanı sıra frekans bağımlı bir zayıflama sergiler ve dolayısıyla alçak geçiren (lowpass) bir filtre görevi görür [18]. Sistemin işletim üst frekansı ve dolayısıyla antenin üst frekansı, malzemenin özellikleri tarafından sınırlanır. Yüksek bir menzil çözünürlüğü elde etme ihtiyacı, antenin ultra geniş bant göstermesini gerektirir ve darbe radar sistemlerinde doğrusal faz cevabı gereklidir. Geniş bant gereksinimi ile üst frekans sınırlamaları karşılıklı olarak çatıştığından, genellikle belirli bir frekans aralığında (10 MHz ile 5 GHz arası) antenlerin tasarımı

için bir denge sağlanır [18, 19, 23]. Operatörün taşınabilirlik gereksinimi, genellikle elektriksel olarak küçük antenlerin kullanılmasını gerektirir. Bu da genellikle düşük kazanç ve bununla ilişkili olarak geniş kutuplu radyasyon (wide radiation pattern) desenlerine neden olur [18, 23]. Kullanılabilecek antenlerin sınırlı olması nedeniyle uygun bir tasarımın seçiminde [18] geniş frekans aralığında çalışma kapasitesi, minimum sinyal bozunumu ve gönderme ile alıcı antenlerinin ayrı olduğu durumlarda düşük çapraz etkileşim seviyeleri gibi faktörler dikkate alınmalıdır. Ayrıca, antenin çevresindeki reaktif alanın dielektrik malzemelerle etkileşimi, antenin performansını etkileyen önemli bir unsurdur. Bu etkileşim, antenin verimliliği, polarizasyon özellikleri ve frekans tepkisi üzerinde belirleyici bir rol oynayabilir. GPR antenleri genellikle elektriksel olarak küçük olmak zorunda olduğundan, etkili bir performans için tasarım sürecinde dikkatli bir denge sağlanmalıdır [18].


Anten tasarımında dikkate alınması gereken diğer faktörler arasında çevresel koşullara dayanıklılık, üretim maliyetleri ve mevcut altyapı gibi konular da bulunmaktadır. Sonuç olarak, GPR antenlerinin tasarımı, geniş bir teknik ve mühendislik bilgisini gerektirmektedir. Dolayısıyla çeşitli faktörlerin dikkatlice dengelenmesini gerektirir. Bu denge, istenen performans özellikleriyle uyumlu bir şekilde elde edilmelidir; ancak aynı zamanda pratik uygulama gereksinimlerini de karşılamalıdır.

Tasarım için bir diğer önemli nokta da anten tasarımının kalkanlama (shielding) özelliğidir [12, 13]. Kalkanlamanın temel amacı, GPR sinyallerinin ortamdaki iletilmesini maksimum seviyede artırmak ve tüm diğer elektromanyetik sinyalleri bastırmak/minimize etmektir [10, 12, 13, 23]. Bu; doğrudan verici ve alıcı arasındaki EM dalgalar, EM dalgalarının havaya dağılması ve dışarıdan gelen parazit sinyalleri gibi diğer elektromanyetik sinyalleri içerir [10, 12]. Şekil 1.2’de bulunan diyagramda GPR uygulamalarında mevcut olan EM sinyalleri gösterilmektedir. Bu veriye dayanarak, GPR uygulamalarında EM sinyallerinin etkili bir şekilde yönetilmesi gerektiği anlaşılır. Kalkanlama, istenmeyen sinyallerin bastırılmasına yardımcı olurken, istenilen sinyallerin iletimini sağlayarak GPR sisteminin performansını artırır. Ayrıca, kalkanlama aynı zamanda dış etkenlerden kaynaklanan girişimlerin önlenmesine de katkıda bulunur. Bu durumda da daha güvenilir ve doğru sonuçlar elde etmeyi sağlar. Elde edilen bilgi, GPR sistemlerinin tasarımında ve uygulanmasında kalkanlamanın önemini vurgular. Böylece daha etkili ve güvenilir bir sistem elde edilmesine yardımcı olur [10, 12, 13].



Şekil 1.2 GPR Antenlerinde Mevcut Elektromanyetik Sinyallerin Yayılması ve Etkileşimleri

Kalkanlama avantajlarına rağmen, GPR sistemlerini daha hacimli, daha ağır ve daha pahalı hale getirir [10, 12, 13, 24]. Ayrıca, kalkanlamanın istenmeyen sinyalleri bastırmak için etkili olabilmesi için, kalkanın elektromanyetik bir yanıt olmalıdır [10, 12]. Bu nedenle, verici anten EM dalgalarını yaydıkça, kalkanlar elektromanyetik enerjinin bir kısmını emerek ve yayarak kısmen emer. Genellikle, kalkanlar tarafından üretilen sinyaller güçlü ve uzun olduğundan, sistemdeki artık tepkiyi, yani ring-down'u artırır [10, 12]. Bu sinyaller şekil 1.3'te gösterilmektedir. Noktalı çizgiler, kalkan tarafından üretilen sinyalleri, düz çizgiler ise verici anten tarafından üretilen elektromanyetik dalgaları temsil eder. Bu sinyaller genellikle kalkanlanmış antenlerde verici ve alıcının aynı konteynerde bulunması nedeniyle, GPR sisteminin esnekliğini azaltır.



Şekil 1.3 GPR antenleri ile kalkanlar arasındaki elektromanyetik etkileşimler.

Kalkanlanmamış antenler ise kapalı değildir, bu nedenle çevresel girişim sinyallerine ve çevreden istenmeyen veri taramasına maruz kalma eğilimindedir [12, 13]. Bunlar genellikle düşük frekanslı işlemler için kullanılır, burada uygun antenler daha büyük ve daha ağırdır ve sistemlerin boyutu ve ağırlığı en büyük öneme sahiptir [10, 12, 24].

1.4.2 Kontrol Ünitesi

GPR sisteminin bir parçası olan kontrol ünitesi, kullanıcıların veri toplama sürecini yöneten ve radarın çalışma parametrelerini ayarlayan birimdir. Kontrol ünitesi verici ve alıcı modüllerine komutlar gönderir, gelen sinyalleri işler, verileri değerlendirir ve sonuçları görüntüler veya depolar [12, 9]. Genellikle bir ekran, kontrol düğmeleri ve veri toplama işlemlerini gerçekleştiren bir bilgisayar arayüzü içerir. Kontrol ünitesi, toplanan verileri kaydederek gerektiğinde gerçek zamanlı olarak görselleştirerek kullanıcıların yer altındaki nesnelerin konumunu analiz etmelerini sağlar [10, 20, 9]. Ayrıca, kullanıcı arayüzüyle etkileşim sağlar ve sistemin çalışma parametrelerini ayarlamak için gereken kontrolü yapar.

1.5 GPR Karakteristiği

Ground penetrating radar bazı spesifik özelliklere sahiptir. GPR'nin karakteristik özellikleri bu teknolojinin kullanım alanlarını, performansını ve sınırlamalarını belirleyen önemli faktörlerdir. GPR'ı tanımlayan parametreler şunlardır. Merkez frekansı (center frequency), bant genişliği (bandwidth), çözünürlük (resolution) ve Nüfuz derinliğidir (penetration depth). Bu özellikler, özellikle impulse GPR sistemlerinin performansını şekillendiren temel unsurlardır.

GPR sistemleri, farklı uygulama gereksinimlerine uygun olarak çeşitli yöntemlerle çalışabilir. Bunlardan en yaygın ve etkili olanı impulse GPR'dır, ancak farklı ihtiyaçları karşılamak üzere geliştirilmiş diğer yöntemler de bulunmaktadır:

Impulse GPR (Darbe GPR) [19, 18], kısa süreli yüksek enerjili elektromanyetik darbeler göndererek çalışır. Bu darbeler yer altına iletilir ve dielektriği farklı olan malzeme sınırlarından geri yansır. Geniş bant genişliği sayesinde hem yüzey hem de derinlerden detaylı bilgi elde etmek için oldukça uygundur.

Step-frequency GPR [25], sinyalleri belirli bir frekans aralığında adım adım göndererek çalışır. Her bir frekansta alınan sinyaller birleştirilir ve geniş bantlı bir veri seti oluşturulur. Bu yöntem, yüksek çözünürlük ve nüfuz derinliği gerektiren uygulamalarda tercih edilir.

Sürekli dalga GPR (Continuous wave GPR), sürekli olarak elektromanyetik sinyal gönderir ve alınan sinyallerin faz ve genlik değişimlerini analiz eder. Bu yöntem genellikle düşük derinliklerde detaylı inceleme yapmak için uygundur.

GPR teknolojisi, ihtiyaçlara uygun olarak farklı yöntemler sunar. Özellikle impulse GPR, geniş bant genişliği ve hassasiyeti sayesinde birçok uygulamada öne çıkan bir yöntemdir. Ancak, diğer yöntemler de farklı gereksinimleri karşılamak için özelleştirilmiştir. Bu çeşitlilik, GPR sistemlerinin kullanım alanlarını genişleten önemli bir avantajdır.

1.5.1 Merkez Frekansı (Center Frequency)

Merkez frekansı, yere nüfuz eden radar (GPR) gibi elektromanyetik dalga tabanlı sistemlerde önemli bir parametredir [10, 12, 18, 26, 27]. Bu frekans, kullanılan antenin çalışma frekans aralığının orta noktasını temsil eder. Merkez frekansı, GPR'ın performansını ve uygulama alanlarını etkileyen birkaç önemli faktörü içerir.

Derinlik ve çözünürlük: Merkez frekansı, GPR'ın çalışma derinliği ile doğrudan ilişkilidir. Daha yüksek merkez frekansları, daha sıkı derinliklerde daha iyi çözünürlük sağlarken, daha düşük frekanslar daha derin penetrasyon sağlar ancak çözünürlük düşer [10, 26].

Hassasiyet (Sensitivity): Merkez frekansı, GPR'ın hassasiyetini etkiler. Belirli bir malzemenin algılanması, kullanılan merkez frekansına ve malzemenin dielektrik özelliklerine bağlı olabilir.

Arazi Türü ve Uygulama: Merkez frekansı, her arazi türü veya uygulama için en uygun GPR frekansını belirler [26]. Örneğin, arkeolojik keşiflerde veya yapısal değerlendirmelerde farklı frekanslar gerekebilir.

Veri İşleme ve Analiz: Merkez frekansı, toplanan verilerin işlenmesi ve yorumlanması için önemlidir. Farklı frekanslarda elde edilen verilerin analizi, yer altı yapıların doğru bir şekilde haritalanması için kritik öneme sahiptir.

GPR'da kullanılacak anteni seçerken antenin çalışma frekansına göre bir seçim yapılmalıdır. GPR üreticileri, anteni kullanılan merkez frekansına göre adlandırmaktadır [26]. GPR'ın etkinliği, işletim frekansı (operating frequency) ve bant genişliği ile merkez frekansı oranından etkilenir [6]. Çözünürlük gereksinimlerini karşılayabilmek için frekansın mümkün olduğunca düşük tutulması önemlidir. Çünkü yüksek frekanslar, elektriksel kayıplar ve saçılma nedeniyle daha fazla zayıflar ve bu da sinyalin ortama daha az nüfuz etmesine yol açar[10].

Ground Penetrating Radar sinyalleri, bant genişliğinin merkez frekansına oranına göre karakterize edilir [10].

$$R = \frac{B}{f_c} \quad (1.9)$$

Denklemden bulunan değişkenin açıklamaları:

R - Bant genişliği ile merkez frekansı arasındaki oran

B - Bant genişliği

f_c - Merkez frekansı

Bant genişliği ile merkez frekans arasındaki oran, GPR sistemlerinin performansını etkiler. Bu oranı maksimize etmek, sistem performansını artırmaya yardımcı olur.

Pratik GPR sistemleri genellikle oranın (R) 1 olduğu bir tek dalga karakterine sahip olmayı hedefler. Bu tür sistemler genellikle ultra geniş bant radarlar, impulse radarlar veya temel bant radarlar olarak adlandırılır.

Sonuç olarak, GPR sistemleri genellikle merkez frekanslarına (f_c göre karakterize edilir. Örneğin, 100 MHz'lik bir GPR, 100 MHz'de merkezlenmiş bir bant genişliği (B) ile çalıştığını belirtir. Bu, sistemde kullanılan frekansın belirtilen merkez frekansı olduğunu ve sinyal genişliğini ifade eder.

Genel olarak, merkez frekansı, GPR'ın performansını ve kullanımını etkileyen temel bir parametredir. Doğru merkez frekansının seçilmesi, belirli bir uygulama veya arazi koşulu için en iyi sonuçların elde edilmesine yardımcı olabilir.

1.5.2 Bant Genişliği (Bandwidth)

GPR'da bant genişliği, sinyallerin çözünürlüğünü ve performansını önemli ölçüde etkiler. Tipik olarak, GPR sinyalleri kısa süreli elektromanyetik enerji darbelerinden oluşur, bu da onların geniş bir frekans aralığında yayılmasını sağlar [12, 18, 19, 26]. Bu geniş frekans aralığına sahip sinyaller, daha yüksek çözünürlükle yer altındaki küçük ayrıntıların daha iyi tespit edilmesini sağlar. Antenlerin bant genişliği genellikle merkez frekansının etrafında ayarlanır ve bant genişliği, merkez frekansın yaklaşık 1.5 katına kadar genişleyebilir [28, 29]. Bant genişliği, uygulamaya bağlıdır ve GPR'ın çözünürlüğüyle sıkı bir şekilde ilişkilidir. Normal GPR işlemlerinde, antenler genellikle birbirine yakın konumlandırılır. Bu nedenle, verici bir darbe gönderdiğinde, sinyal doğrudan vericiden alıcıya geçer [10, 18, 19]. Verici darbesi çok uzunsa, alıcı antenin elektroniğini aşırı yükleyebilir ve hedefin yansıyan EM dalgalarını algılayamaz hale gelebilir. Bu etkiye "verici kapatma" denir. Optimal çözünürlüğü sağlamak için oluşturulan darbelerin mümkün olduğunca küçük olması gerekir, yani bant genişliği maksimize edilmelidir [12].

GPR sistemleri, genellikle 10.000 ns civarında, 10 ps'nin altında örnekleme adımı ile veri kaydetmek zorundadır [19]. Ölçüm bant genişliği, uygulamaya bağlıdır ve doğrudan çözünürlükle ilişkilidir. Çözünürlük, "verici kapatma" ve "hedef ayırma" gibi iki ilişkili konuyu içerir [19]. Verici kapatma, alıcının vericiden gelen sinyalden hemen sonra gelen sinyalleri algılayamaması durumudur. Bu, hem bant genişliği hem de dinamik aralık ile ilgili bir sorundur. Darbe süresi, bant genişliği ile ters orantılı olarak değişir. Çözünürlük uzunluğu Δ_r tarafından belirlenen bant genişliği aşağıdaki denklemle hesaplanır [19]:

$$B = \frac{v}{4\Delta_r} \quad (1.10)$$

Burada, B bant genişliğini, v hızı ve Δ_r çözünürlük uzunluğunu temsil eder. Bu denklem, GPR sisteminin gereksinim duyduğu bant genişliğini belirlemek için kullanılır.

1.5.3 Çözünürlük (Resolution)

GPR'da çözünürlük; yeraltındaki nesnelerin pozisyonu, şekli, boyutu ve kalınlığı gibi özellikleri tahmin ederken elde edilen doğruluk seviyesini ifade eder [12, 18, 19, 30]. Aynı zamanda, en küçük tespit edilebilir yeraltı özelliği olarak da ifade edilebilir [30]. Çözünürlük, iki farklı biçimde tanımlanır: dikey (vertical) çözünürlük ve yanlamasına (lateral) çözünürlük.

1.5.3.1 Dikey Çözünürlük (Vertical Resolution)

Dikey çözünürlük, iki hedef arasındaki minimum derinlik farkını belirler [19, 9, 30]. İki hedefin ayırt edilebilmesi için yansıyan darbelerin, en az dalga boyunun yarısı kadar bir mesafede ayrılması gerektiği kabul edilir. Bu durum Denklem 1.11'de gösterilmektedir.

Şekil 1.4'teki örnekte alıcı ve verici antenlerin birbirine çok yakın olduğu varsayılır. Şekil 1.4'te T1 ve T2, benzer malzemelerden yapılmış objelerdir. Antenler ile T1 objesi arasındaki mesafe d_1 olarak belirtilmiştir. Δr ise dikey çözünürlüğü (vertical resolution) temsil eder ve bu, iki hedef arasında ayırt edilebilirlik için gereken minimum dikey mesafeyi ifade eder. Ortamın yayılma hızına v dersek, hedeflere ulaşan elektromanyetik dalgaların (EM) geçiş süreleri T1 ve T2 için sırasıyla şu şekilde ifade edilir: $t_1 = 2d_1/v$ ve $t_2 = (d_1 + 2\Delta r)/v$ [19, 30]. Dolayısıyla t_1 ve t_2 arasındaki zaman farkı denklem 1.12'de [19, 30] verilmiştir. Denklem 1.11'de [19, 30] verilen dikey çözünürlük için hedefler arasındaki zaman farkı Δt , darbenin genişliğinin (W) yarısından büyük olmalıdır. Denklem 1.13'te [19, 30] ise, dikey çözünürlüğün (Δr) minimum değeri, ortamın yayılma hızı (v) ve darbe genişliği (W) ile ilişkilendirilmiştir.

$$\frac{W}{2} \leq \Delta t \quad (1.11)$$

$$\Delta t = t_1 - t_2 = \frac{2\Delta r}{v} \quad (1.12)$$

$$\Delta r \geq \frac{v * W}{4} \quad (1.13)$$

Denklem 1.11, 1.12 ve 1.13'te kullanılan değişkenlerin açıklamaları:

W - Darbe genişliği

Δt - İki hedef arasındaki zaman farkı


Δr - Dikey çözünürlük

v - Ortamın yayılma hızı

d_1 - İlk hedefin yüzeye olan mesafesi

t_1 - İlk hedefe ulaşan dalgaların geçiş süresi

t_2 - İkinci hedefe ulaşan dalgaların geçiş süresi



Şekil 1.4 GPR sisteminde dikey çözünürlük

1.5.3.2 Yanal Çözünürlük (Lateral Resolution)


Yanal çözünürlük, iki nesne arasındaki minimum yanal mesafeyi belirler. Yanal çözünürlük, nesnelerin ideal bir şekilde ayırt edilebilmesi için gereken en küçük yanal mesafedir [9, 19, 30]. Çözünürlüğün ikinci bir versiyonu olan bu kısım, genellikle nesnelerin derinliğine bağlı olarak değişir [19, 30].

Şekil 1.6’da bulunan antenlerin birbirine çok yakın olduğu varsayılır. Bu örnekte T1 ve T2 benzer özellik taşıyan nesnelerdir. Bu iki nesne d_1 derinliğindedir. Ortalama yayılma hızı v ’dir. Yanal çözünürlük Δl ile temsil edilmektedir. Verici ve alıcı antenler arasındaki yakınlık, hedefin derinliğinden çok daha küçüktür, bu nedenle T1 hedefine ulaşan EM dalgasının dikey bir şekilde yayıldığı varsayılır. Elektromanyetik dalgaların (EM) T1 ve T2’ye ulaşmasında geçen zaman sırasıyla $t_1 = 2d_1/v$ ve $t_2 = 2\sqrt{d_1^2 + \Delta l^2} - d_1/v$ şeklindedir [19, 30]. T1 ile T2 arasındaki zaman farkı yaklaşık olarak denklem 1.14’te verilmiştir [30].

$$\Delta t = t_2 - t_1 = \frac{\Delta l^2}{v * d_1} \quad (1.14)$$

Yanlamasına (lateral) hız için, minimum zaman farkı, yarım dalga boyunun yarısı kadar olmalıdır. Bu gereklilik, 1.11 numaralı denkleme dayanır. Yanlamasına çözünürlüğü belirlemek için 1.11 ve 1.14 numaralı denklemler birlikte çözülerek, yanlamasına çözünürlük, denklem 1.15’te [30] ifade edilen şekilde elde edilir.

$$\Delta l \geq \sqrt{\frac{v * d_1 * W}{2}} \quad (1.15)$$



Şekil 1.5 GPR sisteminde yanlamasına çözünürlük

GPR'da dikey çözünürlük, sinyalin darbe genişliği ve malzemedeki yayılma hızı ile belirlenir. Bu, ideal koşullarda geçerli olsa da gerçek dünyada elektromanyetik dalgaların derinlere nüfuz etmesi sırasında karşılaşılan dağılma ve zayıflama etkileri dikey çözünürlüğü olumsuz etkileyebilir.

Yanlamasına çözünürlük ise, yayılma hızı, darbe genişliği ve hedefe olan mesafe ile ilgilidir. Yüksek frekanslı ve geniş bant genişliğine sahip sistemler daha iyi yanlamasına çözünürlük sağlar. Özellikle, darbe genişliği ile bağlantılı olan merkez frekansın kullanılması, yanlamasına çözünürlüğü etkiler.

Bu kavramlar, genellikle dalgacık temelli algılama yöntemlerinde yaygın olarak kullanılır [10, 30]. İki darbenin birbirinden ne kadar uzakta olması gerektiği, darbe genişliğine bağlıdır. Eğer iki darbe birbirine çok yakınsa, genellikle tek bir olay olarak algılanır. Bu darbe ayrımı kavramı, uzamsal çözünürlüğe dönüştürülerek kullanılır. Dikey çözünürlük uzunluğu, darbe genişliği ve malzemedeki hız tarafından belirlenir. Yanal çözünürlük uzunluğu ise yayılma hızı, darbe genişliği ve hedefe olan mesafe ile belirlenir. Diğer bir deyişle, **GPR sisteminin çözünürlüğü, elektromanyetik özelliklere, merkez frekans ve bant genişliği gibi sistem parametrelerine ve hedefin derinliğine bağlıdır.** Bu iki çözünürlük bileşeni, GPR sisteminin hedeflerin yerini ve özelliklerini belirleme yeteneğini etkiler. Dikey ve yanlamasına çözünürlüklerin iyileştirilmesi, daha hassas ve ayrıntılı toprakaltı görüntüleri elde etmeyi sağlar, bu da tespit çalışmalarında daha iyi sonuçlar elde etmek için kritiktir [10, 18, 19, 20, 30]. Genel olarak, GPR sisteminin çözünürlüğü, elektromanyetik özellikler ve sistem parametrelerine bağlı olarak değişir. Bu nedenle, çözünürlüğü artırmak için geniş bant aralığı ve doğru anten seçimi gibi faktörler dikkate alınmalıdır.

1.5.4 Nüfuz Derinliđi (Penetration Depth)

GPR'ın nüfuz derinliđi, elektromanyetik dalgaların ortamda ne kadar ilerleyebileceđini belirtir [12, 20, 31]. Bu derinlik, kullanılan frekans, malzemenin elektriksel iletkenliđi ve dielektrik sabiti gibi çeşitli faktörlere bađlıdır. Daha düşük frekanslar genellikle daha derine nüfuz eder, ancak bu, yüksek frekanslarda daha iyi çözünürlük elde etmekten ödün verilmesi anlamına gelir [16]. Öte yandan, yüksek iletkenlik veya yüksek dielektrik sabitine sahip malzemeler, elektromanyetik dalgaların nüfuz etmesini engelleyebilir. Bu nedenle, penetrasyon derinliđi, GPR'ın uygulanacađı ortama ve belirlenen hedeflerin derinliđine bađlı olarak deđişir [16, 31].




GPR VERİLERİNİN İŞLENMESİ

İlk bölümde GPR sistemini oluşturan bileşenlerden, tarihinden ve çalışma prensibinden bahsedildi. Bu bölümde GPR verilerinden cisim tespiti için gerekli olan adımlar açıklanacaktır. Yere nüfuz eden radar (GPR), pratik dünyada tahribatsız tarama yapabilen ve geniş uygulama alanlarına sahip kullanışlı bir sistemdir [32]. GPR, askeri ve sivil uygulamalarda yer altının görüntülenmesinde kullanılmaktadır. Bu görüntülemelerden elde edilen verilerin yorumlanması için çoğu zaman insan müdahalesi gerekir [33]. GPR verilerini yorumlama sürecinin otomatikleşmesi için bazı çalışmalar yapılmıştır ancak hala önemli problemler mevcuttur. Bu bölümde, GPR verilerinin işlenmesi, nesne tespiti ve sınıflandırmasına yönelik çalışmalar açıklanacaktır.

Standart GPR veri işleme süreci, yeraltı özelliklerinin optimal görselleştirilmesi ve yorumlanmasını sağlayan birkaç adımdan oluşur [12]. Bunlar en temelde filtreleme ve arka plan çıkarımıdır. Filtrelemenin içeriği bant geçiren filtre, bir boyutlu medyan filtre, iki boyutlu medyan filtre, yatay bant geçiren filtre, gabor filtre vb. olarak verilebilir. Filtreleme işlemi, toplanan verilerdeki gürültüyü azaltmak ve istenmeyen bileşenleri temizlemek için kullanılır. Bu adımda kullanılan işlemler arasında bant geçiren filtre, medyan filtreleri bulunmaktadır. Bant geçiren filtreler, istenmeyen frekans bileşenlerini temizlemek için kullanılır [34, 35]. Medyan filtre, ortalamaları almak yerine medyan değerini kullanarak veriyi temizler [36]. Yatay bant geçiren filtre, GPR antenin yüksekliğinin değişmesinden kaynaklanan kargaşayı gidermek için kullanılırken, Gabor filtresi, belirli bir ölçekte ve yönde veriyi analiz etmek için kullanılır [36]. Derinliğe bağlı kazanç, verinin derinlik boyunca kaybını giderir ve farklı derinliklerdeki nesnelerin daha iyi belirlenmesini sağlamak için kullanılır.

Bu işlemler ve daha fazlası, MATLAB AppDesigner ortamında oluşturulan adını GPRVAT olarak sunduğumuz bir arayüz üzerinden gerçekleştirilecektir. Bu arayüz, kullanıcının kolaylıkla farklı filtreler ve teknikler kullanmasını ve veri işleme sürecini kontrol etmesini sağlayacaktır. Bu arayüz sonraki bölümlerde detaylı olarak açıklanacaktır. Şekil 2.1’de GPRVAT arayüzünde GPR veri işleme ile ilgili yapılan işlerin ana bileşenleri verilmiştir.




Şekil 2.1 GPRVAT veri işleme genel görünümü

2.1 GPR Verisini Elde Etme

GPR veri elde etme süreci, elektromanyetik dalgaların yeraltına gönderilmesi ve bu dalgaların çeşitli yüzeylerden yansıyarak geri dönmesi prensibine dayanır. Yansıyan sinyallerin alıcıya ulaşma süresi ve genliği analiz edilerek yeraltındaki yapıların özellikleri hakkında bilgi edinilir. Bu süreçte kullanılan farklı tarama modları, yeraltı yapılarının incelenmesi için çeşitli veri türleri sağlar. Bunlar: A-tarama, B-tarama ve C-taraması verileridir. Bu taramalar hem farklı çözünürlük seviyelerinde hem de farklı boyutlarda veri sunarak yeraltı özelliklerinin daha kapsamlı bir şekilde analiz edilmesine olanak tanır.

Şekil 2.2’de gösterildiği gibi, sistem belirlenen bir yol boyunca yüzeye paralel olarak hareket eder ve arama başlığı sabit yükseklik ve hızda ilerler. Tarama hızı 3 cm/sn olarak belirlenmiş olup, sistem sağa ve sola doğru 100 cm’lik bir alanı tarayacak şekilde çalışmaktadır. Tarama sırasında, GPR anteni ve metal dedektörü entegre şekilde veri toplayarak, yeraltındaki dielektrik süreksizlikleri algılar.

Şekil 2.2, tarama başlığının hareket yönünü ve yeraltındaki nesnelerden gelen yansımaların nasıl kaydedildiğini görsel olarak sunmaktadır. GPR anteni, belirlenen tarama bölgesinde düzenli bir şekilde ilerleyerek, her noktada A-scan verisi toplar ve bu veriler yatay ekseninde birleştirilerek B-scan görüntüsü oluşturulur. Gömülü cisimlerin derinliği, toprak özelliklerine bağlı olarak değişkenlik gösterebilir. Genel olarak, normal toprak koşullarında nesneler 50 cm’ye kadar gömülü olabilir. Sistem, belirli özel senaryolar haricinde sabit yükseklik ve hızlarda hareket ederek homojen bir veri toplama süreci sağlar. Bu sayede, yeraltındaki nesnelerin tespiti ve sınıflandırılması için tutarlı ve güvenilir bir veri seti oluşturulabilir. Bu süreç, GPR verisinin yeraltı nesnelerinin belirlenmesi ve sınıflandırılması için nasıl toplandığını anlamak açısından kritik öneme sahiptir.




Şekil 2.2 Robotik tarama sistemi ve veri toplama senaryosu

A-tarama (A-Scan), en temel veri elde etme yöntemi olarak, tek bir noktadan elde edilen sinyalin zamana bağlı ifadesini içerir. Bu taramada verici anten elektromanyetik sinyalleri ortama gönderir ve sinyallerin farklı malzeme katmanlarından yansiyarak geri dönme süresi ölçülür. Yansıyan sinyallerin geri dönüş süresi, toprak altında bulunan nesnelerin veya katmanların derinliği hakkında bilgi verir. A-tarama, genellikle dikey ekseninde derinlik profili çıkarmak amacıyla kullanılır ve tek bir noktadan elde edilen sinyalin bir zaman-genlik grafiği ile sunulmasıyla karakterize edilir. GPR A-tarama sinyali şekil 2.4b’de gösterilmektedir. Bu yöntem, basit ve hızlı bir veri toplama işlemi sağlar ancak yeraltındaki yapılar hakkında sınırlı bir bilgi sunar. Çünkü yalnızca bir noktada ölçüm yapılmıştır.

B-tarama (B-Scan) verisi, A-tarama verilerinin genlikleri parlaklık olarak bir görüntüye dönüştürmek suretiyle elde edilir. A-taramanın daha geniş bir alanda tekrarlanması ile elde edilen bir yöntemdir. A-tarama yalnızca tek bir noktada ölçüm yaparken, şekil 2.4c’de görüldüğü gibi GPR B-tarama yatay doğrultuda bir dizi A-tarama verisinin birleştirilmesiyle oluşur. Bu yöntem, bir yüzeyin altındaki yapılar hakkında iki boyutlu bir kesit sunar. B-tarama sayesinde, farklı derinliklerde bulunan yeraltı nesnelerinin veya katmanlarının konumu, boyutu ve derinliği görsel olarak belirlenebilir. B-tarama, yer altındaki nesnelerin yerini tespit etmek ve onların şekil ve boyutlarını değerlendirmek için sıkça kullanılan bir yöntemdir. Özellikle mühendislik, arkeoloji, askeri ve inşaat gibi alanlarda yer altındaki borular, kablolar, mayınlar veya tarihi kalıntılar gibi yapıların tespit edilmesi amacıyla tercih edilir.


C-tarama (C-Scan) ise, en kapsamlı tarama yöntemlerinden biridir ve geniş bir yüzey alanında yapılan çoklu taramalar sonucu üç boyutlu bir veri seti sağlar. C-tarama, B-taramanın farklı eksenlerde tekrarlanmasıyla elde edilen taramalar sonucunda, yüzey altındaki yapıların derinlik ve yatay düzlemdeki dağılımını incelemeye olanak tanır. Bu yöntem, özellikle yüzeyin geniş bir bölgesinde detaylı inceleme yapılması gerektiğinde kullanılır. Birden fazla B-taramanın farklı doğrultularda yapılmasıyla oluşan C-tarama, yer altındaki yapıların üç boyutlu haritalanmasına imkân tanır. Bu sayede nesnelerin sadece yatay ve dikey düzlemdeki konumları değil, aynı zamanda üçüncü boyutta da detaylı bir analizi yapılabilir.

Şekil 2.3’de GPRVAT uygulamasından alınmış bir sayfa görülmektedir. Bu şekilde işlenmiş ve işlenmemiş bir B-tarama verisi ve B-tarama verisini oluşturan A-tarama verilerinden 143’üncüsü görülmektedir. Şekil 2.4b’de görülen B-tarama görüntüsü ve doğal olarak A-tarama görüntüsü ham GPR verisi değildir. Bu verilerin üzerine bazı filtreler uygulanmış durumdadır. Bu kullanılan filtreler sonraki bölümde detaylı olarak anlatılacaktır.




a) İşlenmemiş GPR verisi b) İşlenmiş GPR verisi
Şekil 2.3 GPR B-tarama görüntüsündeki A-tarama verilerini gösteren sayfa (GPRVAT Arayüzü)

Sonuç olarak A-tarama verilerinin yan yana gelmesinden B-tarama verisi, B-tarama verilerinin yan yana gelmesinden C-tarama verisi elde edilir. Bu durum Şekil 2.4'te görülmektedir. Şekil 2.4a'da tarama alanı ve gömülü cisim tasvir edilmiştir. Şekil 2.4b'de tarama alanında tarama yapılırken elde edilen A-tarama verileri temsilen verilmiştir. Şekil 2.4c'de, toplanan A-tarama verilerinin sırasıyla yan yana dizilmesiyle bir B-tarama görüntüsü oluşturulmuştur. Şekil 2.4d'de ise B-tarama verisinin yan yana gelmesiyle C-tarama verisi elde edilmesi görülmektedir.




a) Koordinat sistemi, tarama senaryosu ve temsili gömülü cisim



b) X yönünde toplanan A-tarama sinyalleri



c) GPR B-tarama görüntüsü



d) GPR C-Tarama görüntüsü elde etme

Şekil 2.4 GPR veri toplama senaryosu

2.2 Gürültü Kaldırma

Gürültü kaldırma aşamasında, GPR verilerinin daha anlaşılır ve analiz edilebilir hale getirilmesi için çeşitli yöntemler uygulanmaktadır. Bu aşamada, verilerdeki gürültüyü azaltarak hedef sinyallerin daha belirgin hale gelmesi amaçlanır. Normalizasyon, bant geçiren filtre, dalgacık dönüşüm, Fourier dönüşüm ve

yumuşatma filtreleri gibi teknikler bu süreçte kullanılmaktadır. Bu işlemler, verilerin kalitesini artırarak daha doğru sonuçlar elde edilmesine olanak sağlar.

2.2.1 Filtreleme

GPR'da filtreleme, toplanan verilerdeki gürültüyü azaltmak ve istenmeyen bileşenleri temizlemek için kullanılan bir işlemdir. Filtreleme işlemi, GPR verilerinin daha temiz ve doğru bir şekilde elde edilmesini sağlar [12, 33]. GPRVAT'ta kullandığımız filtreler; Bant geçiren filtre, yatay bant geçiren filtre, bir boyutlu medyan filtresi ve görüntüye uygulanan yumuşatma (smoothing) filtresidir.

2.2.1.1 Bant Geçiren Filtre

Bir bant geçiren filtre, belirli bir frekans aralığında sinyalleri geçirir ve diğer frekansları baskılar [34, 35, 37]. GPR'da bant geçiren filtre A-tarama verisine ve bazen GPR B-tarama verisinin satırlarına uygulanır.

Veriye uygulanacak bant geçiren filtre, tipik olarak bir FIR (Finite Impulse Response) veya IIR (Infinite Impulse Response) filtresi şeklinde olabilir. GPR verilerine bant geçiren filtre uygulaması genellikle bir IIR filtresi kullanılarak yapılır. IIR filtrelerinin Z-domainindeki transfer fonksiyonu şu şekilde ifade edilir [35, 38]:

$$H(z) = \frac{\sum_{k=0}^N b_k z^{-k}}{1 + \sum_{k=1}^M a_k z^{-k}} \quad (2.0)$$


Burada, $H(z)$ transfer fonksiyonunu, b_k (nümeratör) katsayılarını, a_k (denominator) katsayılarını, N filtrenin derecesi ve z^{-n} gecikme terimlerini temsil eder.

Bir bant geçiren IIR filtre tasarımı yapılırken, belirli bir frekans bandının geçişine odaklanılır [38, 37]. Bu tasarımda, üst kesim frekansı (f_h) ve alt kesim frekansı (f_l) belirlenir. Bu frekansları geçirecek şekilde IIR filtresinin katsayıları hesaplanır. Filtre tasarımının ardından, istenilen frekans aralığına uygun katsayılar hesaplanarak GPR verisine uygulanır. Örneğin, bir alçak geçiren IIR filtre için transfer fonksiyonu şu şekilde olabilir:


$$H(z) = \frac{1}{1 + az^{-1}} \quad (2.1)$$

Burada, a bir katsayıdır ve frekans bandını belirler. Bu formül, düşük frekansların geçmesini sağlarken yüksek frekansları baskılar. Bu tür bir IIR filtresi GPR verileri üzerinde düşük frekanslı bileşenleri geçirecek şekilde tasarlanabilir.

Şekil 2.5a'da A-tarama verisi görülmektedir. Şekil 2.5b'de ise bant geçiren filtre uygulanmış A-tarama verisinin grafiği görülmektedir.




a) Bant geçiren filtre uygulanmamış A-tarama verisi




b) Bant geçiren filtre uygulanmış A-tarama verisi

Şekil 2.5 A-tarama verisine bant geçiren filtre uygulaması

Şekil 2.6a'da bant geçiren filtre uygulanmamış GPR verisi görünürken Şekil 2.6b'de bant geçiren filtre uygulanmış GPR verisi görülmektedir. Şekil 2.6a ve Şekil 2.6b'de görülen görüntüler arka plan çıkarılmış görüntülerdir. Yani bu görüntülere bant geçiren filtre uygulanması haricinde daha iyi sonuç elde edebilmek için birkaç işlem daha uygulanmıştır. Yapılan işlemler sonraki bölümlerde detaylı olarak açıklanacaktır fakat burada bant geçiren filtre uygulandığı zamanki farkı görebilmek için bu görüntüler gösterilmiştir. Şekil 2.6c ve Şekil 2.6d'de sırasıyla bant geçiren filtre uygulanmamış ikili görüntü ve bant geçiren filtre uygulanmış ikili görüntü görülmektedir. Buradaki önemli olan nokta bant geçiren filtre A-tarama verisine uygulandıktan sonra B-tarama verisi elde edilmesidir. Yani, bant geçiren filtre doğrudan B-tarama verisine uygulanmamaktadır.




a) Bant geçiren filtre uygulanmamış GPR verisi



b) Bant geçiren filtre uygulanmış GPR verisi



c) Bant geçiren filtre uygulanmamış GPR verisinin ikili görüntüsü




d) Bant geçiren filtre uygulanmış GPR verisinin ikili görüntüsü


Şekil 2.6 Bant geçiren filtrenin GPR verisi üzerindeki etkisi

2.2.1.2 Yatay Bant Geçiren Filtre

Standart GPR uygulamasında bant geçiren filtre bir A-tarama verisine diğer bir ifadeyle B-tarama görüntüsünün bir sütunundan alınan değerlere uygulanırken yatay bant geçiren filtre ise A-tarama verilerinden oluşmuş B-tarama görüntüsünün satırlarından alınan değerlere uygulanır. Yatay bant geçiren filtre GPR verileri toplanırken GPR arama başlığının yüksekliğinin değişiminden kaynaklanan kargaşayı gidermek için kullanılmaktadır. Bu işlemler şekil 2.7a ve şekil 2.7b’de gösterilmiştir. Kırmızı çizgiler filtre uygulanması için alınan verilerin konumunu göstermektedir. Bant geçiren filtre için sütun değerleri dikkate alınırken yatay bant geçiren filtre için satır değerleri dikkate alınmaktadır. Yataydaki bu filtreleme tüm satırlar için yapılır.




a) Bant geçiren filtre uygulama çizgisi



b) Yatay bant geçiren filtre uygulama çizgisi


Şekil 2.7 Yatay bant geçiren filtre uygulaması

Şekil 2.8’de GPRVAT uygulamasından alınmış bir pencere bulunmaktadır. Bu pencerede yatay bant geçiren filtre uygulanmadan önceki tek boyutlu veri ile uygulandıktan sonraki tek boyutlu verinin farkı görülmektedir. Grafikte siyah ile gösterilen sinyal, yatay bant geçiren filtre uygulanmamış halini, yatay bant geçiren mavi ile gösterilen sinyal ise filtre uygulanmış halini göstermektedir.




Şekil 2.8 GPRVAT uygulamasında yatay bant geçiren filtre analiz penceresi


Şekil 2.9’de, GPR arama başlığındaki değişimden kaynaklanan yatay bantların bulunduğu bir GPR verisi ile bu verinin yatay bant geçiren filtre uygulanmış ve uygulanmamış halleri gösterilmektedir.



a) GPR ham veri



b) Yatay bant geçiren filtre uygulanmış GPR verisi



c) Yatay bant geçiren filtre uygulanmış GPR verisi

Şekil 2.9 Yatay bant geçiren filtrenin GPR verisi üzerindeki etkisi

2.2.1.3 Mutlak Alma (Absolute)

Mutlak değer, bir sayının sıfıra olan uzaklığını ifade eden matematiksel bir terimdir. GPR görüntülerinde, her pikseldeki radar dalgasının genliğini veya gücünü temsil eder [39]. Mutlak değer kullanmanın GPR görüntülerindeki faydaları şunlardır:

- Doğruluk ve Tutarlılık: Mutlak değerler, GPR görüntüsündeki piksel değerlerinin gerçek dünyadaki fiziksel niceliklerle ilişkilendirilmesine olanak sağlar. Bu, görüntüdeki nesnelerin ve özelliklerin gerçek boyutlarını ve değerlerini daha doğru bir şekilde temsil etmeyi sağlar.
- Veri Normalizasyonu: GPR sinyalleri, çeşitli faktörlerden dolayı gürültüye maruz kalabilir. Mutlak değerler, bu sinyalleri normalize ederek veri analizini ve işlemeyi kolaylaştırır.

- **Özellik Çıkarma ve Sınıflandırma:** GPR görüntülerinin özelliklerini otomatik olarak çıkarmak ve sınıflandırmak için çeşitli teknikler kullanılır. Bu teknikler, mutlak değerlerin sağladığı doğruluk ve tutarlılığa dayanarak daha iyi sonuçlar sunar.
- **Görsel Netlik:** Mutlak değerler, GPR görüntülerindeki kontrastı ve netliği artırır, bu da nesnelerin ve özelliklerin daha kolay ayırt edilmesini sağlar.

Mutlak değerler, GPR görüntülerindeki piksellere doğruluk, tutarlılık ve görsel netlik kazandırır [40], bu da verilerin daha iyi anlaşılmasına ve GPR yönteminin potansiyelinin tam olarak ortaya çıkmasına olanak tanır.

2.2.2 Gabor Filtresi

Gabor filtresi, görüntü analizinde sıklıkla kullanılan ve belirli örüntüleri görüntü üzerinde ortaya çıkarma özelliklerine sahip bir filtreleme tekniğidir [36, 41]. Gabor filtresinin temel amacı, görüntünün farklı frekans bileşenlerini tespit etmek ve belirli bir yönde mevcut olan uzamsal frekans içeriğini/örüntüyü tespit etmektir [42]. Gabor filtresinin matematiksel denklemi aşağıdaki gibidir [36]:

$$G(x, y; \lambda, \theta, \sigma, \gamma) = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda}\right) \quad (2.2)$$

Bu denklemde:

x, y - Görüntü üzerindeki yatay ve dikey koordinatlar.

λ - Sinüzoidal bileşenin dalga boyu (uzamsal frekans).

θ - Filtrenin yön açısı

σ - Standart sapma


γ - Uzamsal en-boy oranı

x', y' - Döndürülmüş koordinatlar ($x' = x\cos(\theta) + y\sin(\theta)$, $y' = -x\sin(\theta) + y\cos(\theta)$)


Gabor filtresi, farklı frekans bileşenlerini farklı oranlarda vurgulayarak görüntüdeki yapıların çeşitli özelliklerini ortaya çıkarır. Doku analizi, kenar tespiti ve desen tanıma gibi çeşitli alanlarda yaygın olarak kullanılmaktadır [41, 43, 44]. Farklı parametrelerle ayarlanabilen Gabor filtreleri, bir görüntünün farklı yönlerdeki ve ölçeklerdeki frekans bileşenlerini ayırt edebilir. Bu sayede, görüntüdeki belirli desenler, kenarlar veya dokular daha belirgin hale gelir. Gabor filtreleri, özellikle GPR verilerinin sınıflandırılması, biyometrik tanıma sistemleri ve parmak izi ile iris tanıma gibi alanlarda etkin bir şekilde kullanılmaktadır.

Gabor filtresinin etkinliđi, belirli bir frekans ve yön kombinasyonuna duyarlı olmasından kaynaklanır [36, 41, 44]. Bu özellik, bir görüntünün belirli yönlerdeki detaylarını ve yapılarını vurgulamak için oldukça yararlıdır. Bu nedenle, Gabor filtreleri, görüntü işleme ve bilgisayarla görme uygulamalarında sıkça tercih edilen bir araçtır. Ayrıca, bu filtreler sinyallerin zaman-frekans analizinde de kullanılarak, sinyalin hem zamansal hem de frekans bileşenlerinin detaylı incelenmesine olanak tanır.

Gabor filtreleri, ground penetration radar (GPR) verilerinin analizinde önemli bir rol oynar [45]. Bu filtreler, radar sinyallerinin farklı frekans ve yön bilgilerini ayırıştırarak, yer altındaki çeşitli yapıların daha belirgin hale gelmesini sağlar. Aynı zamanda, radar verilerindeki yapısal detayları öne çıkarmakla birlikte, gürültü ve arka plan sinyallerini azaltarak veri kalitesini artırır [46]. Böylece, Gabor filtreleri, GPR verilerinin netliğini ve doğruluğunu artırarak daha etkili bir analiz sağlar. Şekil 2.10'da GPR verilen Gabor filtresinin uygulama sonucu görölmektedir. Uygulanan Gabor filtresinin parametreleri $\lambda = 10$, $\theta=0$, $\sigma=10$ ve $\gamma=1$ şeklindedir.



a) Arka plan çıkarılmış GPR verisi



b) Gabor filtresi uygulanmış GPR verisi

Şekil 2.10 Gabor filtresinin GPR görüntüsüne uygulanması

2.2.3 Dalgacık Dönüşüm (Wavelet Transform)

İki boyutlu dalgacık dönüşüm, sinyal ve görüntü işlemlerinde kullanılan güçlü bir analiz yöntemidir. Fourier dönüşümün sağladığı frekans bilgisine ek olarak, dalgacık dönüşümü hem frekans hem de uzamsal bilgiyi aynı anda sağlar. Bu da sinyallerdeki ani değişiklikleri ve yerel özellikleri tespit etme yeteneğini önemli ölçüde artırır [36, 41, 47, 48]. Bu özellik, dalgacık dönüşümünü sinyal ve görüntü analizinde çok yönlü ve güçlü bir araç haline getirir.

Dalgacık dönüşümün temel matematiksel ifadesi, bir sinyalin veya görüntünün belirli bir wavelet fonksiyonu ile çarpılması ve ardından bu fonksiyonun çeşitli ölçekler ve yerel parametrelerle kaydırılmasıyla elde edilir [48, 49]. 2 boyutlu dalgacık dönüşümü, bir görüntünün farklı ölçeklerdeki yatay, dikey ve çapraz bileşenlerini analiz edebilir. Matematiksel olarak, 2D dalgacık dönüşüm şu denklemle ifade edilir [36, 47]:

$$WT_f(a, b, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \cdot \psi_{a,b,\theta}(x, y) dx dy \quad (2.3)$$

Bu denklemde:

$f(x, y)$ - Analiz edilen görüntüyü temsil eder.

$\psi(x, y)$ - Wavelet fonksiyonudur ve bu fonksiyonun ölçek, yerel pozisyon ve yönüne göre kaydırılmış hali $\psi_{a,b,\theta}(x, y)$ olarak ifade edilir.

a - Ölçek parametresidir; bu parametre, wavelet fonksiyonunun genişliğini değiştirir ve bu sayede farklı frekans bileşenlerini yakalar.

b - Yerel pozisyon parametresidir; bu, wavelet fonksiyonunun görüntü üzerindeki yerini belirler.

θ - Yön parametresidir ve wavelet fonksiyonunun yönünü ayarlar.

Bu denklem, görüntünün farklı ölçeklerde ve yönlerde nasıl analiz edileceğini gösterir. Dalgacık dönüşümün çok ölçekli ve çok yönlü analiz yeteneği, özellikle görüntüdeki farklı ölçeklerdeki detayları ortaya çıkarmak ve bu detayların uzamsal dağılımını anlamak için son derece etkilidir.

Dalgacık dönüşümün sağladığı bu çok yönlü analiz yeteneği, onu bir dizi önemli işlemlerde vazgeçilmez kılar. Özellikle çok ölçekli analizler, kenar tespiti, görüntü sıkıştırma ve gürültü azaltma gibi görevlerde dalgacık dönüşümün üstün performans gösterdiği bilinmektedir [49]. Örneğin, çok ölçekli analiz özelliği, bir görüntüde hem büyük hem de küçük ölçekli detayların aynı anda analiz edilmesine olanak tanır [48]. Bu, görüntüdeki küçük ayrıntıların yanı sıra daha geniş yapıların da doğru bir şekilde incelenmesini sağlar. Kenar tespiti uygulamalarında dalgacık dönüşümü, bir görüntüdeki ani parlaklık değişikliklerini veya sınırları tespit edebilir [50]. Bu özellik, özellikle tıbbi görüntüleme gibi hassas alanlarda son derece değerlidir [51, 52]. Ayrıca, dalgacık dönüşümü sıkıştırma işlemlerinde kullanılarak, yüksek veri hacmine sahip görüntülerin sıkıştırılmasında ve depolama gereksinimlerinin azaltılmasında büyük avantaj sağlar [53]. Gürültü azaltma konusunda da dalgacık dönüşümü, istenmeyen sinyallerin veya gürültünün etkin bir şekilde filtrelenmesini sağlayarak, temiz ve net görüntüler elde edilmesine yardımcı olur.

GPR verilerinde dalgacık dönüşümünün kullanımı, yeraltındaki nesnelerin daha doğru ve güvenilir bir şekilde sınıflandırılmasına da katkıda bulunur [54]. Gürültünün etkin bir şekilde azaltılması, GPR sinyallerinin daha net bir şekilde işlenmesini sağlar. Böylece tespit edilen nesnelerin sınıflandırılmasında daha yüksek doğruluk oranlarına ulaşılmasına olanak tanır [54, 55].

2.2.4 Fourier Dönüşüm

Fourier Dönüşümü (Fourier Transform), sinyal ve görüntü işleme alanlarında kullanılan temel analiz yöntemlerinden biridir. Fourier dönüşümü, bir sinyali frekans domenine dönüştürerek sinyali oluşturan frekans bileşenlerini açığa çıkarır.

Bu, sinyalin frekans özelliklerini anlamak ve analiz etmek için son derece kullanışlıdır. Fourier dönüşümü, frekans bileşenlerine ayrılan sinyallerin genlik ve faz bilgilerini sağlar. Bu da özellikle sürekli sinyallerin incelenmesinde önemli avantajlar sunar. Ancak, yalnızca frekans bilgisinin elde edilmesi, özellikle zaman veya uzamsal alanda geçici olayları analiz etmek gerektiğinde bir sorun olarak ortaya çıkar [56, 57].

Fourier dönüşümünün temel matematiksel yapısı, bir sinyalin kompleks eksponansiyel fonksiyonlarla çarpılmasına dayanır. Zaman veya uzamsal alandaki bir sinyalin Fourier dönüşümü, her bir frekans bileşenini belirlemek için sinyalin tamamına uygulanır. 2 boyutlu Fourier dönüşümü ise bir görüntünün hem yatay hem de dikey frekans bileşenlerini analiz eder. Matematiksel olarak, 2D Fourier dönüşümü şu şekilde ifade edilir:

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-i(ux+vy)} dx dy \quad (2.4)$$

Bu denklemde:

$f(x, y)$, analiz edilen görüntüyü ifade eder.

$F(u, v)$, Görüntünün frekans domenindeki gösterimidir.

u ve v , frekans bileşenlerini temsil eder.

$e^{-i(ux+vy)}$, kompleks eksponansiyel terimdir.

Fourier dönüşümünün bu frekans analiz yeteneği, özellikle sinyallerdeki tekrar eden desenleri veya periyodik yapıları tespit etmede çok etkilidir. Örneğin, bir görüntüde veya sinyalde hangi frekans bileşenlerinin baskın olduğunu anlamak, bu yapının genel özelliklerini incelemek için kritik bir adım olabilir. Fourier dönüşümü, kenar tespiti, görüntü iyileştirme, filtreleme ve spektral analiz gibi birçok sinyal işleme uygulamasında kullanılır [58, 59].

GPR verilerinde Fourier dönüşümünün kullanımı, sinyallerin frekans içeriğini analiz ederek yer altındaki nesnelerin özelliklerini daha iyi anlamamızı sağlar. Özellikle GPR sinyallerinin frekans bileşenleri, nesnelerin konumu, boyutu ve malzeme özellikleri hakkında önemli bilgiler sunabilir. GPR sinyalleri genellikle yer altındaki farklı katmanlardan yansıyan karmaşık sinyallerdir ve Fourier dönüşümü bu sinyalleri frekans alanında analiz ederek, farklı materyallerin ya da nesnelerin neden olduğu frekans farklılıkları ortaya çıkarabilir [60, 61].

Fourier dönüşümünün sağladığı frekans bilgisi, GPR verilerindeki gürültünün azaltılmasında da önemli rol oynar. Frekans domenine dönüştürülen sinyaller, belirli frekans aralıklarında filtrelenerek istenmeyen gürültüler etkin bir şekilde ortadan kaldırılabilir. Bu, özellikle yer altındaki nesnelerin daha doğru bir şekilde lokalize edilmesi ve analiz edilmesi için kritik bir adımdır. Gürültü azaltmanın yanı sıra Fourier dönüşümü, GPR sinyallerindeki farklı frekanslardaki yansılardan

elde edilen verileri ayrıştırarak, nesnelerin yapısal özelliklerini daha net bir şekilde ortaya koyabilir [62, 63, 64].


2.3 Arka Plan Çıkarımı

İşlenmemiş GPR verileri hem arka plan sinyalleri hem de çeşitli gürültü kaynakları içerebilir ve bu durum yer altı yapılarının belirlenmesini zorlaştırır. Arka plan çıkarımı, GPR verilerinin işlenmesinde kritik bir adımdır çünkü yer altındaki hedeflerin daha net tespit edilmesi ve doğru bir analiz yapılması için gereklidir [65, 66, 67, 68]. Arka plan sinyalleri, anten yapısından, toprağın doğal yapısından veya çevresel koşullardan kaynaklanabilir ve bu sinyaller, yer altındaki hedefleri maskeleyerek yanlış sonuçlar üretilmesine yol açabilir. Dolayısıyla, arka plan sinyallerini çıkararak veri kalitesini artırmak, yer altı yapılarının güvenilir bir şekilde tespit edilmesi için temel bir gerekliliktir.

GPR verilerinde arka plan sinyallerini çıkarmak için pek çok farklı teknik geliştirilmiştir. En yaygın kullanılan yöntemlerden bazıları şunlardır: ortalama alma [14, 68, 69], medyan filtresi [14, 70, 71], temel bileşen analizi (PCA) [72, 69], bağımsız bileşen analizi (ICA) [71, 69], arka plan matris çıkarımı (BMS) [73, 74], bulanık ağırlıklı yöntemler (fuzzy weighted) [67] ve diğer çeşitli algoritmalar [75, 76, 77, 78, 79]. Ortalama alma yöntemi, hızlı ve kolay bir uygulama sunarak sıkça tercih edilen bir tekniktir [14, 68]. Medyan filtresi, gürültüleri azaltırken verinin temel özelliklerini korumak açısından avantajlıdır. PCA ve ICA gibi yöntemler ise, daha karmaşık yapılar içeren verilerde farklı bileşenleri ayrıştırarak verinin içsel özelliklerini ortaya çıkarır. BMS, büyük veri setlerinde ve yüksek boyutlu verilerde etkili bir yöntem olarak öne çıkarken [73, 74], bulanık ağırlıklı yöntemler belirsiz ve değişken arka plan sinyallerinin daha hassas bir şekilde çıkarılmasını sağlar [67].

Her yöntemin kendine özgü avantajları ve dezavantajları vardır. Örneğin, ortalama alma ve medyan filtresi basit yöntemler olup hızlı sonuç verirken, PCA ve ICA gibi yöntemler daha fazla işlem gücü gerektirir. Ancak bunlar daha derin analizler sunabilir. Dolayısıyla, kullanılacak yöntemin seçimi, verinin yapısına ve analiz amacına bağlıdır. Bazı durumlarda, birden fazla yöntemin kombinasyonu da verilerin daha doğru işlenmesine katkı sağlayabilir.

Şekil 2.11’te GPR B-tarama görüntüsüne, ortalama alma işlemi ile arka plan çıkarımı işleminin uygulama senaryosu görülmektedir. Ortalama alma ile arka plan çıkarımı önceden belirlenmiş boyuttaki (P) bir pencere içindeki A-tarama verilerinin derinlik bazlı ortalamalarının hesabı sonrası elde edilen ortalama A-tarama verilerinin görüntünün diğer sütunlarından çıkarılmasıdır. Bu işlemler sabit ve dinamik arka plan çıkarımı diye ikiye ayrılır [67].



Şekil 2.11 GPR arka plan çıkarma senaryosu

$a_x(z)$: x pozisyonunda Ham A-scan sinyali (sütun vektörü)

$b(z)$: A-tarama arka sinyal plan tahmini

$s_x(z)$: x pozisyonunda Ham A-scan hedef sinyali tahmini

N : A-scan sinyal uzunluğu

M : B-scan görüntüde bulunan A-scan sinyal sayısı

P : Arka plan hesaplama penceresi uzunluğu


2.3.1 Sabit Arka Plan Çıkarımı

Sabit arka plan çıkarma yöntemi ile arka plan çıkarmı yapmak için ilk başta şekil 2.11b’de görüldüğü gibi arka plan hesaplama penceresi uzunluğu $-P$ belirlenir. Bu işlemin ardından belirlenen uzunluğa göre her satır için ayrı ayrı değerler ortalaması bulunup kalan kısımlardan çıkarılır. Örneğin elimizde 256×237 boyutunda B-tarama GPR görüntü matrisi olsun ve P değeri 15 olsun. Bu görüntü matrisinin ilk 15 sütununda bulunan satırların ortalaması alınmakta ve ortalama A-tarama sinyali

elde edilmektedir. Yani elde edilen sonuç 1×256 boyutunda bir vektör olur. Bu vektörün görüntünün geri kalan kısmından sütun sütun çıkarılması ile sabit arka plan çıkarım işlemi tamamlanır. Örnek bir sabit arka plan çıkarımı şekil 2.12’de görülmektedir.



a) GPR ham veri



b) Sabit arka plan çıkarımı yapılmış GPR verisi


Şekil 2.12 GPR sabit arka plan çıkarımı

2.3.2 Dinamik Arka Plan Çıkarımı

Dinamik arka plan çıkarım yöntemi, sabit arka plan çıkarım yöntemlerine benzemekle birlikte sabit arka plan çıkarımından farkı şekil 2.11b’de görülen P genişlikli pencerenin GPR veri toplama yönünde hareket ederek her adımda yeni bir ortalama hesaplayıp çıkan sonucun bir sonraki sütundan çıkartılmasıdır. Şekil 2.13’de dinamik arka plan çıkarımı yapılmış örnek bir GPR verisi görülmektedir. Hem sabit arka plan çıkarımında hem de dinamik arka plan çıkarımında belirlenen kayan pencere boyutuna göre ilk adımlar veri içermez. Çünkü ilk adımda belirlenen pencere boyutundaki değerlerin ortalaması alındıktan sonra kayan penceredeki bütün sütunlara aynı değerler atanır. Örneğin kayan pencere boyutu $P=15$ olarak belirlendiğinde, ilk 15 sütunun ortalaması alındıktan sonra elde edilen sonuç değeri, bu sütunlara doğrudan atanır. 15.sütundan sonra elde edilen ortalama sonuç değeri diğer sütunlardan çıkartılarak arka plan çıkarımı yapılır. Şekil 2.12b ve şekil 2.13b’ye bakıldığında görüntünün sol tarafında veri içermediği net bir şekilde görülmektedir.



a) GPR ham veri



b) Dinamik arka plan çıkarımı yapılmış GPR verisi

Şekil 2.13 GPR dinamik arka plan çıkarımı

2.4 Eşikleme

Eşikleme, görüntü işleme ve sinyal analizi alanında, verilerin belirli bir eşik değeri temel alınarak ön planın ortaya çıkarılmasını sağlayan temel bölütleme (segmentation) yöntemlerinden biridir [80]. GPR verilerinin işlenmesinde eşikleme teknikleri, hedef nesnelerin tespiti ve gürültünün etkili bir şekilde azaltılması için yaygın olarak kullanılmaktadır. Eşikleme yöntemleri, basit ve hızlı bir çözüm sunmalarına rağmen, doğru bir eşik değerini otomatik olarak belirlemek veri setinin özelliklerine göre büyük bir öneme sahiptir. Literatürde çok sayıda eşikleme yöntemi önerilmiş olup, her bir yöntem farklı veri türleri ve amaçlara yönelik avantajlar sunmaktadır. Sezgin ve Sankur'un [80] eşikleme yöntemleri üzerine gerçekleştirdiği kapsamlı çalışma, bu tekniklerin farklı uygulama senaryolarındaki etkinliğini değerlendiren önemli bir kaynaktır.

Global eşikleme, tüm görüntüde tek bir eşik ile bölütlemenin yapıldığı tekniktir [36]. Histogram tabanlı analiz ile belirlenen sabit eşik değerleri, homojen arka plana sahip görüntülerde etkili sonuçlar sağlamaktadır.

Adaptif (Lokal) eşikleme yöntemleri, küçük görüntü parçacıkları için farklı eşik değerleri belirleyerek yerel özelliklere göre karar verir. Bu yöntem, düzensiz aydınlatma ve karmaşık arka planlar gibi zorlu koşullarda daha etkili sonuçlar verir [36, 80]. Adaptif eşikleme, GPR verilerindeki sinyal farklılıklarını ve arka plan gürültüsünü dikkate alarak her bölgede eşik değerini belirler. Bu sayede, yerel zıtlıklar artırılabilir ve hedeflerin daha net bir şekilde tespiti sağlanabilir. Ancak, adaptif eşikleme yöntemleri daha hesaplama yoğun olabileceğinden işlem süresi uzayabilir [81].


Otsu yöntemi, sınıflar arası varyansı maksimize eden bir eşikleme algoritması olarak, ikili sınıflandırma problemlerinde yaygın olarak kullanılmaktadır [36]. GPR uygulamalarında, Otsu yöntemi hedef nesne ile arka plan arasında belirgin kontrast olduğu durumlarda etkili bir çözüm sunmaktadır. Ancak, çoklu sınıflandırma gerektiren durumlarda yöntemin doğrudan uygulanabilirliği sınırlı olabilmekte ve ek algoritmaların entegre edilmesi gerekmektedir [82].

Çoklu Eşikleme (Multi-level Thresholding), birden fazla eşik değeri kullanarak görüntüyü birden fazla sınıfa ayırma işlemidir [82, 80]. Bu yöntem, özellikle farklı özelliklere sahip çoklu nesnelerin bulunduğu görüntülerde, her sınıf için farklı eşik değerleri belirlenerek uygulanabilir.


Yapay zekâ tabanlı eşikleme yöntemleri, son yıllarda geleneksel eşikleme tekniklerine kıyasla daha üstün sonuçlar elde edebilmek için kullanılmaya başlanmıştır. Bu yöntemler, veriye özel eşik değerlerini otomatik olarak belirlemek ve daha karmaşık sınıflandırma problemlerini çözmek için kullanılmaktadır [83].

Şekil 2.14'te ikili hale dönüştürülen GPR B-tarama görüntüleri görülmektedir. Şekil 2.14a'da yatay bant geçiren filtre uygulanmamış GPR verisine adaptif eşikleme yapıldığında elde edilen GPR verisi görülmektedir. Şekil 2.14b'de ise yatay bant


geçiren filtre uygulanmış GPR verisine adaptif eşikleme kullanılarak elde edilmiş GPR veri görülmektedir. Şekil 2.14c’de ise Gabor filtresi uygulanmış GPR verisine eşik değeri 89 olarak belirlenen sabit eşikleme uygulanarak elde edilen ikili GPR verisi görülmektedir.



a) Yatay bant geçiren filtre uygulanmamış GPR verisinin ikili görüntüsü



b) Yatay bant geçiren filtre uygulanmış GPR verisinin ikili görüntüsü



c) Gabor filtresi uygulanmış GPR verisinin ikili görüntüsü

Şekil 2.14 İkili GPR B-tarama verileri

2.5 İkili (Binary) Görüntülerde Filtreleme Yöntemleri


İkili görüntülerde filtreleme, nesnelerin tespiti ve gürültünün giderilmesi için önemli bir adımdır. Bu işlem, morfolojik filtreleme ve yumuşatma filtreleri gibi yöntemlerle gerçekleştirilir. Morfolojik işlemler, görüntüdeki şekil özelliklerini iyileştirirken, yumuşatma filtreleri pikseller arasındaki geçişleri yumuşatarak görüntüdeki gürültüyü azaltır. Bu teknikler, özellikle GPR verilerinde daha net ve doğru sonuçlar elde edilmesine yardımcı olur.

2.5.1 Morfolojik İşlemler

Biyolojide canlıların şekil ve yapıları ile ilgilenen dala morfoloji (biçim bilimi) denir [84]. Matematiksel morfoloji ise temel küme işlemlerine dayanan ve görüntülerdeki sınırların, iskelet yapılarının tanımlanması ve çıkarılması, gürültü giderimi ve bölütleme gibi uygulamalar için kullanılan bir tekniktir. Bu teknik, görüntü işlemlerinde sıkça kullanılan morfolojik filtreleme, görüntüdeki şekil ve

yapıları inceleyerek ve manipüle ederek belirli özellikleri ortaya çıkarma ve istenmeyen bileşenleri kaldırmak için kullanılır.

Morfolojik işlemler, bir giriş görüntüsüne belirli bir yapılandırma elemanı (structuring element) uygulanarak aynı boyutta bir çıktı görüntüsü oluşturmayı hedefler [36, 43]. Bu süreçte, çıktı görüntüsündeki her pikselin değeri, giriş görüntüsündeki ilgili pikselin çevresindeki komşu piksellerle karşılaştırılarak belirlenir. Yapılandırma elemanı, morfolojik işlemlerin bir bileşenidir ve genellikle küçük, belirli bir şekle sahip bir matristir. Bazı yaygın yapılandırma elemanı türleri şunlardır [36]: dikdörtgen (rectangle), kare (square), elips (ellipse), elmas (diamond), disk ve çizgi (line) şeklindedir. Bu elemanlar, görüntü üzerinde kaydırılarak işlemler gerçekleştirilir. Yapılandırma elemanının şekli ve boyutu, işlenecek görüntünün özelliklerine ve hedeflenen sonuca bağlı olarak dikkatle seçilir. Örneğin bir görüntüdeki yol veya boru gibi uzunlamasına nesneleri belirlemek için çizgi (line) yapılandırma elemanları kullanılabilir veya kare (square) yapılandırma elemanı dikdörtgenlere benzer şekilde genişlemelerde ve büyütme işlemlerinde kullanılır. Şekil 2.15’de bazı yapısal eleman matrisleri görülmektedir.



Şekil 2.15 Temel yapısal elementler

Küçük yapısal elemanları (örneğin, 3x3 boyutunda) küçük detayları ve gürültüleri temizlemek için kullanılırken, daha büyük yapısal elemanları (örneğin, 7x7 boyutunda) daha büyük nesneleri ve yapıları işlemek için kullanılır. Aşağıda, GPR işlemede kullandığımız matematiksel morfoloji işlemleri açıklanmıştır.


2.5.1.1 Erozyon (Erosion)

Erozyon işlemi, bir görüntüdeki nesneleri küçültmek ve ince yapıları yok etmek için kullanılır [85]. Yapılandırma elemanı (structuring element), görüntü üzerinde kaydırılarak, her konumda yapısal elemanın tamamen nesne pikselleri ile örtüşüp örtüşmediğine bakılır. Eğer örtüşme tam değilse, o konumdaki nesne pikselleri kaldırılır. Bu, özellikle küçük gürültülerin temizlenmesi ve nesnelerin inceltilmesi için etkilidir. Matematiksel olarak aşağıdaki gibi gösterilir [85]:

$$A \ominus B = \{z \mid B_z \subseteq A\} \quad (2.5)$$

Burada A matrisi, görüntüyü temsil ederken, B matrisi yapılandırma elemanını, $\ominus$ ise erozyon işlemi temsil eder. Formülde, B_z , B yapısal elemanının z konumunda kaydırılmasını ifade eder. Eğer B yapısal elemanı, A görüntüsü içinde tamamen yer alıyorsa, z konumundaki piksel korunur. Morfolojik işlemler hem gri tonlamalı hem de ikili görüntülerde kullanılabilir, bu nedenle probleme göre farklı yapılandırma

elemanları seçilir. Seçilen yapısal elemanın şekli ve boyutu, işlenecek görüntünün özelliklerine ve hedeflenen sonuca bağlı olarak belirlenir. Şekil 2.16’te ikili GPR görüntüsüne farklı boyutlarda uygulanmış erozyon işlemi görülmektedir.



Şekil 2.16 İkili GPR B-tarama verilerine erozyon işlemi uygulanması

2.5.1.2 Genişleme (Dilation)

Genişleme işlemi, bir görüntüdeki nesneleri büyütmek ve küçük boşlukları doldurmak için kullanılır [85, 86]. Yapılandırma ögesi, görüntü üzerinde kaydırılarak, her konumda yapısal elemanın herhangi bir parçasının nesne pikselleri ile örtüşüp örtüşmediğine bakılır. Eğer herhangi bir örtüşme varsa, o konumdaki piksel nesne pikseli olarak belirlenir.

Genişleme işlemi matematiksel olarak şu şekilde ifade edilir [85].

$$A \oplus B = \{z \mid (B)_z \cap A \neq \emptyset\} \quad (2.6)$$

Burada A, işlenecek görüntü matrisini, B uygun şekilde belirlenmiş yapısal elementi ve $\oplus$ ise genişleme işlemini temsil etmektedir. Genişleme yaygın olarak görüntünün içindeki kopuk bölge ya da nesnelerin birleştirilmesinde kullanılmaktadır.

2.5.1.3 Açma (Opening)

Açma işlemi, görüntüdeki küçük detayları ve gürültüleri ortadan kaldırmak için belirli bir yapılandırma elemanı kullanılarak yapılır. Açma işlemi genellikle ikili görüntü üzerinde uygulanır ancak gri seviyeli versiyonları da vardır. İlk aşamada, giriş görüntüsü olan A matrisi, B yapılandırma elemanı ile erozyona uğratılır [36, 85]. Bu işlem, görüntüdeki küçük nesneleri ve ince detayları yok eder. Erozyon, yapılandırma elemanının tüm piksellerinin A görüntüsünde nesne pikselleri ile tam olarak örtüşmesi esasına dayanır. Bu adım tamamlandıktan sonra, aynı yapılandırma elemanı kullanılarak genişleme işlemi uygulanır. Genişleme, erozyon sırasında küçülen nesnelerin orijinal boyutlarına yakın bir hale gelmesini sağlar. Açma işlemi matematiksel olarak şu şekilde tanımlanır [85] :

$$A \circ B = (A \ominus B) \oplus B \quad (2.7)$$

Açma işlemi, özellikle küçük ve izole gürültülerin temizlenmesinde oldukça etkilidir. Erozyon, küçük gürültü parçalarını ortadan kaldırırken, genişleme işlemi nesneleri tekrar büyütürken orijinal şekillerine yakın hale getirir. Bu süreç, görüntüdeki küçük detayların ve ince yapıların temizlenmesi için kullanılır. Açma işlemi, büyük nesnelerin genel şekillerini korurken, küçük çıkıntıları ve detayları temizler. Bu nedenle, görüntüdeki büyük yapıların bozulmadan kalmasını sağlar. Açma işlemi, birçok görüntü işleme uygulamasında kritik bir rol oynar ve çeşitli problemlerin çözümünde etkili bir yöntem olarak kullanılır.


2.5.1.4 Kapama (Closing)

Closing işlemi, özellikle gürültülü veya bozulmuş görüntülerde nesnelerin konturlarını düzeltmek ve eksik bölgeleri doldurmak için etkilidir. Bu işlem, bir görüntü üzerinde önce bir genişletme (dilation) ve ardından bir erozyon (erosion) işlemi uygulanarak gerçekleştirilir [36, 41, 84]. Bu işlemin matematiksel ifadesi şu şekildedir [85].


$$A \cdot B = (A \oplus B) \ominus B \quad (2.8)$$

2.5.1.5 İskelet (Skeleton)

İskeletleştirme işlemi, bir görüntüdeki nesnelerin iskeletini (skeleton) çıkarmak için kullanılan bir morfolojik işlemdir. İskelet, bir nesnenin “iskelet” yapısını temsil eder. İskelet, bir nesnenin topolojik yapısını korurken, gereksiz detayları ve yan dalları çıkarır [85, 86]. Bu, görüntüdeki nesnelerin daha basit bir temsilini sağlar ve morfolojik analiz için daha uygun hale getirir. İskeletleştirme işlemi, özellikle nesne tanıma, desen tanıma ve görüntü eşleştirme gibi uygulamalarda kullanılır.



a) İkili GPR görüntüsü



b) İskelet uygulanmış ikili GPR görüntüsü

Şekil 2.17 İkili görüntüye iskeletleştirme uygulama örneği

İskeletleştirme işlemi, bir görüntü üzerinde ardışık erozyon ve genişletme işlemleriyle gerçekleştirilir. İlk olarak, giriş görüntüsüne bir dizi erozyon

uygulanarak, nesnelerin dış hatları inceltilir ve tek piksel genişliğinde bir yapı oluşturulur [36]. Ardından, bu inceltirilmiş görüntü üzerine bir dizi genişletme uygulanarak iskelet elde edilir. Genişletme işlemi, nesnelerin dış hatlarını takip ederken, iç kısımlarını çıkarır ve nihai iskeleti oluşturur. Şekil 2.17’te ikili GPR verisine iskelet işlemi uygulaması gösterilmiştir.

2.5.1.6 Yumuşatma Filtreleri (Smoothing Filter)

Yumuşatma filtreleri, bir görüntüdeki keskin kenarları ve görüntüdeki gürültüleri azaltmak için kullanılan filtrelerdir [87]. Bu filtreler, bir pikselin değerini, çevresindeki piksellerin değerlerinin bir ortalama veya ağırlıklı ortalama değerleriyle değiştirerek çalışır. Yumuşatma filtreleri, bir görüntüdeki keskin geçişleri yumuşatarak ve görüntüdeki küçük detayları bastırarak görüntünün daha homojen ve pürüzsüz olmasını sağlar [87, 88].

Yumuşatma filtrelerinin çeşitli türleri vardır ancak en yaygın olarak kullanılan ve GPR görüntüsünün ön işleme aşamasında kullandığımız çeşitleri ortalama filtresi, medyan filtresi ve Gauss filtresidir.

Filtreleme yaparken, girdi görüntüsü $h(i,j)$, filtre maskesi $f(i,j)$ ile konvolüsyona tabi tutulur. Bu matematiksel olarak şu şekilde ifade edilir [88].

$$g(i,j) = f(i,j) * h(i,j) \quad (2.9)$$

Burada $*$ işareti konvolüsyon operatörünü temsil eder.

➤ Konvolüsyon işlemi

Bir çekirdek şablonun (matris veya kernel) bir resmin üzerinde kaydırma ve piksel çarpımlarının toplamı işlemleriyle konvolüsyon gerçekleştirilir [88]. Belirli özel uygulamalar için çeşitli standart şablonlar mevcuttur. Şablonun boyutu ve şekli, gerçekleştirilen işlemin karakterini belirler. Örneğin, ortalama (mean) ve Laplace operatörlerinin (3x3) çekirdek şablonları (kernel matrisleri) şekil 2.18’de verilmiştir.

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

Ortlama(mean)

0	-1	0
-1	4	-1
0	-1	0


Laplace

Şekil 2.18 Konvolüsyon matrisleri

➤ Ortalama Filtresi (Mean Filter)


Ortalama filtresi, bir pikselin değerini, önceden belirlenmiş filtre boyutuna göre çevresindeki piksellerin aritmetik ortalaması ile değiştirir [36]. Bu sayede, görüntüde çevresine uymayan piksel değerleri değiştirilir. Bu filtreler gürültüyü azaltmak için etkilidir, fakat kenarları veya detayları korumada genellikle zayıf

kalırlar [36, 41]. Ortalama filtresi bir konvolüsyon filtresi türüdür ve çekirdek şablon (kernel) temeline dayanır [44]. Genellikle 3×3 boyutunda bir kare çekirdek şablon kullanılır, ancak bazı yumuşatma işlemlerinde daha büyük şablonlar (örneğin 5×5 veya 7×7) tercih edilebilir. Büyük şablonların tek geçişte yarattığı etki, küçük şablonların birden fazla geçişle de elde edilebilir. Ortalama filtresinin görüntü üzerinde uygulanması şekil 2.19’de gösterilmiştir.



Şekil 2.19 3x3 filtre boyutunda ortalama filtresi uygulanması


Ortalama Filtresi diğer görüntülerde olduğu gibi GPR görüntüsünde de gürültüyü azaltmak için kullanılmaktadır. Şekil 2.20’de GPR görüntüsüne ortalama filtresi 3x3 filtre boyutunda uygulandığı zaman elde edilen GPR görüntüsü görülmektedir. Ortalama filtresi bu örnekte ikili GPR görüntüsüne uygulanmıştır.



Şekil 2.20 GPR verilerine ortalama (mean) filtresi uygulanması

➤ Medyan Filtresi (Median Filter)

Medyan Filtresi, görüntü işlemede yaygın olarak kullanılan ve görüntülerdeki gürültüyü azaltma, kenar koruma ve görüntü yumuşatma gibi çeşitli amaçlar için tercih edilen bir filtreleme yöntemidir [36, 41, 89]. Resim üzerindeki detayların kaybolmaması noktasında ortalama (mean) filtresinden daha iyi sonuç verir. Bu filtre, Şekil 2.20'de görüldüğü gibi her bir pikselin değerini, çevresindeki piksellerden oluşan bir pencerenin ortanca değeriyle değiştirerek çalışır. Yani, piksel değerlerinin yarısı bu ortanca değerden büyük, diğer yarısı ise küçüktür. Diğer filtrelerin aksine, medyan filtresi istatistiksel hesaplamalarla değil, piksel değerlerinin sıralanması ve ortanca değerin seçilmesi yoluyla çalışır [36, 43]. Bu özellikle kenarlarda veya detaylı yapıların olduğu bölgelerde etkili sonuçlar sağlar. Zira medyan filtresi kenar koruma yeteneğine sahiptir [90].




Şekil 2.21 3x3 filtre boyutunda medyan filtresi uygulanması

Medyan filtresinin bir diğer avantajı, işlem süresinin diğer filtreleme tekniklerine göre daha kısa olmasıdır. Çünkü her piksel için çevresindeki piksellerin sıralanması gerekmeyle birlikte, bu işlem genellikle hızlıdır. Ancak, medyan filtresinin dezavantajları da vardır. Özellikle büyük bir filtre boyutu kullanıldığında, görüntüdeki detayların kaybına veya bulanıklığa neden olabilir. Ayrıca, medyan filtresi tüm gürültü tiplerine karşı etkili değildir ve bazı durumlarda istenmeyen sonuçlara yol açabilir. Şekil 2.21'de, 3x3 boyutunda bir filtre belirlenmiştir. Bu filtre, görüntü matrisindeki her pikseli ortalayacak şekilde matris üzerinde

kaydırılmıştır. Her adımda, 9 piksel değeri küçükten büyüğe sıralanmış ve ortadaki değer, o pikselin yeni değeri olarak atanmıştır.

GPR görüntülerinde medyan filtresi gürültü giderme amacıyla kullanılmıştır. Medyan filtresi bu çalışmada hem bir boyutlu hem de iki boyutlu olarak kullanılmıştır. Şekil 2.22’te Arka plan çıkarılmış ve 0-255 arasına normalize edildikten sonra ikili görüntüye çevrilmiş görüntüye 3x3 boyutunda medyan filtresi uygulanan GPR verisi görülmektedir.




Şekil 2.22 GPR verilerine medyan (median) filtresi uygulanması

➤ Gauss Filtresi (Gaussian Filter)

Gauss yumuşatma operatörü, görüntüleri bulanıklaştırmak ve gürültüyü azaltmak amacıyla kullanılan 2 boyutlu bir maskedir [36, 41, 43, 90]. Bu maske, çekirdek matrisin görüntüdeki piksellerle çarpılıp toplanmasıyla çalışır. Gauss filtresi, her pikselin değerini, komşu piksellerin ağırlıklı ortalaması ile değiştirir. Bu ağırlıklar denklem 2.10’te verilen bir Gauss dağılımı fonksiyonu ile belirlenir [36, 41].

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{\left(-\frac{x^2+y^2}{2\sigma^2}\right)} \quad (2.10)$$

Bu formülde, $G(x,y)$ filtre çekirdeğinde bulunan her bir elemanın temsil eder. x ve y , filtre çekirdeğinin merkezinden uzaklığıdır. σ ise Gauss fonksiyonunun standart sapmasıdır. Standart sapma değeri arttıkça, Gauss filtresinin etkisi genişler. Şekil 2.23’da 0-255 arasındaki GPR verisine Gauss filtresi uygulaması görülmektedir.



Şekil 2.23 GPR verilerine Gauss filtresi uygulanması

2.6 Öznitelik Çıkarımı

Öznitelik çıkarımı, verilerin içerdiği bilgileri sayısal büyüklüklere dönüştürme işlemidir. Bu adım; örüntü tanıma, makine öğrenmesi ve sinir ağları tabanlı sınıflandırma yöntemlerinde temel bir işlemdir. Öznitelikler, bir nesnenin veya görüntünün belirli özelliklerini temsil eder ve genellikle parlaklık, renk, kenarlar, köşeler ve dokular gibi önemli nitelikleri içerir.

Öznitelik çıkarımı sonrasında uygulanan örüntü tanıma işlemi verilerdeki düzenliliklerin, ilişkilerin ve anlamlı yapıların belirlenmesini sağlar. Bu süreç, çıkarılan özniteliklerin işlenmesi ve belirli sınıflara atanmasıyla gerçekleştirilir. Örneğin, bir görüntüdeki kenarların veya köşelerin tespiti, bu yapıların belirli bir nesneyi temsil edip etmediğini anlamak için kullanılan bir örüntü tanıma işlemi olarak düşünülebilir. Örüntü tanıma, genellikle makine öğrenmesi ve sinir ağları gibi yöntemler aracılığıyla çıkarılan özniteliklerin analiz edilmesini ve verideki karmaşık yapıların anlamlandırılmasını mümkün kılar.

Literatürde, GPR verilerinden öznitelik çıkarımı için pek çok farklı yöntem önerilmiştir. Fourier ve dalgacık dönüşümleri, frekans ve zaman-frekans çözümlemesi sağlayarak sinyalin detaylı analizine imkân tanımakta ve yüzey özelliklerinden etkilenmeyen nitelikler sunmaktadır [91]. Hedef alanına yönelik olarak ikili hale getirilmiş GPR görüntülerinden elde edilen alan, çevre, momentler gibi geometrik öznitelikler, gömülü nesnelerin fiziksel özelliklerini açıklamak için kullanılmaktadır [2], [92]. Kenar tespiti (edge detection) yöntemleri, GPR görüntülerinde nesnelerin sınırlarını belirleyerek, yeraltındaki yapılar ve nesneler hakkında önemli öznitelikler sağlar. Hiperbolik yansımalarla dayalı fiziksel parametreler ise nesnelerin şekil, boyut ve derinlik bilgilerini sağlamaktadır [2]. İstatistiksel öznitelikler arasında ortalama, varyans, enerji ve entropi gibi ölçütler, sinyalin yapısal özelliklerini anlamaya yönelik olarak öne çıkmaktadır [93].

Son yıllarda, derin öğrenme yöntemleri ile ham GPR verilerinden otomatik öznitelik çıkarımı gerçekleştirilmiş ve özellikle konvolüsyonel sinir ağları (CNN) kullanılarak sınıflandırma ve segmentasyon işlemleri yüksek başarı oranlarıyla uygulanmıştır [32]. Buna ek olarak, literatürde Gabor filtreleri gibi görüntü işleme tabanlı öznitelik çıkarım yöntemleri de kullanılmıştır. Gabor filtreleri, bir nesnenin farklı ölçeklerdeki ve yönlerdeki dokusal özelliklerini çıkarmakta etkili olup, yer altındaki gömülü nesnelerin doku farklılıklarını analiz etmede kullanılmaktadır [94].

2.6.1 Kenar Tespiti (Edge Detection)

GPR verilerinin sınıflandırılmasında, yeraltındaki nesnelerin sınırlarını ve yapısını belirlemek için kenar tespiti öznitelik çıkarım yöntemlerinden bir tanesidir [95]. Bu işlem, GPR görüntülerindeki nesnelerin kenarlarını belirleyerek, nesnelerin şekilleri, boyutları ve konumları hakkında bilgi sağlar [96]. Kenar tespiti algoritmaları, özellikle Sobel ve Canny gibi yöntemler, pikseller arasındaki parlaklık farklarını analiz ederek nesnelerin kenarlarını ortaya çıkarır [36].

Kenar tespiti, görüntülerdeki parlaklık değişimlerini ölçerek, nesnelerin sınırlarını belirlemeyi amaçlar [97]. Bu işlemde, her pikselin etrafındaki parlaklık farkları dikkate alınır ve bu farklar, nesnelerin kenarlarını tanımlamak için kullanılır. GPR verilerinde, bu teknik nesnelerin sınırlarını ve şekillerini belirleyerek yeraltındaki yapıların doğru sınıflandırılmasına yardımcı olur.


2.6.2 Parabol Uydurma

GPR verilerinin sınıflandırılmasında hedeften yansıyan dalgaların genel biçimi/örüntüsü önemli bir bilgi kaynağıdır. Bu bilgi eğri uydurma teknikleriyle de elde edilebilir. Özellikle, GPR sinyalleri parabolik eğrilerle modellenerek hedeflerin konumları belirlenebilir veya türleri hakkında tahminler yapılabilir [98, 99]. Parabolik eğrilerin bu süreçteki rolü, sinyallerin belirli bir matematiksel formata uydurulmasıyla hedefin özelliklerini analiz etmeyi sağlar. Bu yöntemde, ön işlemleri bitmiş ikili GPR verisi üzerinde eğri uydurma yöntemi uygulanmaktadır. Bu öznitelik çıkarma yönteminde, hedefin geri dönüş sinyalleri parabolik bir modelle temsil edilmektedir ve bu modelin analitik ifadesi nesnenin derinliği, elektriksel özellikleri ve ortamın fiziksel özelliklerine dair parametreleri içerir. Parabolik eğrinin matematiksel ifadesi şu şekildedir:

$$y = ax^2 + bx + c \quad (2.11)$$

Bu çalışmada, GPR görüntülerindeki ikili eşikleme işlemi ile elde edilen ön plan bölgesinde, en büyük 6 alana en uygun parabolik eğriyi tanımlayan a, b ve c katsayıları belirlenmiş ve bu katsayılar sınıflandırma aşamasında öznitelik olarak kullanılmıştır. Eğer ön plan bölgesinde 6 alan bulunmuyorsa, eksik alanların yerine

görüntü özneliliğine 0 değeri atanmıştır. Bu yaklaşım, hedeflerin daha doğru bir şekilde tanımlanmasına ve sınıflandırılmasına yardımcı olmuştur.



Şekil 2.24 GPR görüntüsüne parabol uydurma

2.6.3 Nesne Alanına Yönelik Öznitelikler

GPR verilerinde beyaz bölgelerin alanlarının, ortalamalarının, 2. moment ve 3. momentlerinin hesaplanması, yer altındaki nesneler hakkında ilave bilgi toplanmasına olanak sağlar [100]. Bu hesaplamalar, nesnelerin fiziksel boyutları, konumları ve yapısal özellikleri hakkında bilgiler sunar.

Alan hesaplaması, şekil 2.23b’de görülen beyaz bölgenin (ön bölge) büyüklüğünü belirleyerek, yer altındaki nesnelerin ne kadar geniş bir alan kapladığını ortaya koyar. Ortalama hesaplaması ise beyaz bölgelerin merkez koordinatlarını tespit ederek nesnelerin görüntü üzerindeki kesin konumlarını belirler[100]. Momentler ise daha ileri seviyede yapısal analiz sağlar. İkinci moment, bir nesnenin belirli bir eksen etrafında ne kadar yayıldığını ölçer ve bu sayede nesnelerin şekil ve dağılımlarını anlamaya yardımcı olur. İkinci moment sayesinde, nesnenin ne kadar simetrik olduğu ya da simetriden ne kadar sapma gösterdiği anlaşılabilir [101]. Üçüncü moment ise nesnelerin asimetri ve düzensizliklerini ölçerek yapısal bozuklukların tespitine olanak tanır [100]. Bu, özellikle karmaşık ya da düzensiz şekle sahip nesnelerin belirlenmesinde etkili bir yöntemdir. Bu hesaplamalar, nesnelerin konum ve yapılarını tespit etmede, dolayısıyla daha hassas ve güvenilir bir analiz sağlamada kritik rol oynar.

2.6.4 Fourier Dönüşümünden Elde Edilen Öznitelik


B-tarama GPR verilerinde Fourier dönüşümünün kullanımı verilerin analizi için güçlü bir yöntemdir. Bu dönüşüm, verinin frekans alanındaki bileşenlerini ortaya çıkararak, sinyalin spektral özelliklerinin analiz edilmesine imkân tanır. Fourier dönüşümü sonrası elde edilen 2 boyutlu frekans örüntüsü, verinin içerdiği yerel ve genel yapılar hakkında önemli bilgiler sağlar.

2 boyutlu Fourier dönüşümü uygulandıktan sonra elde edilen genlik görüntüsünün merkez bölgesindeki 128x128 boyutundaki kısım, öznitelik olarak alınmıştır. Şekil

2.25b’de ham GPR verisine 2 boyutlu Fourier dönüşümü uygulanarak elde edilen genlik bilgisi gösterilmektedir. Genlik görüntüsünün kullanılması, sinyalin frekans bileşenlerinin güç yoğunluğunu ifade ettiği için özellikle önemlidir. Bu merkez bölgesi, sinyalin frekans spektrumunun en baskın bileşenlerini içerir ve sınıflandırma için anlamlı bilgiler sağlar. Frekans spektrumunun bu bölgesinin vektör haline getirilerek kullanılması, sınıflandırma aşamasında sinyallerin temel özelliklerinin etkin bir şekilde temsil edilmesine imkân tanır. Bu işlem, verideki karmaşıklığın azaltılmasına ve sadece en önemli bileşenlerin öznitelik olarak kullanılmasına olanak tanır.



a) Ham GPR verisi



b) Fourier dönüşümünden elde edilen genlik bilgisi

Şekil 2.25 Fourier dönüşümünden elde edilen öznitelik

2.7 Makine Öğrenmesi

Makine öğrenmesi, bilgisayarların insan benzeri öğrenme yetkinlikleri kazanmasını sağlamak amacıyla geliştirilen algoritmalar ve yöntemlerin bir bütünüdür [102]. Makine öğrenmesi alanının temelleri, 1950’li yıllarda Alan Turing’in "Makineler düşünebilir mi?" sorusunu ortaya atmasıyla atılmıştır [103]. Turing, makinelerin insan zekasına sahip olup olamayacağını test etmek için Turing Testi’ni önermiştir. 1952’de Arthur Samuel, oynadıkça kendi performansını iyileştiren dama oynayan ilk bilgisayar programını geliştirmiştir [102]. 1960’larda k-en yakın komşu (k-NN) algoritması ve 1980’lerde yapay sinir ağları ve geriye yayılım (backpropagation) algoritması geliştirilmiştir. 1990’lar ve 2000’lerde SVM ve HMM gibi algoritmalar yaygınlaşmıştır [104]. Günümüzde makine öğrenmesi, büyük veri kümelerinin artışıyla daha da önemli hale gelmiştir. Bu alanın temel amacı, büyük veri setlerindeki örüntüleri keşfetmek, gelecekteki olaylara ilişkin öngörülerde bulunmak ve çeşitli otomasyon süreçlerini gerçekleştirmektir [102, 104, 105].

Makine öğrenmesi çalışmalarında, kullanılan veri türleri ve değişkenler modelin performansını doğrudan etkiler [106]. **Kategorik değişkenler**, sınıflandırılmış verileri temsil eder ve genellikle one-hot encoding gibi yöntemlerle sayısal formata dönüştürülür [107]. **Sayısal değişkenler**, yaş, gelir veya sıcaklık gibi ölçülebilir verilerden oluşur ve doğrudan matematiksel işlemlere uygun oldukları için daha az

ön işlem gerektirir [104]. **Metin tabanlı değişkenler** ise doğal dil işlemeye özgüdür; müşteri yorumları veya sosyal medya gönderileri gibi veriler TF-IDF veya word embeddings ile sayısal forma dönüştürülerek modele uygun hale getirilir [108]. Bu değişken türleri, algoritmaların veriyi anlamlandırmasına ve modelin performansını artırmasına katkı sağlar.

Makine öğrenmesi sürecinde yaygın olarak kullanılan üç ana öğrenme türü vardır [103]: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme. Her biri, belirli veri yapıları ve problem türleri için etkili çözümler sağlar.

2.7.1 Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme, etiketli veri setlerinden yararlanarak gelecekteki olayları öngörmeyi amaçlayan bir yöntemdir [103, 109]. Bu yöntemde, her veri noktasının doğru cevabı ile eşleştirildiği bir eğitim süreci bulunur ve iki ana alt kategoriye ayrılır. Bunlar sınıflandırma ve regresyondur.


Sınıflandırma: Sınıflandırma, etiketlenmiş eğitim verilerine dayanarak girdileri belirli sınıflara veya kategorilere ayırmayı amaçlar [103, 110]. Örneğin, bir görüntünün bir köpek mi yoksa bir kedi mi olduğunu belirleme amacı bu sınıflandırma türünün örnekleridir. Bu tür bir sınıflandırma, e-postaları spam mı yoksa spam olmayan mı olduğunu ayırt etmek veya müşteri geri bildirimlerini pozitif mi yoksa negatif mi olarak sınıflandırmak gibi çeşitli alanlarda da kullanılabilir. Sınıflandırma işleminde, girdilerin (X) çıktılara (Y) eşlendiği bir süreç söz konusudur [110]. Burada, çıktılar önceden tanımlanmış sınıflar kümesine (örneğin, {1, ..., C}) aittir ve C sınıf sayısını temsil eder. İki sınıf varsa ikili sınıflandırma, daha fazla sınıf varsa ise çoklu sınıflandırma şeklinde adlandırılır. Bu çıktılar farklı şekillerde uygulanır.

Bu kapsamda karar ağaçları (decision trees), lojistik regresyon (logistic regression), destek vektör makineleri (support vector machines), yapay sinir ağları (artificial neural networks) ve Random Forest gibi çeşitli denetimli sınıflandırma modelleri bulunmaktadır [103, 110]. Bu modeller, farklı veri setleri ve gereksinimler için çeşitli güçlere sahiptir ve uygulandıkları alanlarda farklı sonuçlar verebilirler.

Regresyon: Regresyon görevleri, modelin girdi ve çıktı verileri arasında sayısal bir ilişki kurmasını bekler [103, 110, 111]. Örneğin, bir evin fiyatını, evin büyüklüğü, bulunduğu bölge ve oda sayısı gibi özelliklere dayanarak tahmin hava durumu verilerine göre bir sonraki günün maksimum sıcaklığını öngörmek, bir aracın motor hacmi ve ağırlığı gibi özelliklere bağlı olarak yakıt tüketimini litre cinsinden hesaplamak veya geçmiş satış verilerine ve pazarlama harcamalarına dayanarak bir mağazanın gelecekteki günlük satış miktarını tahmin etmek regresyon problemlerine örnek olarak verilebilir. Denetimli öğrenme programlarında yaygın olarak kullanılan algoritmalar arasında Bayesian mantığı, doğrusal regresyon, doğrusal olmayan regresyon ve regresyon ağaçları yer alır [111]. Bayesian mantığı, model parametreleri hakkındaki önceki bilgileri analiz ederken, doğrusal regresyon bir değişkenin değerini başka bir değişkene dayanarak tahmin eder. Doğrusal

olmayan regresyon ise, veri noktalarının doğrusal olmayan bir ilişki paylaştığı durumlarda kullanılır.

Denetimli öğrenmede sıkça kullanılan algoritmalar arasında doğrusal regresyon, lojistik regresyon, Naive Bayes, karar ağaçları, Random Forest, destek vektör makineleri (SVM) ve yapay sinir ağları yer alır [110, 111]. Şekil 2.26’te denetimli makine öğrenme modeli görülmektedir.



Şekil 2.26 Makine öğrenmesi denetimli öğrenme modeli


2.7.2 Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenme, etiketlenmemiş veri setlerini kullanarak verideki saklı kalıpları ve yapıları ortaya çıkarmayı hedefler [103]. Bu yöntem, verinin doğal yapılarını keşfetmek için kullanılır ve iki ana alt türe ayrılır [103, 112]. Bunlar kümeleme ve boyut indirgemedir.

Kümeleme (Clustering): Kümeleme, benzer özelliklere sahip veri noktalarını bir araya getiren bir denetimsiz öğrenme yöntemidir [103, 113]. Amacı, veri noktalarını aynı kümeye daha benzer hale getirerek veri setini bölmektir [113]. Farklı türlerde kümeleme algoritmaları mevcuttur. Örneğin, ayırık kümeleme, her veri noktasının sadece bir kümeye ait olduğu bir yaklaşımı benimser. K-means algoritması [114] bu tür kümeleme yöntemlerinden birisidir. Örtüşen kümeleme (fuzzy clustering) de yaygındır ve Fuzzy C-means [115] algoritması ile gerçekleştirilir. Hiyerarşik kümeleme, veriyi bir hiyerarşi veya ağaç yapısı içinde düzenler. Böylelikle ilişkileri ve ortak özellikleri anlamak için kullanılır [113]. Birleştirici ve bölücü olmak üzere iki ana türü vardır. Son olarak, olasılıksal kümeleme, veri noktalarının farklı kümelerdeki üyeliklerini belirlemek için olasılık dağılımlarını kullanır [113].

Boyut İndirgeme (Dimensionality Reduction): Boyut indirgeme, veri setindeki değişken sayısını azaltarak analiz ve görselleştirmeyi kolaylaştıran bir süreçtir [103, 113, 116]. Bu yöntemlerden temel bileşen analizi (PCA), doğrusal bir yöntem olup, verinin temel yapısını koruyarak veri setini daha düşük boyutlara indirger. Diğer bir

boyut indirgeme yöntemi olan t-dağılımlı Stokastik Komşu Yerleştirme (t-SNE) ise doğrusal olmayan bir yaklaşım kullanarak verinin yerel yapısını korur ve daha etkili bir görselleştirme sağlar [113, 116]. Özellikle yüksek boyutlu veri setlerinde kullanılan bu teknikler, veri karmaşıklığını azaltarak algoritmaların verimliliğini artırır [116].



Şekil 2.27 Makine öğrenmesi denetimsiz öğrenme modeli

2.7.3 Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme, makine öğreniminin bir dalıdır ve belirli durumlarda en yüksek ödül elde etmek için uygun eylemleri seçmeyi amaçlar. Bu, yazılımlar ve makineler tarafından belirli bir durumda en iyi davranışı bulmak için kullanılır [117]. Denetimli öğrenmeden farklı olarak, Pekiştirmeli öğrenmede eğitim verileri doğru cevaplarla sunulmaz. Bunun yerine, Pekiştirmeli öğrenme ajanı, verilen görevi yerine getirmek için hangi eylemleri gerçekleştireceğine deneyimleri aracılığıyla kendi başına karar verir [117, 118].

Pekiştirmeli öğrenme, bir ortamda maksimum ödül elde etmek için en uygun davranışları öğrenmeye çalışır [118]. Bu süreçte, algoritmalar deneme-yanılma yöntemiyle öğrenir ve her eylemden sonra geri bildirim alarak sonraki adımlarını belirler. Bu tür sistemler, insan müdahalesine ihtiyaç duymadan bir dizi karar vermesi gereken otomatik karar sistemleri için son derece uygundur. Pekiştirmeli öğrenme, özellikle dinamik ve değişken ortamlarda uygulanır [119]. Pekiştirmeli öğrenme, oyunlar, robotik, otonom araçlar ve çeşitli optimizasyon problemlerinde yaygın olarak kullanılmaktadır.

Q-Öğrenme (Q-Learning): Pekiştirmeli öğrenmenin temel yöntemlerinden biri olan Q-öğrenme, ajanın belirli bir durumda en uygun eylemi seçmesini öğrenmek için Q-değerlerini tahmin ettiği ve güncellediği bir algoritmadır [118]. Bu yöntem, ödülleri maksimize etmek için en iyi aksiyonları bulmaya çalışır.

Derin Q-Ağları (DQN): Daha karmaşık ve büyük ölçekli ortamlarda Q-öğrenmenin performansını artırmak için Derin Q-Ağları kullanılır. DQN, derin

öğrenme ile Q-öğrenmeyi birleştirerek, daha karmaşık yapıları öğrenebilir ve zenginleştirilmiş bir strateji sunar [118, 120].

Politika Gradyan Yöntemleri (Policy Gradient Methods): Bir diğer pekiştirmeli öğrenme yaklaşımı olan Politika Gradyan Yöntemleri, doğrudan eylem politikalarını optimize ederek ajanın optimal eylem stratejisini öğrenmesini sağlar [121]. Bu yöntem, politikaların sürekli bir şekilde güncellenmesini sağlar ve özellikle büyük ve karmaşık eylem uzaylarında etkin çözümler sunar.

2.7.4 Model Başarısı Değerlendirme Yöntemleri

Makine öğrenmesi projelerinde modelin başarısını değerlendirmek, modelin performansını ve genelleme yeteneğini belirlemek için büyük bir öneme sahiptir. Model değerlendirme yöntemleri, modelin doğruluk oranını, hata oranlarını ve tahmin kabiliyetini ölçmek amacıyla kullanılır. Bu değerlendirmeler, modelin gerçek dünya verileriyle ne kadar iyi çalıştığını ve ne kadar güvenilir olduğunu anlamak için gereklidir.

2.7.4.1 Regresyon Modellerinde Başarı Değerlendirme

Regresyon modellerinin başarısını ölçmek için çeşitli metrikler ve yöntemler kullanılır. Bu metrikler, modelin tahmin performansını ve doğruluğunu değerlendirmek için önemlidir. Hedef değişkenin sürekli olduğu durumlarda yaygın olarak kullanılan bu metrikler şunlardır [122]:

➤ Ortalama Mutlak Hata (Mean Absolute Error – MAE)

MAE, tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını ifade eder. Bu metrik, modelin yaptığı hataların ortalama büyüklüğünü gösterir. MAE şu formülle hesaplanır [122, 123]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (2.11)$$

Burada, $\hat{y}_i$ tahmin edilen değer, y_i gerçek değer ve n toplam gözlem sayısıdır. MAE'nin düşük olması, modelin daha doğru tahminler yaptığını gösterir.

➤ Ortalama Kare Hatası (Mean Squared Error - MSE)

MSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını alır. Bu metrik, büyük hataları daha fazla cezalandırarak modelin performansını değerlendirir. MSE şu formülle hesaplanır [123]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (2.12)$$

MSE'nin düşük olması, modelin daha iyi performans gösterdiğini belirtir.

➤ Karekök Ortalama Kare Hatası (Root Mean Squared Error – RMSE)

RMSE, MSE'nin karekökünü alarak hata oranını orijinal birimlerde ifade eder. RMSE şu formülle hesaplanır [122]:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2.13)$$

RMSE, hataların büyüklüğünü daha anlamlı bir şekilde sunar ve modelin performansını değerlendirirken kullanılır.

➤ Ortalama Yüzde Hata (Mean Absolute Percentage Error - MAPE)

MAPE, tahmin hatalarının yüzdesel olarak ifadesini sunar. Bu metrik, tahmin hatalarının gerçek değerlere oranını gösterir ve şu şekilde hesaplanır [122]:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (2.14)$$

MAPE, farklı veri setleri arasında karşılaştırma yapmayı kolaylaştırır ancak sıfıra yakın gerçek değerlerde problem oluşturabilir.

2.7.4.2 Sınıflandırma Modellerinde Başarı Değerlendirme

Sınıflandırma modellerinin başarı değerlendirilmesi, modelin performansını ve doğruluğunu belirlemek için çeşitli metrikler ve yöntemler kullanılarak gerçekleştirilir [124, 123]. Sınıflandırma problemlerinde, modelin doğruluğunu, hata oranını ve genel performansını ölçmek için yaygın olarak kullanılan metrikler aşağıda açıklanmıştır.

➤ Karışıklık Matrisi (Confusion Matrix)

Karışıklık matrisi, modelin performansını dört temel bileşenle değerlendirir: doğru pozitifler (TP), yanlış pozitifler (FP), doğru negatifler (TN) ve yanlış negatifler (FN). Bu matris, modelin sınıflandırma başarısını detaylı bir şekilde analiz etmeye olanak sağlar [125].

	Tahmin: Pozitif	Tahmin: Negatif
Gerçek: Pozitif	TP	FN
Gerçek: Negatif	FP	TN

➤ Doğruluk (Accuracy)

Doğruluk, modelin doğru tahmin ettiği örneklerin toplam örneklere oranını ifade eder. Sınıflandırma modellerinde, regresyon modellerine kıyasla daha basit bir değerlendirme ölçütü olan doğruluk (Accuracy) yöntemi yaygın olarak kullanılır. Genel performansın hızlı bir ölçümünü sağlar, ancak sınıf dengesizliği olan veri setlerinde yanıltıcı olabilir [125]. Doğruluk şu şekilde hesaplanır:

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.15)$$

➤ **Kesinlik (Precision)**

Kesinlik, modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu ölçer. Yanlış pozitiflerin etkisini minimize etmek için kullanılır [125]. Kesinlik şu şekilde hesaplanır:

$$Kesinlik = \frac{TP}{TP + FP} \quad (2.16)$$

➤ **Duyarlılık (Recall) / True Positive Rate (TPR)**

Duyarlılık, modelin gerçek pozitif örnekleri ne kadar iyi tespit ettiğini gösterir. Yanlış negatifleri minimize etmek için kullanılır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (2.16)$$

Burada, *FN* (False Negative) yanlış negatif, modelin negatif olarak tahmin ettiği ancak aslında pozitif olan örneklerdir. Duyarlılık, modelin gerçek pozitifleri kaçırma oranını değerlendirir. Yüksek duyarlılık (recall), yanlış negatiflerin az olduğunu gösterir.

Mayın tespitinde yanlış negatifler (FN), yani modelin mayınları yanlışlıkla tehdit içermeyen nesneler olarak sınıflandırması, ciddi güvenlik riskleri doğurabilir. Bu nedenle, yüksek duyarlılık (recall) değeri, modelin tehdit unsuru içeren nesneleri kaçırma olasılığını azaltır ve tespit sürecini daha güvenilir hale getirir. Özellikle mayın gibi tehlikeli nesnelerin sınıflandırıldığı sistemlerde, precision (kesinlik) yerine recall değerinin yüksek olması daha kritik bir gerekliliktir, çünkü modelin tehdit içeren bir nesneyi gözden kaçırmaması, modelin yanlış bir nesneyi tehdit olarak sınıflandırmasından çok daha büyük bir risk oluşturur.

➤ **Özgüllük (Specificity) / True Negative Rate (TNR)**

Specificity, modelin gerçek negatifleri ne kadar iyi tespit ettiğini gösterir. Yanlış pozitifleri azaltmak için kullanılır.

$$Özgüllük = \frac{TN}{TN + FP} \quad (2.16)$$

Burada *TN* (True Negative) doğru negatif, modelin negatif olarak tahmin ettiği ve gerçekten de negatif olan örneklerdir. Özgüllük değeri yüksek olduğunda, modelin yanlış pozitif tahminleri düşük olur.

➤ **F1-Skoru (F1-Score)**

F1-skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır. Modelin genel başarımını değerlendirmek için kullanılır.

$$F1 = 2 * \frac{Keskinlik * Duyarlilik}{Keskinlik + Duyarlilik} \quad (2.16)$$

F1-skoru, duyarlılık ve kesinlik arasında bir denge kurar. Eğer yanlış pozitifler ve yanlış negatifler arasında bir denge sağlamak isteniyorsa F1-skoru dikkate alınır.

➤ Logaritmik kayıp (Log Loss)

Log loss, hem modelin başarısını hem de optimizasyon sürecini değerlendiren önemli bir metriktir [125, 105]. Bu metrik, modelin hiperparametreleri ve ağırlıkları üzerinde optimize edilmesine odaklanır ve aynı zamanda Çapraz Entropi (Cross Entropy) olarak da bilinir [105]. Entropi, bilgi ve çeşitlilik kavramlarını ifade eder. Yüksek entropi, veri setindeki bilgi ve varyansın fazla olduğunu belirtir. Dolayısıyla, model performansında düşük entropi arzu edilir. Log loss kullanılarak başarı değerlendirilmesi, gerçek değerler ile tahmin edilen olasılıklar arasındaki farkı ölçer. Yapılan değerlendirmede bu farkın minimize edilmesi amaçlanır [125]. Daha düşük log loss değerleri, daha iyi model performansını gösterir. Log Loss şu şekilde hesaplanır:

$$Log Loss = -\frac{1}{n} \sum_{i=1}^n [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (2.17)$$


Bu denklemde, y_i gerçek etiket ya da doğru sınıf etiketini temsil eder. Yani, y_i her bir örneğin doğru sınıfını belirtirken, bu değer genellikle 0 veya 1 olur. p_i ise modelin, i -inci örnek için, pozitif sınıfa ait olma olasılığını tahmin ettiği değeri ifade eder ve bu değer 0 ile 1 arasında bir olasılık değeri alır.

➤ Aşırı Öğrenme (Overfitting)

Aşırı öğrenme (overfitting), makine öğrenmesi modelinin eğitim verisine aşırı derecede uyum sağladığı, ancak yeni veya daha önce karşılaşmadığı verilere genelleme yapma yeteneğinin zayıf olduğu bir durumu ifade eder [126]. Bu problem, modelin eğitim verisindeki gürültü ve rastgele dalgalanmalara gereğinden fazla uyum göstermesinden kaynaklanır [126]. Aşırı öğrenme, modelin eğitim verisinde çok iyi performans göstermesine, ancak test veya gerçek dünya verilerinde düşük performans sergilemesine yol açar [127]. Bu durum, modelin gerçek dünya senaryolarında başarısız olmasına neden olabilir, çünkü model yalnızca eğitim verisindeki örüntüleri değil, aynı zamanda bu verideki rastgele hataları da öğrenir. Sonuç olarak, model eğitim verisi üzerinde yüksek performans sergilerken, test verisi veya gerçek dünya verisi üzerinde düşük performans gösterir.

Aşırı Öğrenmeyi Tespit Etme: Aşırı öğrenme durumunu belirlemek için çeşitli yöntemler kullanılabilir. İlk olarak, eğitim ve test hatalarının karşılaştırılması bu

durumun önemli bir göstergesidir [127]. Eğer model, eğitim verisinde düşük hata oranına sahipken test verisinde yüksek hata oranı gösteriyorsa, bu durum aşırı öğrenmeyi işaret eder. Ayrıca, öğrenme eğrileri de bu tespitte kritik bir rol oynar. Şekil 2.28’de görüldüğü gibi modelin eğitim hatası sürekli olarak azalırken doğrulama hatasının belirli bir noktadan sonra artması, aşırı öğrenmenin bir göstergesi olabilir.




Şekil 2.28 Makine öğrenmesi yaparken eğitim aşamasında aşırı öğrenmeye başlama noktası

Şekil 2.28’deki Grafikte görüldüğü üzere, model karmaşıklığı arttıkça eğitim hatası sürekli azalır, çünkü model eğitim verisini daha iyi öğrenir. Ancak test hatası belirli bir noktaya kadar azalır ve sonrasında tekrar artmaya başlar. Bu durum, modelin eğitim verisine aşırı uyum sağladığını ve yeni verilerde iyi performans gösteremediğini gösterir. Bu noktada model aşırı öğrenmiş (overfitting) demektir. Aşırı öğrenmeyi önlemek için model karmaşıklığını optimum noktada tutmak gerekir. Bu nokta, eğitim ve test hatalarının en iyi dengelendiği yerdir.

2.7.5 Karar Ağaçları

Karar ağaçları, sınıflandırma ve regresyon problemlerinde kullanılan yaygın ve etkili makine öğrenme algoritmasıdır. Bu yöntem, veriyi daha küçük gruplara ayırarak belirli kurallara göre kararlar alır. Karar ağaçları, basit ve anlaşılır bir yapıya sahip olmaları nedeniyle yorumlanabilirliği yüksek modellerdir [128]. Karar ağaçları, şekil 2.29’de görüldüğü gibi kök düğüm (root node), iç düğüm (internal nodes) ve yaprak düğümlerden (leaf nodes) oluşur.



Şekil 2.29 Karar ağaçları genel yapısı

Kök düğüm, verinin ilk olarak işlendiği ve en üstte bulunan düğümüdür. İç düğümler, veriyi belirli özelliklere göre ayıran düğümlerdir ve her bir iç düğüm, karar kuralına sahiptir. Yaprak düğümler ise nihai kararların alındığı düğümlerdir ve sınıf etiketi veya hedef değeri içerir.

Karar ağacı algoritması, öncelikle verileri belirli bir özelliğe ve bu özelliğin belirli değerine göre böler. Bu bölme işlemi, bilgi kazancı, Gini safsızlığı (Gini Impurity) veya varyans azaltımı gibi kriterlere dayanarak yapılır [128]. Gini safsızlığı, düğümdeki örneklerin homojenliğini ölçer ve formülü aşağıdaki gibidir [129].

$$Gini(D) = 1 - \sum_{k=1}^K p_k^2 \quad (2.18)$$

Burada p_k , k-inci sınıfın düğümdeki oranını temsil eder. Gini safsızlığında daha düşük değerler daha homojen düğümleri ifade eder.

Bilgi kazancı ise veri kümesinin entropisi ile belirli bir özelliğin alt kümelerinin entropisi arasındaki fark olarak hesaplanır ve formülü şu şekildedir [129]:

$$IG(D, A) = H(D) - \sum_{v \in \text{values}(A)} \frac{|D_v|}{|D|} H(D_v) \quad (2.19)$$

Burada $H(D)$ veri kümesinin entropisi, D_v ise A özelliğinin v değerine sahip alt kümesidir.

Regresyon problemleri için ise ortalama kare hata (MSE) kullanılır ve formülü aşağıda verilmiştir [128]:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2 \quad (2.20)$$

Burada y_i , gerçek değerleri ve $\hat{y}$, tahmin edilen ortalama değeri temsil eder.

Her bölünme, veri kümesini daha küçük alt kümelere ayırır ve bu alt kümeler iç düğümler aracılığıyla dallanır. Her iç düğüm, belirli bir özelliğe ve değere göre veriyi daha da böler. Ağacın daha fazla bölünmemesi için belirli kriterler kullanılır. Bu kriterler, belirli bir derinliğe ulaşılması, belirli bir düğümdeki minimum veri noktası sayısı veya bilgi kazancının belirli bir eşik değerin altına düşmesi olabilir. Yeni bir veri noktası geldiğinde, kök düğümünden başlayarak her iç düğümdeki kurallara göre ilerlenir ve nihayetinde yaprak düğüme ulaşılır. Yaprak düğümdeki sınıf etiketi veya hedef değeri tahmin olarak kullanılır.

Karar ağaçlarının avantajları arasında yorumlanabilirlik, az ön işleme gereksinimi ve esneklik yer alır. Karar ağaçları, karar kurallarını açıkça gösterir ve bu kurallar kolayca yorumlanabilir. Ayrıca, veri normalleştirme veya ölçekleme gerektirmez ve hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Ancak, karar ağaçları derinleştikçe aşırı uyum gösterme eğilimindedir ve veri setindeki küçük değişikliklere karşı hassastır, bu da modelin performansını olumsuz etkileyebilir.

Genellikle aşırı uyum riskini azaltmak ve performansı artırmak için toplu (ensemble) yöntemlerle birlikte kullanılırlar.


2.7.6 Random Forest

Random Forest yöntemi, 2000’li yıllarda Leo Breiman tarafından geliştirilen ve makine öğrenimi alanında önemli bir yenilik olarak kabul edilen bir tekniktir [130]. Bu yöntemdeki “Random” ifadesi, gözlem ve değişkenlerin rastgele seçilmesi sürecine işaret eder. Bu rastgelelik, modelin genellenebilirliğini artırarak aşırı öğrenme sorununu minimize etmeye yardımcı olur [130].

Random Forest algoritması, birden fazla karar ağacını bir araya getirerek çalışan, toplu (ensemble) bir makine öğrenme yöntemidir. Hem sınıflandırma hem de regresyon problemlerinde kullanılır [131]. Algoritmanın temel amacı, bireysel karar ağaçlarının hata oranlarını azaltarak daha doğru ve genelleştirilmiş sonuçlar elde etmektir. Random Forest algoritması, “Bagging (öznitelik torbalama)” ve karar ağaçlarını temel alarak geliştirilmiş bir algoritmadır [130].

Bagging (Bootstrap Aggregating): Leo Breiman tarafından 1990’larda geliştirilmiştir. Breiman, Bagging yöntemini oluştururken, birden çok karar ağacını kullanarak model doğruluğunu artırmayı amaçlamıştır [132]. Bu yaklaşım, tek bir karar ağacına uygulanan CART (Classification and Regression Trees) algoritmasının, birden fazla ağaca uygulanarak çoğaltılması esasına dayanır [130, 132]. Bagging yönteminin temelinde, veri setindeki gözlem birimlerinin “bootstrap” örnekleme yöntemi ile seçilmesi ve bu örnekler üzerinden yeni modeller oluşturulması bulunmaktadır. Bagging yöntemi, veri setinde M adet gözlem birimi bulunduğunda, bu gözlemlerden n adet ($n < M$ olacak şekilde) bootstrap örnekleme yöntemi ile seçilerek K tane yeni karar ağacı modeli oluşturulmasını içerir [132]. Her yeni oluşturulan ağaç, önceki ağaçlardan bağımsız olarak eğitilir. Bu süreç sonucunda K adet bağımsız karar ağacı modeli elde edilir. Her bir karar ağacı, bağımsız olarak tahminler üretir ve bu K tahmin değeri bir araya getirilir. Nihai tahmin, bu K tahmin değerinin çoğunluk oylaması (sınıflandırma problemleri için) veya ortalaması (regresyon problemleri için) alınarak belirlenir [132]. Bu yöntem, modelin overfitting’e karşı dayanıklılığını artırarak genel performansını iyileştirir.

Random Forest yöntemi, şekil 2.30’da gösterilen veri alt kümelerinin oluşturulması (bagging), karar ağaçlarının eğitilmesi ve tahminlerin birleştirilmesi olmak üzere üç ana adımı içerir.



Şekil 2.30 Random Forest algoritması yapısı

İlk adımda, bagging yöntemi kullanılarak eğitim veri setinden rastgele ve tekrarlı örnekleme (bootstrap sampling) yöntemiyle belirli sayıda (B) alt küme oluşturulur. Her alt küme, orijinal veri setinin boyutuyla aynı olabilir, ancak rastgele örneklenmiş veri noktaları içerir. İkinci adımda, her bir alt küme için, belirli sayıda rastgele seçilen özellik kullanılarak bir karar ağacı eğitilir. Her düğümde, tüm özellikler arasından değil, rastgele seçilen bir alt küme arasından en iyi bölünme (split) özelliği seçilir. Bu sayı genellikle sınıflandırma için $\sqrt{M}$, regresyon için ise $M/3$ olarak belirlenir. Burada M tüm özelliklerin sayısını temsil eder [133, 134].

Karar ağacında, sınıflandırma problemleri için genellikle Gini safsızlığı veya bilgi kazancı kullanılarak en iyi bölünme noktası belirlenir. Gini safsızlığı, düğümdeki veri kümesinin safsızlığını ölçer ve düşük değerler daha iyi bölünmeleri ifade eder. Bilgi kazancı ise düğümün bölünmesinden önce ve sonra bilgi entropisi arasındaki farktır. Regresyon problemlerinde ise ortalama kare hata (MSE) kullanılır ve bu yöntem düğümdeki hata miktarını ölçer.


Son adımda, her bir karar ağacının yaptığı tahminler birleştirilir. Sınıflandırma problemlerinde, her ağacın tahminleri oylanır ve en çok oyu alan sınıf nihai tahmin olarak seçilir. Regresyon problemlerinde ise, tüm ağaçların tahminlerinin ortalaması alınarak nihai tahmin elde edilir. Bu sayede, Random Forest algoritması, bireysel ağaçlardaki hata oranlarını azaltarak daha doğru ve genelleştirilmiş tahminler sağlar. Bu yöntem, modelin aşırı öğrenme (overfitting) riskini de azaltarak daha sağlam ve güvenilir sonuçlar elde etmeye yardımcı olur.

2.7.7 K-Nearest Neighbors (K-NN)

K-Nearest Neighbors (K-NN) algoritması, 1950’lerde Evelyn Fix ve Joseph Hodges tarafından geliştirilmiştir. Bu algoritma, sınıflandırma problemlerine

yönelik parametresiz bir yöntem olarak tanıtılmıştır [135]. 1960'lar ve 1970'lerde, K-NN algoritması daha geniş bir araştırma topluluğu tarafından benimsenmiş ve çeşitli makine öğrenimi problemlerinde kullanılmaya başlanmıştır. Algoritmanın temel prensibi, bir veri noktasının sınıfını veya değerini, bu noktanın en yakın komşularının sınıf veya değerlerine göre belirlemektir [135]. Bu yaklaşım, özellikle basit ve etkili olması nedeniyle popülerlik kazanmıştır.

K-NN Algoritmasının Çalışma Prensibi: K-NN algoritması hem sınıflandırma hem de regresyon problemlerinde kullanılabilen esnek bir yöntemdir [136]. Bu algoritmanın temel prensibi, şekil 2.31'da gösterildiği gibi yeni bir veri noktasının en yakın K komşusunu bulmak ve bu komşuların özelliklerine dayanarak tahmin yapmaktır [135, 136]. K-NN algoritmasının çalışma adımları k değerinin belirlenmesi, mesafe ölçümü, k en yakın komşunun seçilmesi ve son adım ise sınıflandırma veya regresyondur



Şekil 2.31 K-NN sınıflandırma algoritması yeni değer sınıf seçme işlemi

K Değerinin Belirlenmesi: K-NN algoritmasının performansı, seçilen K değerine bağlıdır. K değeri, dikkate alınacak en yakın komşu sayısını belirtir. Küçük bir K değeri, modelin gürültüye duyarlı olmasına neden olabilirken, büyük bir K değeri, modelin fazla genelleme yapmasına yol açabilir. İdeal K değeri, veri setine ve problemin türene bağlı olarak değişir [137]. Sabit bir K değeri yoktur ve en uygun k değeri deneme-yanılma yoluyla veya çapraz doğrulama (cross-validation) gibi teknikler kullanılarak belirlenir [137].

Mesafe Ölçütü: Algoritma, yeni bir veri noktasının komşularını belirlemek için mesafe ölçütlerini kullanır. K-NN algoritmasında iki nokta arasındaki mesafeyi hesaplamak için kullanılan en yaygın yöntemler: Euclidean, Manhattan, Chebyshev ve hamming yöntemleridir [135, 136].

1. **Euclidean Mesafesi:** İki nokta arasındaki düz çizgi mesafesini ölçer ve en yaygın kullanılan mesafe ölçütüdür. Matematiksel olarak, iki nokta arasındaki Euclidean mesafesi şu şekilde hesaplanır [135]:

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (2.21)$$

2. **Manhattan Mesafesi:** L1 normu olarak da bilinir ve iki nokta arasındaki mutlak farkların toplamını ölçer. Bu mesafe, bir şehir blokları üzerindeki grid sisteminde hareket ediyormuş gibi hesaplanır [135]:


$$d(p, q) = \sum_{i=1}^n |p_i - q_i| \quad (2.22)$$

3. **Chebyshev Mesafesi:** Bu mesafe ölçütü, iki nokta arasındaki en büyük tek boyutlu farkı alır. Satrançta bir kralın hareketi gibi, en uzun adımın mesafesini temsil eder:

$$d(p, q) = \max_i |p_i - q_i|$$

4. **Hamming Mesafesi:** Bu mesafe ölçütü, iki dizi arasındaki farklı pozisyonlardaki sembollerin sayısını sayar. Özellikle kategorik verilerde ve ikili dizilerde kullanılır [135]:

$$d(p, q) = \sum_{i=1}^n 1(p_i \neq q_i) \quad (2.24)$$



Şekil 2.32 K-NN mesafe ölçüt yöntemleri

Bu mesafe ölçütleri, K-NN algoritmasının temel yapı taşlarıdır ve eğitilecek veri setinin doğasına ve problem türüne göre uygun olanı seçilir [135]. Doğru mesafe ölçütünü seçmek, algoritmanın performansını ve doğruluğunu doğrudan etkiler. Dolayısıyla, K-NN algoritmasının uygulanmasında mesafe ölçütlerinin dikkatli bir

şekilde belirlenmesi, başarılı bir tahmin modeli oluşturmak için kritik derecede önemlidir.

K En Yakın Komşunun Seçilmesi: Yeni veri noktasına en yakın K komşu, hesaplanan mesafelere göre seçilir. Bu komşular, yeni veri noktasının etrafındaki K veri noktasıdır.

Sınıflandırma veya Regresyon:


- Sınıflandırma: Mesafe çoğunlukla hangi sınıfa daha yakınsa yeni veriye o sınıf atanır. K en yakın komşunun sınıfları incelenir ve çoğunluk oyu ile yeni veri noktasının sınıfı belirlenir. Örneğin, K=5 ise ve 3 komşu bir sınıfa, 2 komşu başka bir sınıfa aitse, yeni veri noktası 3 komşunun sınıfına atanır.
- Regresyon: K en yakın komşunun değerleri alınır ve bu değerlerin ortalaması, yeni veri noktasının tahmini olarak kullanılır. Örneğin, K=3 ise ve komşuların değerleri 4, 5 ve 6 ise, tahmin değeri $(4+5+6) / 3 = 5$ olacaktır.

K-NN algoritması, basitliği ve doğrudan yorumu nedeniyle makine öğrenimi alanında yaygın olarak kullanılmaktadır [136]. Herhangi bir önceden belirlenmiş model olmadan, doğrudan veri noktalarının benzerliklerine dayanarak tahminler yapması, bu algoritmanın güçlü yanlarından biridir.

2.7.8 Support Vector Machine

Support Vector Machines (SVM), hem sınıflandırma hem de regresyon problemlerinde kullanılan güçlü ve esnek bir denetimli öğrenme algoritmasıdır. SVM, 1990'ların başında Vladimir Vapnik ve ekibi tarafından geliştirilmiştir [138]. Karmaşık veri setlerinde yüksek doğruluk sağlamasıyla bilinen bu algoritma, veri noktalarını ayıran en uygun hiper düzlemi bulmayı hedefler [138] .

SVM'nin çalışma prensibi, marjın ve destek vektörleri olmak üzere iki ana bileşenden oluşur. Hiper düzlem, veriyi farklı sınıflara ayıran bir düzlemdir ve bu düzlem, sınıflar arasındaki en iyi ayrımı sağlar. SVM, bu hiper düzlemi seçerken mümkün olan en geniş marjını bırakmaya çalışır [138, 139]. Marjın, hiper düzlemin iki tarafındaki en yakın veri noktalarına olan uzaklığı ifade eder ve SVM, bu marjını maksimum yapmayı hedefler. Büyük bir marjın, modelin genelleme kabiliyetini artırır. Hiper düzlemin konumunu ve yönünü belirleyen en yakın veri noktaları ise destek vektörleri olarak adlandırılır [139]. Bu işlemler şekil 2.33'de gösterilmiştir. Destek vektörleri, hiper düzlemin yerleşimi ve yönelimi üzerinde kritik bir etkiye sahiptir.



Şekil 2.33 Support Vector Machine

SVM'nin matematiksel temelleri, veriyi iki sınıfa ayıran bir hiper düzlem bulmaya dayanır. İki sınıf için hedeflenen hiper düzlem, $\mathbf{w} \cdot \mathbf{x} + b = 0$ denklemiyle ifade edilir [139]. Burada, $\mathbf{w}$ hiper düzlemin normali (hiper düzleme dik olan vektör) olan ağırlık vektörü, $\mathbf{x}$ veri noktası ve b hiper düzlemin bias terimidir. Amaç, bu hiper düzlemin iki sınıfı en iyi şekilde ayırmasıdır [132]. SVM, aşağıdaki optimizasyon problemini çözer [139]:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad (2.25)$$

Bu denklemde:

$\mathbf{w}$ - Sınıflandırma sınırını belirleyen vektördür.

b - Sınıflandırma düzleminin kaydırma terimidir.

$\|\mathbf{w}\|^2$ - $\mathbf{w}$ vektörünün normunun karesini temsil eder.


SVM, doğrusal olmayan sınıflandırma problemlerinde de etkilidir [140]. Kernel yöntemleri kullanarak, veri uzayı daha yüksek boyutlu bir uzaya dönüştürülür ve burada doğrusal bir ayırım yapılabilir. Yaygın kernel fonksiyonları arasında polinomial, radyal bazlı fonksiyon ve sigmoid kernel bulunur. Kernel fonksiyonu $\phi(\mathbf{x})$, veri noktalarını daha yüksek boyutlu bir uzaya dönüştürür ve ardından SVM bu yeni uzayda doğrusal bir hiper düzlem bulur. SVM'nin avantajları arasında yüksek doğruluk, genelleme kabiliyeti ve esneklik bulunur. Ancak, büyük veri setlerinde hesaplama maliyeti yüksek olabilir ve model parametrelerinin seçimi zordur. SVM, biyoinformatik, metin ve görüntü tanıma, tıbbi teşhisler ve finansal tahminler gibi çeşitli alanlarda kullanılmaktadır. Özellikle yüksek boyutlu özellik uzaylarına sahip veri setlerinde etkinliği kanıtlanmış bir yöntemdir. Sonuç olarak, SVM algoritması, veriyi etkili bir şekilde ayıran optimal hiper düzlemi bulmak için

güçlü matematiksel temelleri kullanan, esnek ve güçlü bir makine öğrenme algoritmasıdır.

2.8 Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin öğrenme, yeni bilgiler üretme ve keşfetme gibi yeteneklerini taklit etmeyi amaçlayan, bu süreçleri herhangi bir dış müdahaleye ihtiyaç duymadan otomatik olarak gerçekleştirebilen yapılardır [141]. Bu yapılar, biyolojik sinir ağlarının işleyişinden ilham alınarak geliştirilmiş ve öğrenme süreçleri matematiksel bir yaklaşımla modellenmiştir.


Bu sistemler, biyolojik sinir ağlarının temel özelliklerini taklit ederek öğrenme, genelleme ve hatırlama gibi işlevleri gerçekleştirebilir [142]. Şekil 2.34'de görüldüğü gibi, biyolojik sinir hücresi dendrit, hücre gövdesi, akson ve sinaps gibi farklı bölümlerden oluşur [143]. Yapay sinir ağları da bu biyolojik yapıyı örnek alarak matematiksel bir modelle tasarlanmıştır.



Şekil 2.34 Biyolojik Sinir Hücre Yapısı


Bu bağlamda, yapay sinir hücresi, biyolojik sinir hücresinin çalışma prensiplerini dijital ortama uyarlayan bir modeldir. Şekil 2.35'te gösterildiği gibi, bir yapay sinir hücresi; giriş verilerini belirli ağırlıklarla çarpar, ardından bu değerleri toplar ve bir aktivasyon fonksiyonundan geçirerek sonuç üretir [142, 143]. Bu yapı, öğrenme sürecinde verilen örneklerden faydalanarak sistemin yeni veriler üzerinde tahmin yapmasını sağlar.

Bu esnek ve güçlü yöntem, özellikle karmaşık problemlerin çözümünde geniş bir kullanım alanına sahiptir. Görüntü işleme, ses tanıma ve veri analizi gibi alanlarda etkili sonuçlar sunar.



Şekil 2.35 Yapay Sinir Hücresi

Yapay sinir ağları, birden fazla katman ve sinir hücresi ile daha karmaşık yapıları modelleyebilir. Şekil 2.36'de görüldüğü gibi, bu yapılar genellikle **giriş katmanı**, **gizli katmanlar** ve **çıkış katmanı** olmak üzere üç temel bölümden oluşur. **Giriş katmanı**, ham verilerin sisteme sunulduğu yerdir [144]. **Gizli katmanlar**, veriler üzerinde matematiksel işlemler gerçekleştirerek veri dönüşümünü sağlar. **Çıkış katmanı** ise bu işlemler sonucunda elde edilen nihai çıktıları temsil eder [144]. Gizli katmanların sayısı ve karmaşıklığı, ağın performansını ve öğrenme kapasitesini doğrudan etkiler.



Şekil 2.36 Yapay sinir ağları katmanları

2.8.1 Derin Öğrenme

Yapay sinir ağları geleneksel problemlerin çözümünde etkili olsa da daha karmaşık ve büyük veri setleri üzerinde çalışılması gerektiğinde derin öğrenme yöntemleri ön plana çıkmaktadır. Derin öğrenme, birden fazla gizli katmandan oluşan derin sinir ağlarını kullanır ve büyük miktarda veriyle etkili bir şekilde çalışabilir [145]. Bu yöntem, özellikle veri içerisindeki gizli ilişkileri keşfetmek ve karmaşık desenleri tanımlamak için oldukça idealdir. Derin öğrenme algoritmaları, insan beynine daha yakın bir öğrenme mekanizması sunarak, daha yüksek doğruluk oranlarına ulaşmayı mümkün kılar [146]. Derin öğrenme, geleneksel yapay sinir ağlarına kıyasla daha karmaşık problemlerin çözülmesinde etkili sonuçlar verir ve bu, genellikle daha derin, daha karmaşık ağ mimarileriyle sağlanır. Bu ağlar, büyük veri kümesi üzerinde eğitim alarak, çok sayıda özellik arasındaki ilişkileri öğrenir ve ardından yeni veriler üzerinde tahmin yapabilir. Özellikle, büyük verinin analizinde klasik algoritmalara göre çok daha verimli çalışarak, verinin içindeki derin yapıları öğrenmeye olanak tanır.

Derin öğrenme, geleneksel yapay sinir ağlarına kıyasla daha karmaşık problemleri çözmek için tasarlanmış özel mimarilere sahiptir [147]. Bu mimariler arasında en yaygın olanları Konvolüsyonel Sinir Ağları (Convolutional Neural Networks, CNNs) [148], Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNNs) [149] ve Transformer tabanlı modeller [150] yer alır.

Konvolüsyonel Sinir Ağları (CNNs): Özellikle görüntü işleme ve bilgisayarla görme alanlarında başarılıdır. CNN'ler, verideki uzamsal ve bölgesel özellikleri çıkararak, nesne tanıma, yüz algılama ve tıbbi görüntü analizi gibi uygulamalarda etkin bir şekilde kullanılmaktadır [148].

Tekrarlayan Sinir Ağları (RNNs): Zaman serileri ve ardışık verilerle çalışmak için geliştirilmiştir. Doğal dil işleme (NLP), ses tanıma ve finansal zaman serisi analizi gibi alanlarda yaygın olarak kullanılmaktadır [149].

Transformer Tabanlı Modeller: NLP'deki ilerlemelerle öne çıkan Transformer mimarisi, özellikle metin çevirisi, dil modelleme ve sohbet botlarında büyük başarı elde etmiştir. GPT ve BERT gibi modeller, bu mimarinin gücünü göstermektedir [150].

Derin öğrenmenin uygulama alanları oldukça geniştir. Derin öğrenme algoritmalarını kullanarak ortamdaki nesneleri gerçek zamanlı algılama ve bu verilere dayalı karar verme süreçlerinde büyük bir ilerleme sağlamaktadır [151]. Sağlık sektörü, derin öğrenme sayesinde kanser teşhisi, genetik analiz ve biyomedikal görüntülerin sınıflandırılmasında önemli bir ilerleme kaydetmiştir. Bir diğer önemli uygulama alanı ise GPR verisi işlemedir. Derin öğrenme, GPR verilerini analiz ederek yer altı nesnelerinin tespiti, mayın ve patlayıcı cihazların belirlenmesi gibi kritik görevlerde de kullanılmaktadır [152].

Matlab AppDesigner, bilimsel ve mühendislik uygulamaları için kullanıcı dostu grafiksel arayüzler (GUI) geliştirmeye olanak tanıyan, Matlab'ın sunduğu güçlü bir platformdur. Sürükle-bırak yöntemiyle bileşenleri düzenleyerek arayüz tasarlama imkânı sunan AppDesigner, kodlama bilgisi sınırlı olan kullanıcılar için bile etkili uygulamalar oluşturmayı kolaylaştırır. Bu platform, Matlab'ın geniş fonksiyon setini ve hesaplama gücünü, sezgisel bir kullanıcı arayüzü ile birleştirerek etkileşimli ve dinamik uygulamalar geliştirmenizi sağlar. Kullanıcılar, arayüzdeki butonlar, grafik pencereleri, kaydırma çubukları ve diğer bileşenlerle verileri işleyebilir, görselleştirebilir ve analiz edebilir [157].

AppDesigner, Matlab'ın güçlü arka plan fonksiyonlarıyla entegre çalışarak, kullanıcıların karmaşık hesaplamalar yapmasını mümkün kılar. Uygulama geliştirme sürecinde, arka planda otomatik olarak oluşturulan kod, Matlab'ın hesaplama gücünü en verimli şekilde kullanarak işlemlerin hızla gerçekleştirilmesini sağlar [158]. Matlab'ın hesaplama yeteneklerini grafiksel bir arayüzle birleştiren AppDesigner, veri analizini hızlandırmak ve kullanıcıya görsel bir çalışma ortamı sağlamak için idealdir.

Bu araç, özellikle veri işleme, analiz ve görselleştirme süreçlerini yönetmek için özelleştirilmiş uygulamalar geliştirmek isteyen kullanıcılar için çok kullanışlıdır. AppDesigner ile tasarlanan arayüzler, çeşitli veri türlerini hızlıca işleyebilmek, analiz edebilmek ve görselleştirebilmek için geniş çapta özelleştirilebilir [158]. Bu sayede, kullanıcılar veri manipülasyonu, grafiksel sunumlar ve ileri seviye analiz adımlarını bir arada gerçekleştirebilir.

3.1 Matlab Appdesigner'da Görüntü İşleme ve Makine Öğrenmesi Uygulamaları

AppDesigner, özellikle görüntü işleme ve makine öğrenmesi uygulamalarında kullanıcı dostu bir ortam sunar [159]. Görüntü işleme teknikleri, verilerden anlamlı öznitelikler çıkarmak, görüntü segmentasyonu, sınıflandırma ve nesne tanıma gibi işlemler için kritik öneme sahiptir. Bu süreçlerde, verilerin doğru bir şekilde işlenmesi ve analiz edilmesi, model performansını doğrudan etkiler. AppDesigner, bu analizleri kolaylaştırmak için öznitelik çıkarımı, veri segmentasyonu, gürültü azaltma ve görselleştirme gibi işlemleri gerçekleştirebilen arayüzler geliştirme imkânı tanır.

Yapay zekâ ve makine öğrenmesi uygulamalarında, doğru özniteliklerin çıkarılması ve bu özniteliklerin uygun sınıflandırma algoritmaları ile işlenmesi, başarılı bir modelin anahtarıdır. AppDesigner, bu süreci optimize etmek için gerekli araçları sunar; böylece kullanıcılar, verilerini hızlıca işleyebilir, analiz edebilir ve


sonuçlarını interaktif bir şekilde gözlemleyebilir [159]. Örneğin, arayüz üzerinde gerçekleştirilen işlemler, kullanıcının algoritmaların çıktıları üzerinde doğrudan müdahalede bulunmasını ve farklı yöntemleri deneyerek en iyi sonuçları elde etmesini sağlar.

AppDesigner, görüntü işleme sürecinde yalnızca analiz değil, aynı zamanda verilerin etkili bir şekilde görselleştirilmesini de sağlar. Grafiksel çıktılar ve interaktif bileşenler sayesinde, kullanıcılar analiz sonuçlarını anında değerlendirebilir ve görsel sunumlar ile desteklenen karar alma süreçlerini hızlandırabilirler. Bu özellikler onun, veri analitiği, sinyal işleme ve makine öğrenmesi gibi geniş bir yelpazede kullanımını mümkün kılar.

3.2 GPR verilerinin işlenmesi

Bu çalışmada geliştirilen Matlab AppDesigner arayüzü, elimizdeki Yere Nüfuz Eden Radar (GPR) verilerini işlemek, işlenmiş verilerden öznetelik çıkarmak ve çeşitli görüntü işleme teknikleriyle verileri analiz edebilmek amacıyla tasarlanmıştır. Bu arayüzün adını GPRVAT (GPR Visual Analysis Tool) verdik. Bu arayüz, GPR verilerinin etkili bir şekilde değerlendirilmesini sağlayarak, kullanıcılara verileri daha anlamlı hale getiren interaktif bir analiz ortamı sunar. GPR verilerinin doğru bir şekilde işlenmesi, veriden çıkarılacak bilgilerin doğruluğu ve güvenilirliğini doğrudan etkiler. Bu nedenle arayüz, kullanıcıya veri işleme sürecinin her aşamasında esneklik ve kontrol imkânı sunar.

Matlab AppDesigner ile geliştirilen bu arayüzün **birinci sayfasında**, GPR veri setleri işlenip öznetelikleri çıkarılmaktadır. Şekil 3.1’de gösterilen bu sayfada A-tarama sinyallerine DC çıkarma, bant geçiren filtre, tek boyutlu gauss filtre ve tek boyutlu medyan filtresi uygulanabilmektedir. A-tarama sinyallerini filtreledikten sonra tarama başlığındaki yükseklik değişimlerinin neden olduğu kargaşayı ortadan kaldırmak için yatay eksende bir bant geçiren filtre değiştirilebilir parametreler ile uygulanabilmektedir. GPR veri işlemede ilk başta yapılabilecek filtre işleminin ardından sinyallerin arka planını daha net bir şekilde ayırmak amacıyla iki farklı arka plan çıkarımı (sabit ve dinamik arka plan çıkarımı) yöntemi kullanılabilmektedir. Arka plan çıkarımı işlemi bittikten sonra GPR görüntüsünü ikili (Binary) görüntüye çevirmek için arayüzde hem sabit eşikleme hem de adaptif eşikleme yöntemi bulunmaktadır. İkili GPR görüntüsünü filtreleyebilmek için morfolojik operatörler ve yumuşatma filtreleri bulunmaktadır. Bu işlemlerin yanında arka plan çıkarılmış görüntüye gabor filtresi uygulayabilmek için bir buton bulunmaktadır. GPR görüntü işleme süreci bittikten sonra işlenmiş ve işlenmemiş görüntüleri (GPR ham veri, GPR arka plan çıkarılmış veri, GPR ikili görüntü ve blob color GPR görüntüsü) kaydedebilmek için bir alan da bulunmaktadır. Bu arayüzden çıkarılan öznetelikler ise beyaz bölgenin alanı, ortalaması, ikinci momenti, üçüncü momenti, beyaz bölgeye uydurulan parabolün denklemlerinin katsayıları (a, b ve c) ve Fourier transform yapıldıktan sonra elde edilen genlik görüntüsüdür.




Şekil 3.1 GPRVAT arayüzü ana sayfası

Şekil 3.2’de görülen GPRVAT arayüzünün ikinci, üçüncü ve dördüncü sayfaları GPR verilerinin analiz sürecini görselleştirme ve kullanıcıya detaylı bir veri inceleme ortamı sunmaktadır. Bu sayfalar, verilerin anlamlandırılmasını kolaylaştıran grafikler, görselleştirmeler ve animasyonlarla zenginleştirilmiştir.


GPRVAT arayüzünün **ikinci sayfası** Şekil 3.2a’da gösterilmiştir. Bu sayfada Fourier dönüşümü sonucunda elde edilen genlik ve faz görüntüleri, B-tarama görüntüsünün içinde bulunan A-tarama sinyallerini, yatay bant geçiren filtre uygulandığı zaman işlenmiş ve ham sinyalli gösteren grafikler bulunmaktadır. Bunun yanında GPR veri toplama ve B-tarama görüntüsü oluşturma sürecini anlayabilmek için bir animasyon bulunmaktadır. Kullanıcı, görselleştirilen veriler üzerinde yakınlaştırma, uzaklaştırma, belirli bölgeleri seçme gibi işlemler yaparak analiz sürecine müdahil olabilir ve çeşitli incelemeler gerçekleştirebilir.

Üçüncü sayfa Şekil 3.2b’de sunulmaktadır. Bu sayfada GPR verilerinin önışlem ve arka plan çıkarımı yapıldıktan sabit eşik değeri belirleyebilmek için bir alan bulunmaktadır. Bunun yanında GPR verilerini kullanarak gömülü nesnenin konumunu belirlemek için kullanılan DTS (Algılama testi istatistikleri) örneği gösterilmektedir ve son olarak Gri seviye morfolojik operatör uygulanacak alan görülmektedir.


Şekil 3.2c’de gösterilen GPRVAT arayüzünün **dördüncü sayfasında** ise Gabor filtresi parametreleri, 3 boyutlu Gabor sonuçlarını ve Gabor çekirdek matrisi gösterilmektedir. Kullanıcı, bu sayede GPR verilerindeki detaylı filtreleme süreçlerini inceleyebilir ve sonuçları değerlendirebilir.



a) GPRVAT arayüzünün ikinci sayfası



b) GPRVAT arayüzünün üçüncü sayfası



c) GPRVAT arayüzünün dördüncü sayfası
 Şekil 3.2 GPRVAT arayüzünün GPR analiz sayfaları


Şekil 3.3'te görülen GPRVAT arayüzünün beşinci ve altıncı sayfaları, GPR verilerinden ziyade genel görüntü işleme ve analiz süreçlerine odaklanmaktadır. Bu arayüz, özellikle ders anlatımları ve eğitim materyallerinin görselleştirilmesi için faydalı bir araç olarak kullanılmakta ve kullanıcıların görüntü işleme tekniklerini interaktif bir ortamda deneyimlemesine olanak sağlamaktadır.

Beşinci sayfa, Şekil 3.3a'da gösterilmektedir. Bu sayfa, renkli görüntülerin R-G-B (Kırmızı-Yeşil-Mavi) renk kanalları ile gri seviye histogramlarının incelenmesini mümkün kılmaktadır. Kullanıcı, her bir renk kanalının görüntü üzerindeki etkilerini analiz ederek belirli nesnelerin hangi renk kanallarında daha belirgin olduğunu gözlemleyebilir. Ayrıca, gri tonlamaya dönüştürülen görüntülerin histogram analizleri, piksel yoğunluklarının dağılımını görselleştirerek ışık ve kontrast ayarlarının optimize edilmesine olanak tanır. Belirlenen eşik seviyelerine göre ikili (binary) görüntüler oluşturma işlemi sayesinde, görüntüdeki önemli yapılar arka plandan ayrıştırılabilir. Bu süreç, nesne tanıma ve segmentasyon analizlerinde kritik bir rol oynamaktadır. Kullanıcı, farklı eşik değerlerini deneyerek en uygun ayrıştırmayı elde edebilir ve görüntüdeki detayları daha net bir şekilde analiz edebilir.

Altıncı sayfa, Şekil 3.3b'de gösterilmektedir. Bu sayfa, görüntülerin çoklu eşikleme yöntemiyle bölütlendiği bir analiz ortamı sunmaktadır. Çoklu eşikleme yöntemi, özellikle karmaşık yapılar içeren görüntülerde, veriyi sadeleştirerek analiz sürecini kolaylaştırmaktadır. Görüntüyü belirli gri seviye bölgelerine göre bölerek, farklı bölgelerin birbirinden ayrılmasını sağlayan bu yöntem, nesne tanıma ve görüntü işleme uygulamalarında yaygın olarak kullanılan etkili bir tekniktir. Kullanıcı, arayüz üzerinde farklı eşik seviyelerini ayarlayarak en uygun segmentasyonu elde edebilir ve görüntünün detaylarını daha iyi analiz edebilir.



a) GPRVAT arayüzünün beşinci sayfası



b) GPRVAT arayüzünün altıncı sayfası
 Şekil 3.3 GPRVAT arayüzünün görüntü bölütleme sayfaları

GPR VERİLERİNİN İKİLİ VE ÇOKLU SINIFLANDIRMASI

Yer altı yapılarının sınıflandırılması, jeofizik araştırmalardan arkeolojik kazılara, altyapı incelemelerinden güvenlik uygulamalarına kadar geniş bir yelpazede kritik bir öneme sahiptir [67]. Jeofizik araştırmalarda, GPR teknolojisi, yer altındaki mineral yataklarının, su kaynaklarının ve yer altı yapılarını etkileyebilecek fay hatlarının tespit edilmesinde önemli bir rol oynamaktadır. Bu bağlamda, GPR'ın sunduğu görüntüler, jeologların ve mühendislerin yer altındaki yapıları detaylı bir şekilde analiz etmelerine olanak tanır. Aynı zamanda, GPR'ın yüksek frekanslı dalgalar kullanarak detaylı görüntüleme yapabilme yeteneği, yer altı yapılarının karmaşık geometrik yapısını anlamak için kritik bilgiler sunar [153].

Güvenlik uygulamaları kapsamında, GPR teknolojisi, mayın ve patlayıcı madde içeren nesnelerin tespitinde etkin bir şekilde kullanılmaktadır [154]. Askeri alanlarda, mayınlar ve patlayıcıların güvenli bir şekilde tespiti, personelin korunması ve operasyonların güvenli bir şekilde yürütülmesi açısından kritik bir öneme sahiptir [155]. GPR, elektromanyetik dalgaların yer altındaki nesnelerle etkileşimi sonucu oluşan yansımaları analiz ederek, yüzey altında gömülü olan nesnelerin konumunu, şeklini ve derinliğini doğru bir şekilde belirleyebilir. GPR'ın metalik ve metalik olmayan mayınları tespit edebilme kabiliyeti, onu diğer sensör teknolojilerinden ayıran en önemli özelliklerden biridir [152]. Geleneksel metal dedektörleri, metal içeren mayınları tespit etmekte etkili olmasına rağmen, plastik veya az metal içeren modern mayınları tespit etmekte yetersiz kalabilir [152]. GPR, elektromanyetik dalgaların farklı malzemelerle etkileşime girmesi sonucu elde edilen yüksek çözünürlüklü veriler sayesinde, plastik ve az metal içeren mayınların bile tespit edilmesine olanak tanır. Bu durum, modern savaş alanlarında GPR'ı vazgeçilmez bir araç haline getirmiştir. Zira plastik mayınlar, düşük metal içeriği nedeniyle çoğu zaman diğer algılama yöntemlerinden kaçabilir. GPR, bu tür nesneleri, onların yüzey altındaki benzersiz yansıma örüntülerini analiz ederek tespit eder ve operatörlere konum bilgisi verir.

GPR'ın ayrıntılı tespit yeteneği, özellikle farklı yapısal özelliklere sahip mayınların sınıflandırmasında büyük bir avantaj sağlar. Mayınlar, farklı boyutlarda, şekillerde ve malzemelerden yapılabilir; bu da onların yansıma desenlerini oldukça karmaşık hale getirir. GPR, bu karmaşıklığın üstesinden gelerek, yansımaları analiz edip nesnelerin hangi tür mayınlar olabileceğini değerlendirebilir. Plastik mayınlar, düşük yansıma profilleri ve farklı yansıma açılarından dolayı geleneksel dedektörlerden kaçabilir. Ancak GPR'ın detaylı analiz yeteneği sayesinde bu tür mayınlar da doğru bir şekilde sınıflandırılabilir [156]. Bu durum, GPR'ı modern

askeri operasyonlarda vazgeçilmez bir araç haline getirmektedir. Zira sahada bulunan her tür mayın veya patlayıcının hızlı ve güvenilir bir şekilde tanımlanması ve sınıflandırılması, askeri personelin güvenliğini doğrudan etkiler.

Bu çalışmada, GPR verilerinden elde edilen gömülü cisimler klasik makine öğrenmesi yöntemleri kullanarak sınıflandırılacaktır. Sınıflandırma işlemi iki farklı kapsamda yapılacaktır. Bu çalışmalardan biri ikili sınıflandırmaya, diğer ise çoklu sınıflandırmaya yöneliktir. İkili sınıflandırmaya yönelik çalışmada, GPR veri setine 9 farklı yöntemde ön işleme, arka plan çıkarmı, son işlem ve öz nitelik çıkarımı yapılarak klasik makine öğrenmesi yöntemleri ile sınıflandırılacaktır. Çoklu sınıflandırmada ise 28 farklı yöntemde ön işlem, arka plan çıkarmı, son işlem ve öz nitelik çıkarımı ile klasik makine öğrenmesi yöntemleri kullanarak sınıflandırma yapılacaktır. İkili ve çoklu sınıflandırma aşamasında kullanılan temel adımlar şekil 4.1’de verilmiştir.



Şekil 4.1 GPR verilerini sınıflandırmaya yönelik temel adımlar

4.1 İkili Sınıflandırmaya Yönelik GPR Verilerinin İşleme Süreci

GPR verilerinin ikili sınıflandırma sürecinde ilk adım ön işleme aşamasıdır. Bu aşamada, normalizasyon, sinyallere çeşitli filtreleme, hizalama ve derinliğe bağlı kazanç gibi işlemler uygulanabilir. Örneğin, ön işleme sırasında A-tarama verilerine bant geçiren filtre uygulanarak sinyallerde oluşan gürültü ve parazit azaltılır. Ön işleminin ardından, arka plan çıkarma işlemi gerçekleştirilir. Arka plan çıkarmından sonra, son işlem aşamasında ise çeşitli gürültü giderme filtreleri ve görüntü bölütleme yöntemleri kullanılarak veri daha da iyileştirilir.

İkili sınıflandırmada kullanılan GPR veri setleri Tablo 4.1 ve Tablo 4.2’de görülmektedir. Tehdit içeren cisimler metal içeren ve içermeyen taklit mayınlardan oluşmaktadır. Diğer cisimler ise doğal cisim (taş), metal disk ve teneke kutularından oluşmaktadır.

Tablo 4.1’de gösterilen 1080 örnekten oluşan veri seti, tespit ve sınıflandırma açısından farklı seviyelerde zorluk içeren örneklerden oluşmaktadır. Bu veri

setinde, ayırt edilmesi kolay ve belirgin görüntülerin yanı sıra, ayırt edilebilirliği düşük ve sınıflandırılması daha zor olan görüntüler de bulunmaktadır. Bu durum, veri setini sınıflandırma açısından daha karmaşık hale getirmektedir.

Öte yandan, Tablo 3.2’de gösterilen 520 örnekten oluşan veri seti, daha belirgin ve ayırt edilebilir görüntüler içermektedir. Bu nedenle, sınıflandırma açısından nispeten daha kolay bir veri kümesi olarak değerlendirilebilir. Genel olarak, 520 örnekten oluşan veri seti daha düşük zorluk seviyesine sahipken, 1080 örnekten oluşan veri seti daha karmaşık ve zorlayıcı bir sınıflandırma problemine sahiptir.

Tablo 4.1 İkili sınıflandırma 1080 veri seti


Taklit Mayın (Tehtit)	440
Diğer Cisim (Tehtit içermiyor)	640
Toplam	1080

Tablo 4.2 İkili sınıflandırma 520 seri seti

Taklit Mayın (Tehtit)	100
Diğer Cisim (Tehtit içermiyor)	420
Toplam	520

Bu çalışmada, ön işlem aşamasında yönteme bağlı olarak farklı büyüklükteki verileri aynı ölçeğe getirmek için normalizasyon; A-tarama verilerinde gürültü ve kargaşa gidermek için bant geçiren filtre; GPR anteninin yükseklik farkından kaynaklanan gürültüleri gidermek için farklı parametreler ile yatay eksen bant geçiren filtre uygulanması; Derinde bulunan cisimleri tespit edebilmek için derinliğe bağlı kazanç fonksiyonu ve A-tarama verilerinin gürültülerini giderebilmek için 1 boyutlu gauss filtresi uygulanmıştır.

Arka plan çıkarımında daha önce bahsedilen ortalama alma ile arka plan çıkarımı yapılmış bu işlem yöntemlere bağlı olarak sabit ve dinamik arka plan çıkarımı olarak uygulanmıştır. Arka plan çıkarımı işleminde P değeri 15 olarak seçilmiştir.



Şekil 4.2 İkili Sınıflandırmada arka plan çıkarımı

Son işlem aşamasında yine yöntemle bağlı olarak verilerin daha belirgin hale getirilmesi Gabor filtresi ve yumuşatma filtresi (2D ortalama filtresi, 2D medyan filtresi, 2D gauss filtresi) uygulanmıştır. GPR verisini ikili (binary) hale getirmek yani bölütlemek için sabit veya adaptif eşikleme yöntemleri kullanılmıştır. Adaptif eşikleme Matlab de bulunan adaptif eşikleme fonksiyonları ile gerçekleştirilmiştir. Sabit eşikleme kullanılan yöntemlerde eşik değeri 89'dur. İkili görüntüleri filtrelemek için morfolojik operatörler kullanılmış, 2D gauss filtresi uygulanan yöntemlerde $\omega = 3$ olarak belirlenmiştir.

Öznitelik çıkarım işleminde ise ikili GPR görüntüsünde bulunan beyaz bölgenin (ön bölge) alanı, ortalaması, 2. momenti ve 3.momenti öznitelik olarak alınmıştır. Bunların yanında ön bölgeye parabol uydurularak parabol denkleminde elde edilen katsayılar öznitelik olarak kullanılmıştır. Tablo 4.4'te görüldüğü üzere öznitelikler, önileme ve son işlemler uygulanarak 9 farklı yöntem elde edilmiştir.

İkili-1: Veri işleme sürecinde normalizasyon, bant geçiren filtre, yatay bant geçiren filtre, dinamik arka plan çıkarımı, Gauss filtresi ve adaptif eşikleme kullanıldı. Çıkarılan öznitelik ise parabol denkleminde elde edilen katsayılardır.

İkili-2: Metot-1'den tek fark, sabit arka plan çıkarım işlemi yapılmasıdır.

İkili-3: Normalizasyon, bant geçiren filtre, sabit arka plan çıkarımı, gabor filtresi ve sabit eşikleme kullanıldı. Çıkarılan öznitelik ise beyaz bölgelerden elde edilen alandır.

İkili-4: Normalizasyon, bant geçiren filtre, yatay bant geçiren filtre, Gauss filtre, sabit arka plan çıkarımı, Gabor filtresi ve sabit eşikleme kullanıldı. Çıkarılan öznitelik ise beyaz bölgeden elde edilen alan, ortalama, 2. moment ve 3. momenttir.

İkili-5: Normalizasyon, bant geçiren filtre, Gauss filtresi, dinamik arka plan çıkarımı ve adaptif eşikleme kullanıldı. Çıkarılan öznitelik ise beyaz bölgeden elde edilen alan, ortalama, 2. moment, 3. moment ve parabol denkleminde elde edilen katsayılardır.

İkili-6: Normalizasyon, bant geçiren filtre, yatay bant geçiren filtre, Gauss filtre, derinliğe bağlı kazanç, dinamik arka plan çıkarımı, Gabor filtresi, sabit eşikleme ve erozyon kullanıldı. Çıkarılan öznitelik ise beyaz bölgeden elde edilen alandır. Kullanılan Gabor filtresi parametreleri tablo 4.3'te verilmiştir.

Tablo 4.3 İkili sınıflandırma yöntem-6'da Gabor filtresi parametreleri

Parametreler	Filtre-1	Filtre-2	Filtre-3	Filtre-4
Dalga Boyu (λ)	4	4	4	4
Yönelim (θ)	0.52	0.78	-0.52	-0.78
Standart Sapma (σ)	10	10	10	10
Asimetri Parametresi (γ)	1	1	1	1

İkili-7’de, normalizasyon, bant geçiren filtre, yatay bant geçiren filtre, Gauss filtre, dinamik arka plan çıkarımı ve adaptif eşikleme kullanıldı. Çıkarılan öznelite ise beyaz bölgeden elde edilen alan, ortalama, 2. moment, 3. moment ve parabol denkleminde elde edilen katsayılarıdır.

İkili-8’de, normalizasyon, bant geçiren filtre, yatay bant geçiren filtre, Gauss filtresi, dinamik arka plan çıkarımı, Gabor filtresi, sabit eşikleme kullanıldı. Çıkarılan öznelite ise parabol denkleminde elde edilen katsayılarıdır.

İkili-9’da ise normalizasyon, bant geçiren filtre, yatay bant geçiren filtre, Gauss filtresi, sabit arka plan çıkarımı, adaptif eşikleme kullanıldı. Çıkarılan öznelite ise parabol denkleminde elde edilen katsayılarıdır.

Tablo 4.4 İkili sınıflandırmada veri işleme süreçleri ve öznelite çıkarma yöntemleri

Süreçler	Uygulanan Bölge	Yöntemler								
		1	2	3	4	5	6	7	8	9
Normalizasyon	A-taramalar	Evet	Evet	Evet	Evet	Evet	Evet	Evet	Evet	Evet
Bant Geçiren Filtre	A-taramalar	Evet	Evet	Evet	Evet	Evet	Evet	Evet	Evet	Evet
Yatay Bant Geçiren Filtre	GPR verilerinin Satırları	Evet	Evet	-	Evet	-	Evet	Evet	Evet	Evet
Derinliğe Bağlı Kazanç	A-taramalar	-	-	-	-	-	Evet	-	-	-
Gauss Filtresi	B-taramalar	Evet	Evet	-	Evet	Evet	-	Evet	Evet	Evet
Sabit Arka Plan Çıkarımı	B-taramalar	-	Evet	Evet	Evet	-	-	-	-	Evet
Dinamik Arka Plan Çıkarımı	B-taramalar	Evet	-	-	-	Evet	Evet	Evet	Evet	-
Gabor filtresi	B-taramalar	-	-	Evet	Evet	-	Evet	-	Evet	-
Sabit Eşikleme	B-taramalar	-	-	Evet	Evet	-	Evet	-	Evet	-
Adaptif Eşikleme	B-taramalar	Evet	Evet	-	-	Evet	-	Evet	-	Evet
Morfolojik İşlem (Erozyon)	B-taramalar, binary	-	-	-	-	-	Evet	-	-	-
Morfolojik İşlem (İskelet)	B-taramalar, binary	-	-	-	-	-	-	-	-	Evet
Parabol Uydurma	B-taramalar, binary	Evet	Evet	-	-	Evet	-	Evet	Evet	Evet
Alan Hesaplama	B-taramalar, binary	-	-	Evet	Evet	Evet	Evet	Evet	-	-
Ortalama ve Momentleri Hesaplama	B-taramalar, binary	-	-	-	Evet	Evet	-	Evet	-	-

4.2 Çoklu Sınıflandırmaya Yönelik GPR Verilerinin İşleme Süreci

GPR verilerinin çoklu sınıflandırmasında kullanılan GPR veri seti, altı farklı sınıfa içermektedir. Bu sınıflar ve toplam görüntü sayısı Tablo 4.5’de verilmiştir. Her bir sınıf, farklı fiziksel ve yapısal özellikleri temsil etmektedir. Bu sınıflara ait örnek GPR görüntüleri Şekil 4.3’te sunulmuştur.

Tablo 4.5’te gösterilen 1040 verilik veri seti, Tablo 4.1’de gösterilen 1080 verilik veri setine benzer bir yapıya sahiptir. Ancak, tespit edilmesi oldukça zor olan bazı cisimlerin (örneğin çivi) GPR görüntüleri veri setinden çıkarılmıştır. Bu seçim, sınıflandırma problemini daha dengeli hale getirmek ve veri setinin genel zorluk seviyesini optimize etmek amacıyla yapılmıştır.

Tablo 4.5 Çoklu sınıflandırma aşamasında kullanılan Veri setinin içeriği

Taklit Mayın (Tehtit)	440
Metal içermeyen taklit anti-tank mayın	60
Az metal içeren taklit anti-personel mayın	120
Yüksek metal içeren taklit anti-personel mayın	100
Yüksek metal içeren taklit büyük boy anti-tank mayın	160
Diğer Cisim (Tehtit içermiyor)	600
metal içermeyen doğal cisim (taş)	120
Yüksek metal içeriğine sahip diğer cisim (örneğin kola kutusu)	480
Toplam	1040

Sınıflandırma süreci Tablo 4.6’te görüldüğü gibi önışleme, arka plan çıkarımı, son işlem, öznitelik çıkarımı ve sınıflandırma işlemlerinden oluşmaktadır. Önışleme aşamasında ilk olarak bant geçiren filtre uygulanır. Bu işlem, sinyallere karışan gürültü ve kargaşayı azaltarak daha tutarlı veriler elde edilmesini sağlar. Filtreleme sürecinin ardından yönteme bağlı olarak arama başlığının yüksekliğindeki değişiklikten kaynaklanan kargaşayı azaltmak için yatay bant geçiren filtre (GPR satırlarına) uygulanır.



a) Tehdit içermeyen doğal nesne




b) Tehdit içermeyen yüksek metalik nesne



c) Metal içermeyen büyük boy taklit anti-tank mayın



d) Az metal içeren taklit anti-personel mayın



e) Çok metal içeren taklit anti-personel mayını



f) Çok metal içeren büyük boy taklit anti-tank mayını

Şekil 4.3 Çoklu sınıflandırmada kullanılan örnek GPR görüntüleri

Arka plan çıkarımında ikili sınıflandırmada olduğu gibi ortalama alma yöntemi ile arka plan çıkarımı yapılmaktadır. Bu işlem yönteme bağlı olarak sabit ve arka plan çıkarımı Tablo 4.6’te görüldüğü gibi yapılmaktadır.

Son işlem aşamasında yönteme bağlı olarak 2 boyutlu dalgacık dönüşüm, 2 boyutlu Fourier dönüşüm, yumuşatma filtreleri, eşikleme ve morfolojik işlemler uygulanabilmektedir. Yumuşatma filtrelerinden 2 boyutlu Gauss filtresi kullanılmıştır. Eşikleme yöntemleri olarak sabit ve adaptif eşikleme yöntemi kullanılmıştır.

Çoklu sınıflandırmada elde edilen öznitelikler ikili GPR görüntüsünde bulunan beyaz bölgenin (ön bölge) alanı, ortalaması, 2.momenti, 3.momenti, ön bölgeye parabol uydurularak parabol denkleminde elde edilen katsayıları öznitelik olarak kullanılmıştır. Bunların yanında bazı yöntemlerde B-tarama GPR verisi ikili hale getirilmeden önce 2 boyutlu Fourier dönüşümü alınmış ve elde edilen 2 boyutlu görüntünün merkez bölgesindeki 128x128 boyutlarındaki kısmı, öznitelik olarak kullanılmak üzere vektör haline getirilmiştir.

Tablo 4.6’te, çeşitli parametreler göz önüne alınarak belirlenen 28 farklı sınıflandırma yöntemine dair ayrıntılı bilgiler sunulmaktadır. Her sınıflandırma yöntemi, veri işleme sürecinde farklı adımları içermektedir ve bu yöntemlerin her birinde, veri setine özgü belirli ihtiyaçlar doğrultusunda farklı ön işleme, arka plan çıkarma, son işlem, öznitelik çıkarma ve sınıflandırma algoritmaları kullanılmaktadır. Bu yöntemler, her aşamada farklı teknikler ve algoritmaların bir kombinasyonu olarak geliştirilmiştir.

Tablo 4.6 Çoklu sınıflandırma veri işleme adımları ve öznitelik çıkarma yöntemleri

Yöntemler	Bant Geçiren Filtre (A-Tarama)	Yatay Bant Geçiren Filtre (B-tarama)	Arka Plan Çıkarımı	Dalgacık Dönüşüm	Fourier Dönüşüm	Eşikleme	Gauss Filtre	Öznitelik Kümesi
Çoklu-1	Evet	-	Sabit	-	-	Adaptif	-	3
Çoklu-2	Evet	-	Sabit	-	-	Adaptif	Evet	3
Çoklu-3	Evet	-	Sabit	-	-	Sabit	-	1
Çoklu-4	Evet	-	Sabit	-	-	Sabit	-	2
Çoklu-5	Evet	-	Sabit	-	-	Adaptif	Evet	5
Çoklu-6	Evet	-	Sabit	-	-	Sabit	-	3
Çoklu-7	Evet	-	Sabit	-	Evet	-	-	4
Çoklu-8	Evet	-	Dinamik	-	-	Adaptif	-	3
Çoklu-9	Evet	-	Dinamik	-	-	Adaptif	Evet	3
Çoklu-10	Evet	-	Dinamik	-	-	Sabit	-	1
Çoklu-11	Evet	-	Dinamik	-	-	Sabit	-	2
Çoklu-12	Evet	-	Dinamik	-	-	Adaptif	Evet	5
Çoklu-13	Evet	-	Dinamik	-	-	Sabit	-	3
Çoklu-14	Evet	-	Dinamik	-	Evet	-	-	4
Çoklu-15	Evet	Evet	Dinamik	-	-	Adaptif	-	3
Çoklu-16	Evet	Evet	Dinamik	-	-	Adaptif	Evet	3
Çoklu-17	Evet	Evet	Dinamik	-	-	Sabit	-	1
Çoklu-18	Evet	Evet	Dinamik	-	-	Sabit	-	2
Çoklu-19	Evet	Evet	Dinamik	-	-	Adaptif	Evet	5
Çoklu-20	Evet	Evet	Dinamik	-	-	Sabit	-	3
Çoklu-21	Evet	Evet	Dinamik	-	Evet	-	-	4
Çoklu-22	Evet	Evet	Sabit	Evet	-	Adaptif	-	3
Çoklu-23	Evet	Evet	Sabit	Evet	-	Adaptif	Evet	3
Çoklu-24	Evet	Evet	Sabit	Evet	-	Sabit	-	1
Çoklu-25	Evet	Evet	Sabit	Evet	-	Sabit	-	2
Çoklu-26	Evet	Evet	Sabit	Evet	-	Adaptif	-	5
Çoklu-27	Evet	Evet	Sabit	Evet	-	Sabit	-	3
Çoklu-28	Evet	Evet	Sabit	Evet	Evet	-	-	4

Tablo 4.7’te ise yöntemlere göre çıkarılan öznitelikler verilmektedir. Örneğin Çoklu-1, Çoklu-2, Çoklu-6, Çoklu-8, Çoklu-9, Çoklu-13, Çoklu-15, Çoklu-16, Çoklu-20, Çoklu-22, Çoklu-23 ve Çoklu-27’de parabol denkleminin katsayılarından elde edilen öznitelik kullanılmıştır

Tablo 4.7 Çoklu sınıflandırma Öznitelik kümesi

Öznitelik Kümesi	İşlenmiş Verilerden Çıkarılan Öznitelikler
1	beyaz bölge alanı
2	Beyaz Bölge alanı, ortalaması ve Momentleri
3	Parabol Uydurma
4	Fourier dönüşüm genlik bilgisi
5	Beyaz Bölge alanı,ortalaması,Momentleri ve Parabol Uydurma

Çoklu sınıflandırma için veri işleme sürecinde yöntemlerde yapılan işlemler şu şekildedir:

Çoklu-1: Bant geçiren filtre, sabit arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Çıkarılan öznelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti ve 3. momentidir.

Çoklu-2: Bant geçiren filtre, dinamik arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Çıkarılan öznelikler, parabol denkleminin katsayılarıdır.

Çoklu-3: Bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme kullanılmıştır. Öznelik olarak ikili GPR görüntüsünün beyaz bölge alanı çıkarılmıştır.

Çoklu-4: Bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme uygulanmıştır. Çıkarılan öznelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti ve 3. momentidir.

Çoklu-5: Bant geçiren filtre, sabit arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Çıkarılan öznelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti, 3. momenti ve parabol denkleminin katsayılarıdır.

Çoklu-6: Bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme uygulanmıştır. Öznelik olarak ikili GPR görüntüsünün beyaz bölge alanı hesaplanmıştır.

Çoklu-7: Bant geçiren filtre, sabit arka plan çıkarımı, Fourier dönüşümü uygulanmıştır. Fourier dönüşümünden elde edilen genlik bilgisi öznelik olarak kullanılmıştır.

Çoklu-8: Bant geçiren filtre, dinamik arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Öznelik olarak parabol denkleminin katsayıları kullanılmıştır.

Çoklu-9: Bant geçiren filtre, dinamik arka plan çıkarımı ve adaptif eşikleme kullanılmıştır. Çıkarılan öznelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti, 3. momenti ve parabol denkleminin katsayılarıdır.

Çoklu-10: Bant geçiren filtre, dinamik arka plan çıkarımı ve sabit eşikleme uygulanmıştır. Öznelik olarak ikili GPR görüntüsünün beyaz bölge alanı çıkarılmıştır.

Çoklu-11: Bant geçiren filtre, dinamik arka plan çıkarımı ve sabit eşikleme uygulanmıştır. Çıkarılan öznelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti ve 3. momentidir.

Çoklu-12: Bant geçiren filtre, dinamik arka plan çıkarımı ve adaptif eşikleme kullanılmıştır. Çıkarılan öznelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti, 3. momenti ve parabol denkleminin katsayılarıdır.

Çoklu-13: Bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme kullanılmıştır. Öznitelik olarak ikili GPR görüntüsünün beyaz bölge alanı hesaplanmıştır.

Çoklu-14: Bant geçiren filtre, yatay bant geçiren filtre, dinamik arka plan çıkarımı, Fourier dönüşümü uygulanmıştır. Fourier dönüşümünden elde edilen genlik bilgisi öznitelik olarak kullanılmıştır.

Çoklu-15: Bant geçiren filtre, yatay bant geçiren filtre, dinamik arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Öznitelik olarak parabol denkleminin katsayıları kullanılmıştır.

Çoklu-16: Bant geçiren filtre, yatay bant geçiren filtre, dinamik arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Çıkarılan öznitelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti, 3. momenti ve parabol denkleminin katsayılarıdır.

Çoklu-17: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme kullanılmıştır. Öznitelik olarak ikili GPR görüntüsünün beyaz bölge alanı hesaplanmıştır.

Çoklu-18: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme kullanılmıştır. Çıkarılan öznitelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti ve 3. momentidir.

Çoklu-19: Bant geçiren filtre, yatay bant geçiren filtre, dinamik arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Çıkarılan öznitelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti, 3. momenti ve parabol denkleminin katsayılarıdır.

Çoklu-20: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme kullanılmıştır. Öznitelik olarak ikili GPR görüntüsünün beyaz bölge alanı hesaplanmıştır.

Çoklu-21: Bant geçiren filtre, yatay bant geçiren filtre, dinamik arka plan çıkarımı, Fourier dönüşümü uygulanmıştır. Fourier dönüşümünden elde edilen genlik bilgisi öznitelik olarak kullanılmıştır.

Çoklu-22: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Öznitelik olarak parabol denkleminin katsayıları kullanılmıştır.

Çoklu-23: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı ve adaptif eşikleme uygulanmıştır. Çıkarılan öznitelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti, 3. momenti ve parabol denkleminin katsayılarıdır.

Çoklu-24: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme uygulanmıştır. Öznitelik olarak ikili GPR görüntüsünün beyaz bölge alanı hesaplanmıştır.

Çoklu-25: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme uygulanmıştır. Çıkarılan öznelikler, ikili GPR görüntüsünün beyaz bölgesinin alanı, ortalaması, 2. momenti ve 3. momentidir.

Çoklu-27: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı ve sabit eşikleme kullanılmıştır. Öznelik olarak ikili GPR görüntüsünün beyaz bölge alanı hesaplanmıştır.

Çoklu-28: Bant geçiren filtre, yatay bant geçiren filtre, sabit arka plan çıkarımı, dalgacık dönüşüm ve Fourier dönüşümü uygulanmıştır. Fourier dönüşümünden elde edilen genlik bilgisi öznelik olarak kullanılmıştır.



Bu bölümde, GPR verilerinin işlenmesi sürecinde gerçekleştirilen ikili ve çoklu sınıflandırma aşamalarına ait deneysel sonuçlar sunulmuştur. Öncelikle, hedef nesnelerin belirlenmesine yönelik tespit çalışmaları, kullanılan yöntemlerin performansına dair bulgularla birlikte açıklanmıştır. Ardından, tespit edilen nesnelerin türlerine göre ikili ve çoklu sınıflandırılması detaylandırılmıştır. Bu kapsamda, her iki aşamaya ait analizler, yöntemlerin etkinliği ve doğruluk oranları temel alınarak değerlendirilmiştir. Bu çalışmada kullanılan veriler TÜBİTAK BİLGEM BTE MEKTAM test sahasında akademik amaçla toplanmıştır.

5.1 İkili Sınıflandırmaya Yönelik Deneysel Sonuçlar

İkili sınıflandırma için geliştirilen bu metodolojiler, gömülü nesneleri sınıflandırma amacıyla GPR verilerinin işlenmesi ve analiz edilmesi için 520 ve 1080 gerçek veri içeren iki veri seti üzerinde test edildi. Veri setimiz temelde iki farklı sınıfı içermektedir. Bunlar taklit mayın ve diğer cisim (yağ tenekesi, plastik materyal, taş, vb.) şeklindedir. Sınıflandırma sonuçları Tablo 5.1’te ve Tablo 5.2’te verilmiştir. İkili-6 haricinde Gabor filtresi kullanılan yöntemlerde Gabor filtresinin parametreleri $\lambda = 10$, $\theta=0$, $\sigma=10$ ve $\gamma=1$ şeklindedir.

Bu yöntemler Random Forest, K-NN ve SVM sınıflandırma algoritmaları ile Weka [147] yazılımı üzerinde sınıflandırıldı. Sonuç olarak Random Forest, K-NN ve SVM algoritmaları ile %45 ile %100 arasında doğruluk oranı elde edildi.

Tablo 5.1 İkili sınıflandırmada 520 veri seti için performans değerleri

Yöntemler	Veri Seti	Random Forest			K-NN			SVM		
		Accuracy	MAE	RMSE	Accuracy	MAE	RMSE	Accuracy	MAE	RMSE
İkili-1	520	0,990	0,022	0,150	0,990	0,007	0,065	0,740	0,260	0,510
İkili-2	520	0,990	0,038	0,110	0,981	0,023	0,127	0,875	0,120	0,350
İkili-3	520	0,981	0,032	0,120	1,000	0,000	0,000	0,904	0,096	0,310
İkili-4	520	1,000	0,000	0,000	0,990	0,010	0,098	0,913	0,087	0,290
İkili-5	520	1,000	0,000	0,000	1,000	0,000	0,000	0,980	0,019	0,130
İkili-6	520	0,990	0,026	0,087	0,990	0,010	0,073	0,980	0,019	0,130
İkili-7	520	1,000	0,000	0,000	0,870	0,130	0,290	0,960	0,039	0,196
İkili-8	520	0,990	0,041	0,092	0,990	0,010	0,070	0,798	0,200	0,440
İkili-9	520	0,971	0,108	0,192	0,910	0,090	0,270	0,740	0,250	0,500

Tablo 5.2 İkili sınıflandırmada 1080 veri seti için performans değerleri

Yöntemler	Veri Seti	Random Forest			K-NN			SVM		
		Accuracy	MAE	RMSE	Accuracy	MAE	RMSE	Accuracy	MAE	RMSE
İkili-1	1080	0,931	0,170	0,250	0,903	0,115	0,290	0,750	0,250	0,500
İkili-2	1080	0,903	0,192	0,281	0,861	0,158	0,329	0,681	0,310	0,560
İkili-3	1080	0,818	0,250	0,360	0,833	0,171	0,353	0,557	0,050	0,443
İkili-4	1080	0,875	0,206	0,302	0,870	0,164	0,306	0,745	0,255	0,505
İkili-5	1080	0,931	0,150	0,230	0,926	0,085	0,226	0,819	0,180	0,420
İkili-6	1080	0,931	0,160	0,245	0,907	0,098	0,247	0,764	0,230	0,480
İkili-7	1080	0,954	0,150	0,230	0,870	0,136	0,294	0,912	0,080	0,290
İkili-8	1080	0,926	0,165	0,241	0,856	0,139	0,304	0,704	0,290	0,540
İkili-9	1080	0,917	0,224	0,292	0,907	0,123	0,279	0,713	0,280	0,530

İkili sınıflandırma sonuçları, 9 farklı yöntem için Random Forest, K-NN (K=3) ve SVM algoritmalarıyla gerçekleştirilen değerlendirmeleri içermektedir. Birinci adımda 520, ikinci adımda ise 1080 veri kullanılmıştır. Genel olarak, Random Forest algoritması her iki veri setinde de en başarılı sonuçları vermiştir. Özellikle 520 verilik dataset'te Random Forest, birçok yöntemde %100'e yakın doğruluk sağlamıştır. Ancak veri sayısı 1080'e çıktığında, Random Forest'in doğruluk oranında bir miktar azalma gözlenmiştir; buna rağmen diğer algoritmalarla kıyaslandığında daha istikrarlı kalmıştır. Random Forest algoritması hem küçük hem de büyük veri setlerinde en iyi ve tutarlı performansı sergilemiştir. K-NN algoritması genel olarak yüksek doğruluk oranları elde etmiş olsa da bazı yöntemlerde performans düşüşleri görülmektedir. SVM algoritması ise genel olarak en düşük doğruluk oranlarını göstermiştir. 520 veriden oluşan veri setinde, bazı yöntemlerde %90'a yaklaşan doğruluk sağlasa da veri setinin büyümesiyle birlikte performansında ciddi bir düşüş yaşanmıştır. Özellikle yöntem-2 ve yöntem-9'da SVM, doğruluk oranlarında %20'ye varan bir düşüş yaşamış ve 1080 verilik tabloda diğer algoritmaların gerisinde kalmıştır.

5.2 Çoklu Sınıflandırmaya Yönelik Deneysel Sonuçlar

Çoklu sınıflandırmaya yönelik geliştirilen yöntemlerde, gömülü nesnelerin sınıflandırılması amacıyla GPR verilerinin işlenmesi ve analiz edilmesi için 1040 gerçek veri içeren bir veri setinden oluşmaktadır. Bu veri seti GPR ile gömülü cisim tespiti için kullanılan 1080 veri seti ile aynı fakat bazı anlamsız ve çok fazla kargaşa içeren görüntülerin çıkarılmış halidir. Veri seti 6 farklı sınıftan oluşmaktadır. Bu sınıflar, taklit anti-tank (AT) mayınları, taklit anti-personel (AP) mayınları, az metal içeren taklit AT ve AP mayınları, metal içermeyen taklit mayınlar ve diğer cisimlerdir (metal disk, yağ tenekesi, taş, plastik şişe, çivi, kola tenekesi).

Python ortamında gerçekleştirilen makine öğrenmesi yöntemlerinden Random Forest, K-Nearest Neighbors (K-NN, K=3) ve Destek Vektör Makineleri (SVM) ile sınıflandırma işleminde, verilerin %80'i eğitim için, kalan %20'si ise test aşaması için ayrılmıştır. Eğitim aşamasında veri seti, her bir sınıflandırma algoritması için öznitelik vektörleri üzerinden eğitilmiş ve test aşamasında ise algoritmaların performansı değerlendirilmiştir.

Elde edilen sonuçlar Tablo 5.3'te verilmiştir. Buna göre, ortalama başarımlar oranı açısından en iyi sonuç, %85,73 doğruluk oranı ile Random Forest algoritmasından

alınmıştır. Bu sonuç, Random Forest algoritmasının istikrarlı bir şekilde yüksek doğruluk sağlayabildiğini göstermektedir. Bununla birlikte, test edilen yöntemler arasında tekil olarak en yüksek doğruluk oranı, K-NN algoritmasının Çoklu-28 üzerinde %99,0383 doğruluk oranı elde etmesiyle kaydedilmiştir. K-NN algoritmasının en düşük performansı %58,17 ile tespit edilmiştir. Bu oran, özellikle kullanılan metot ve veri setine bağlı olarak algoritmanın başarısının değişebileceğini göstermektedir. Verilen sonuçlar arasında, SVM algoritması da bazı yöntemlerde yüksek doğruluk oranları sağlarken, diğer yöntemlerde sınırlı bir başarı göstermiştir. Örneğin, Çoklu-28'de %97,12 doğruluk oranı elde edilmiş ve bu oran, algoritmanın güçlü yönlerini yansıtmıştır. SVM'in doğruluk oranı, bazı yöntemlerde diğer algoritmalara kıyasla daha düşük olsa da Fourier dönüşümü özneliği ile çalıştığına Random Forest algoritmasından yüksek ve K-NN'e yakın sonuçlar vermiştir

Tablo 5.3 Çoklu sınıflandırmada 1040 veri seti için performans değerleri

Yöntemler	Random Forest			K-NN			SVM		
	Accuracy	MAE	RMSE	Accuracy	MAE	RMSE	Accuracy	MAE	RMSE
Çoklu-1	0,938	0,168	0,676	0,899	0,250	0,866	0,543	1,159	1,888
Çoklu-2	0,926	0,082	0,450	0,885	0,308	1,000	0,639	0,942	1,707
Çoklu-3	0,837	0,440	1,175	0,880	0,322	1,058	0,558	1,154	1,937
Çoklu-4	0,851	0,409	1,179	0,841	0,389	1,141	0,649	1,029	1,886
Çoklu-5	0,966	0,091	0,550	0,909	0,250	0,912	0,861	0,462	1,297
Çoklu-6	0,913	0,226	0,874	0,779	0,567	1,383	0,433	1,361	2,025
Çoklu-7	0,870	0,428	1,179	0,962	0,101	0,584	0,904	0,269	0,946
Çoklu-8	0,861	0,289	0,861	0,788	0,524	1,280	0,567	1,019	1,710
Çoklu-9	0,942	0,130	0,584	0,841	0,385	1,065	0,654	0,784	1,492
Çoklu-10	0,769	0,596	1,369	0,827	0,433	1,139	0,601	1,067	1,873
Çoklu-11	0,769	0,572	1,321	0,745	0,678	1,479	0,678	0,832	1,634
Çoklu-12	0,933	0,106	0,460	0,918	0,164	0,620	0,870	0,322	0,993
Çoklu-13	0,923	0,151	0,380	0,903	0,230	0,656	0,883	0,300	0,851
Çoklu-14	0,894	0,365	1,083	0,952	0,144	0,714	0,923	0,178	0,697
Çoklu-15	0,899	0,240	0,861	0,731	0,664	1,454	0,471	1,216	1,923
Çoklu-16	0,918	0,154	0,612	0,861	0,317	0,946	0,558	0,928	1,561
Çoklu-17	0,822	0,414	1,109	0,803	0,433	1,135	0,534	1,164	1,912
Çoklu-18	0,817	0,447	1,175	0,779	0,529	1,282	0,678	0,851	1,683
Çoklu-19	0,923	0,173	0,693	0,899	0,269	0,946	0,837	0,394	1,092
Çoklu-20	0,938	0,139	0,601	0,861	0,394	1,135	0,534	1,029	1,698
Çoklu-21	0,899	0,322	0,998	0,947	0,173	0,803	0,918	0,207	0,788
Çoklu-22	0,769	0,505	1,187	0,625	0,885	1,629	0,466	1,293	1,989
Çoklu-23	0,817	0,481	1,263	0,649	0,865	1,632	0,486	1,188	1,849
Çoklu-24	0,630	0,976	1,791	0,582	1,043	1,825	0,457	1,322	2,004
Çoklu-25	0,673	0,779	1,535	0,697	0,793	1,601	0,601	1,111	1,918
Çoklu-26	0,798	0,490	1,248	0,779	0,567	1,334	0,683	0,760	1,500
Çoklu-27	0,813	0,332	0,885	0,697	0,789	1,602	0,519	1,091	1,777
Çoklu-28	0,918	0,216	0,794	0,990	0,029	0,310	0,971	0,082	0,495
Ortalama									
Başarım (%)	85,81%			82,24%			65,97%		

Bu çoklu sınıflandırma çalışmasında kullanılan öznelilikler arasında, Fourier dönüşümü ile elde edilen vektörel formdaki genlik bilgisi, sınıflandırmada en iyi sonuç veren öznelilik olmuştur. Bu yöntem, özellikle frekans tabanlı analizlerde veri setinin yapısal özelliklerini yakalama konusunda oldukça başarılıdır. Fourier

dönüşümünden elde edilen bu bilgi, K-NN, Random Forest ve SVM algoritmaları ile yapılan sınıflandırmalarda en yüksek doğruluk oranlarına ulaşılmasına katkı sağlamıştır.

Tablo 5.4'te, beş farklı öznitelik kümesine göre sınıflandırma algoritmalarının en iyi sonuçları karşılaştırılmıştır. Çıkarılan öznitelik kümeleri ve sınıflandırma performansları incelendiğinde, en iyi sonucu Öznitelik Kümesi 4 vermiştir. Bu küme, Fourier dönüşümünden elde edilen genlik bilgisi içerdiğinden, sınıflar arasındaki farkları en belirgin hale getirmiş ve tüm sınıflandırma algoritmalarında yüksek doğruluk sağlamıştır. Öznitelik Kümesi 5'te, beyaz bölgeye uydurulan parabol denkleminin katsayıları ve nesne alanına yönelik (alan, ortalama ve momentler) bilgileri içererek en iyi ikinci sonucu vermiştir. Genlik bilgisine kıyasla daha düşük doğruluk göstermesine rağmen, belirli sınıflarda ayırt ediciliği artırmıştır.

Tablo 5.4 Çoklu sınıflandırma En iyi Öznitelik Kümesi

Öznitelik Kümesi	Random Forest (%)	K-NN (%)	SVM (%)	Ortalama Başarım (%)
1	0,822	0,880	0,601	0,768
2	0,851	0,841	0,678	0,790
3	0,962	0,903	0,883	0,916
4	0,918	0,990	0,971	0,960
5	0,966	0,918	0,870	0,918

Tablo 5.5, 5.7 ve 5.9'da yer alan sınıflar, GPR verileri kullanılarak sınıflandırılan farklı türdeki nesneleri temsil etmektedir. Bu sınıflar iki temel gruba ayrılmaktadır: tehdit içermeyen cisimler ve tehdit içeren cisimler.

Sınıf 0, Metal içermeyen nesneleri kapsamaktadır. Bu grupta taş, cam şişe gibi doğal ya da zararsız nesneler bulunmaktadır. Sınıf 1, Metal içeren ancak tehdit unsuru taşımayan nesnelerden oluşmaktadır. Örneğin, yağ tenekesi, metal disk gibi nesneler bu sınıfa dahildir.

Sınıf 2, Metal içermeyen, büyük boy taklit anti-tank mayınlarını içermektedir. Sınıf 3, Az metal içeren taklit anti-personel mayınlarını temsil etmektedir. Sınıf 4, Çok metal içeren taklit anti-personel mayınlarını içermektedir. Sınıf 5, Çok metal içeren, büyük boy taklit anti-tank mayınlarını içermektedir.

Tablo 5.5, SVM algoritmasının çoklu-28 yöntemi ile elde ettiği precision, recall ve F1-score değerlerini göstermektedir. Sonuçlara bakıldığında, Sınıf 4 ve Sınıf 5'in precision ve recall değerlerinin yüksek olduğu görülmektedir. Bu durum, çok metal içeren nesnelerin daha belirgin sinyaller oluşturması sayesinde modelin bu sınıfları daha net ayırt edebilmesiyle açıklanabilir. Sınıf 0 ve Sınıf 1'de recall değerleri yüksek, çünkü tehdit içermeyen nesneler genellikle yanlış negatif oranı düşük olan sınıflardır. Ancak precision değerleri bazı durumlarda düşüş göstermektedir, bu da

modelin bu sınıfları tahmin ederken zaman zaman yanlış pozitif üretmesine neden olmaktadır. Sınıf 2 ve Sınıf 3 için recall değerleri düşüktür, yani model bu sınıfları yeterince iyi tanıyamamış ve bazı örnekleri yanlış negatif olarak sınıflandırmıştır.

Tablo 5.5 SVM algoritması için en iyi yöntemin (çoklu-28) sınıf bazlı performans değerleri

Çoklu-28 - SVM	Diğer Cisim Sınıfları	Sınıf	Precision	Recall	f1-Score	Nesne Adedi
		0	0,94	1,00	0,97	29
	Taklit Mayın Sınıfları	1	1,00	0,99	0,99	89
		2	1,00	0,64	0,78	14
		3	1,00	1,00	1,00	24
		4	1,00	1,00	1,00	19
		5	0,89	1,00	0,94	33

Tablo 5.5, Tablo 5.6'te verilen sınıf bazlı precision, recall ve F1-score değerlerinin, taklit mayın ve diğer cisimler şeklinde gruplandırılarak hesaplanmış ortalama değerlerini göstermektedir. Bu tabloda, diğer cisimler için belirtilen precision, recall ve F1-score değerleri Sınıf 0 ve Sınıf 1'in ortalamalarından, taklit mayınlar için verilen değerler ise Sınıf 2, Sınıf 3, Sınıf 4 ve Sınıf 5'in ortalamalarından elde edilmiştir.

Tablo 5.6 SVM algoritması için en iyi yöntemin (çoklu-28) sınıf bazlı ortalama performans değerleri

Çoklu-28 : SVM	Precision	Recall	f1-Score
Diğer Cisim Sınıfları	0,97	0,995	0,98
Taklit Mayın Sınıfları	0,97	0,91	0,93

Tablo 5.7, K-NN algoritmasının çoklu-28 yöntemi ile elde ettiği precision, recall ve F1-score değerlerini sınıf bazında göstermektedir. Sonuçlar incelendiğinde, Sınıf 4 ve Sınıf 5'te precision değerlerinin yüksek olduğu görülmektedir, bu da modelin çok metal içeren nesneleri daha doğru şekilde tahmin ettiğini göstermektedir. Sınıf 0 ve Sınıf 1'de recall değerleri yüksek çıkmış, yani model tehdit içermeyen nesneleri büyük oranda doğru şekilde tespit edebilmiştir. Ancak Sınıf 2 ve Sınıf 3 için recall değerlerinin düşük olduğu gözlemlenmiştir, bu da modelin az metal içeren veya metal içermeyen tehdit içeren nesneleri yanlış negatif olarak sınıflandırma eğiliminde olduğunu göstermektedir. F1-score açısından en iyi değerler yine Sınıf 4 ve Sınıf 5'te elde edilmiştir, çünkü bu sınıflarda hem precision hem de recall değerleri dengeli sonuçlar vermiştir. Sınıf 2 ve Sınıf 3'te ise düşük recall nedeniyle F1-score değerlerinin düştüğü görülmektedir. Genel olarak K-NN algoritmasının, metal içeren nesneleri tespit etmekte başarılı olduğu ancak düşük metal içeren tehdit içeren nesnelerde hata oranının arttığı gözlemlenmiştir.

Tablo 5.7 KNN algoritması için en iyi yöntemin (çoklu-28) sınıf bazlı performans değerleri

		Sınıf	Precision	Recall	f1-Score	Nesne Adedi
Çoklu-28 - KNN	Diğer Cisim Sınıfları	0	0,97	1,00	0,98	29
		1	1,00	0,99	0,99	89
	Taklit Mayın Sınıfları	2	1,00	0,93	0,96	14
		3	1,00	1,00	1,00	24
		4	1,00	1,00	1,00	19
		5	0,97	1,00	0,99	33

Tablo 5.8’de, K-NN algoritmasının çoklu-28 yöntemi ile elde edilen sınıflandırma sonuçlarının gruplandırılmış ortalama precision, recall ve F1-score değerleri sunulmaktadır.

Tablo 5.8 KNN algoritması için en iyi yöntemin (çoklu-28) sınıf bazlı ortalama performans değerleri

Çoklu-28 : KNN	Precision	Recall	f1-Score
Diğer Cisim Sınıfları	0,985	0,995	0,985
Taklit Mayın Sınıfları	0,99	0,98	0,99

Tablo 5.9’da, Random Forest algoritmasının çoklu-5 yöntemi ile elde ettiği sınıf bazlı precision, recall ve F1-score değerleri incelendiğinde, modelin özellikle metal içeren nesneleri tespit etmede daha başarılı olduğu görülmektedir. Sınıf 4 ve Sınıf 5 için yüksek precision değerleri elde edilmiştir. Öte yandan, Sınıf 0 ve Sınıf 1 için yüksek recall değerleri, modelin tehdit içermeyen nesneleri büyük oranda doğru şekilde tespit ettiğini göstermektedir. Ancak precision değerlerinde zaman zaman düşüşler gözlemlenmesi, modelin bazı yanlış pozitifler üretebileceğini göstermektedir. Düşük recall değerlerine sahip olan Sınıf 2 ve Sınıf 3, düşük metal içeren veya metal içermeyen tehdit içeren nesneler olarak öne çıkmaktadır ve modelin bu nesneleri yanlış negatif olarak sınıflandırma eğiliminde olduğu gözlemlenmektedir. Genel olarak, Random Forest algoritmasının metal içeriği yüksek nesneleri başarılı bir şekilde sınıflandırdığı, ancak düşük metal içeriğine sahip tehdit unsurlarını ayırt etmede daha fazla hata yaptığı gözlemlenmiştir.

Tablo 5.9 Random Forest algoritması için en iyi yöntemin (çoklu-5) sınıf bazlı performans değerleri

		Sınıf	Precision	Recall	f1-Score	Nesne Adedi
Çoklu-5 - Random Forest	Diğer Cisim Sınıfları	0	0,96	0,93	0,95	29
		1	0,94	1,00	0,97	89
	Taklit Mayın Sınıfları	2	1,00	0,93	0,96	14
		3	1,00	1,00	1,00	24
		4	1,00	0,95	0,97	19
		5	1,00	0,91	0,95	33

Tablo 5.10’da ise Tablo 5.9’da sunulan sınıf bazlı performans değerleri gruplandırılarak tehdit içermeyen nesneler ve taklit mayınlar için hesaplanan

ortalama precision, recall ve F1-score deęerleri gsterilmektedir. Burada dikkat eken nokta, taklit mayınlar iin ortalama precision ve recall deęerlerinin nispeten daha dřk ıkmasıdır. Bu durum, modelin dřk metal ieren veya metal iermeyen tehdit ieren nesneleri tespit etmede zorlandıęını ortaya koymaktadır. te yandan, tehdit iermeyen nesneler iin yksek recall deęeri, modelin bu tr nesneleri byk oranda doęru řekilde tanıyabildięini gstermektedir.

Tablo 5.10 Random Forest algoritması iin en iyi yntemin (oklu-5) sınıf bazlı ortalama performans deęerleri

oklu-5 : Random Forest	Precision	Recall	f1-Score
Dięer Cisim Sınıfları	0,95	0,965	0,96
Taklit Mayın Sınıfları	1,00	0,95	0,97

Bu tezde, Ground Penetration Radar (GPR) verilerini kullanarak gömülü nesneleri sınıflandırmaya yönelik bir çalışma gerçekleştirilmiştir. Tez kapsamında iki ana problem üzerine odaklanılmıştır: ikili sınıflandırma (tehdit-tehdit değil) ve çoklu sınıflandırma (çok sınıflı sınıflandırma). Bu tez çalışmasında, ikili sınıflandırma için 9 farklı yöntem ve çoklu sınıflandırma için 28 farklı yöntemde başarımlar oranlarına bakılmıştır. Bu doğrultuda, GPR verileri üzerinde ön işleme, arka plan çıkarımı, son işlem, öznitelik çıkarma ve çeşitli makine öğrenmesi algoritmaları ile sınıflandırma işlemleri yapılmıştır. Tezde elde edilen bulgular ve sonuçlar aşağıdaki başlıklar altında tartışılmıştır.

6.1 GPR Verilerinin İşlenmesi ve Öznitelik çıkarımı

Çalışmanın başlangıç aşamasında, GPR verilerinin doğru bir şekilde işlenmesi büyük önem taşımaktadır. GPR verileri genellikle gürültülü ve karmaşık yapıda olduğu için, bu verilerin belirli bir ön işleme sürecinden geçirilmesi gerekmektedir. Bu bağlamda yonteme bağıli olarak normalizasyon, bant geçiren filtreler ve yatay bant geçiren filtreler çıkarma gibi ön işleme teknikleri kullanılmıştır. Bu süreç verilerdeki gereksiz bileşenleri ve gürültüleri bertaraf edilmesini sağlayarak daha anlamlı veriler elde edilmesine olanak tanımıştır.

Öznitelik çıkarma aşamasında, ikili GPR görüntüsündeki beyaz bölgelerin alanları, ortalamaları, 2.momentleri, 3.momentleri, beyaz bölgelere uydurulan parabol 'ün katsayıları ve arka plan çıkarılmış GPR verisinin Fourier dönüşümünden elde edilen genlik bilgisi öznitelik olarak kullanılmıştır.

6.2 İkili Sınıflandırma

İkili sınıflandırma aşamasında, GPR verilerinin sınıflandırılması için kullanılan ön işleme, arka plan çıkarımı ve öznitelik çıkarma yöntemleriyle birlikte çeşitli örüntü tanıma algoritmalarının performansı incelenmiştir. 520 ve 1080 veri olmak üzere iki farklı veri seti üzerinde yapılan deneyler sonucunda Random Forest, K-NN ve SVM algoritmalarının sınıflandırma doğrulukları karşılaştırılmıştır. Elde edilen bulgular, kullanılan veri işleme adımlarının ve sınıflandırma algoritmalarının doğruluk oranlarını büyük ölçüde etkilediğini göstermektedir.

520 verilik veri setinde, Random Forest hemen hemen tüm yöntemlerde %100'e yakın doğruluk sağlamıştır. Özellikle İkili-4 ve İkili-5 %100 doğruluk oranı ile en iyi performansı göstermiştir. K-NN (K=3), İkili-3 ve İkili-5'te %100 doğruluk oranına ulaşırken, diğer metotlarda %87 ile %99 arasında yüksek doğruluklar elde edilmiştir. SVM ise diğer algoritmalara kıyasla daha düşük performans sergilemiş,

yöntem-5'te %98,07 ile en yüksek doğruluğu sağlarken bazı yöntemlerde %74'e kadar düşmüştür.

1080 verilik veri setinde de Random Forest, veri seti büyüklüğüne rağmen yüksek performansını korumuş ve İkili-1, İkili-5 ve İkili-6'da %93 doğruluk oranına ulaşmıştır. En iyi doğruluk oranını ise İkili-7'de %95,3704 doğruluk oranı ile sağlamıştır. K-NN algoritması, %92,59 ile İkili-5'te en iyi sonucu verirken, diğer yöntemlerde %85 ile %90 arasında sonuçlar elde etmiştir. SVM algoritması ise daha büyük veri seti ile birlikte performans düşüşü yaşamış ve doğruluk oranları %64 ile %78 arasında değişiklik göstermiştir. Özellikle yöntem-2 ve yöntem-9'da SVM'in performans düşüşü belirgin olmuştur. Her iki veri seti için en iyi yöntem sınıflandırma sonuçlarına göre İkili-5 olmuştur.

Sonuç olarak, Random Forest hem küçük hem büyük veri setlerinde en başarılı algoritma olarak öne çıkmıştır. Karmaşık veri yapıları ve dinamik arka plan çıkarma işlemleri ile yüksek doğruluk oranları sunmuştur. K-NN, bazı metotlarda yüksek doğruluk sağlasa da performansı dalgalı olmuştur. SVM ise özellikle büyük veri setlerinde daha düşük doğruluk oranlarıyla sınırlı kalmıştır.

6.3 Çoklu Sınıflandırma

Çoklu sınıflandırma aşamasında, altı farklı sınıfa ait (taklit anti-tank (AT) mayınları, taklit anti-personel (AP) mayınları, az metal içeren taklit AT ve AP mayınları, metal içermeyen taklit mayınlar ve diğer cisimler) nesnelerin sınıflandırılması yapılmıştır. Bu aşamada, nesnelerin hangi tür nesne olduğunu belirlemek hedeflenmiştir. Çoklu sınıflandırma işlemi, ikili sınıflandırma işlemine kıyasla daha zorlayıcı olmuştur; zira sınıf sayısının artması, sınıflandırma algoritmalarının daha karmaşık verilerle çalışmasını gerektirmiştir. Ancak Fourier dönüşümünden elde edilen genlik bilgisi, çoklu sınıflandırma sürecinde önemli katkılar sağlamıştır.

Sınıflandırma sonuçlarına göre, en yüksek doğruluk oranı %99,04 ile **Çoklu-7** kullanılarak **K-NN** algoritmasında elde edilmiştir. Bu sonuç, K-NN algoritmasının GPR verileri üzerinde yüksek başarı gösterdiğini ve özellikle Çoklu-7 ile kullanıldığında sınıflandırmada oldukça etkili olduğunu göstermektedir. Benzer şekilde, **Çoklu-7**'de kullanılan **SVM** algoritması %97,12 doğruluk oranı ile oldukça başarılı bir performans sergilemiştir. Bu sonuç, SVM'nin belirli öznetelik çıkarma yöntemleriyle entegre edildiğinde rekabetçi bir doğruluk oranına ulaşabildiğini göstermektedir. Diğer yandan, **Çoklu-5**'te **Random Forest** algoritması %96,63 doğruluk oranı ile iyi bir performans sergilemiş, tekil sınıflandırma sonuçlarına göre K-NN ve SVM algoritmalarının gerisinde kalmıştır ancak ortalama başarı oranına bakıldığında zaman en iyi sonucu veren algoritma Random Forest algoritması olmuştur. Yani tüm yöntemlere göre en stabil çalışan algoritma Random Forest algoritması olmuştur. En düşük doğruluk sonucu **SVM** algoritmasıyla %43,27 ile elde edilmiştir. **K-NN** algoritmasında en düşük doğruluk oranı %58,17 iken, **Random Forest** algoritmasında bu oran %62,98 olarak tespit edilmiştir. Bu

sonuçlara göre çoklu sınıflandırmada en iyi yöntemin sınıflandırma sonuçlarına göre **Çoklu-7** olduğu görülmüştür.

Random Forest algoritmasının çoklu sınıflandırma sürecinde elde ettiği sınıf bazlı performans sonuçları incelendiğinde, modelin metal içeren nesneleri yüksek doğruluk oranıyla sınıflandırdığı, ancak düşük metal içeriğine sahip tehdit unsurlarını ayırt etmede daha fazla hata yaptığı gözlemlenmiştir. Özellikle sınıf bazlı precision ve recall değerleri değerlendirildiğinde, metal içermeyen veya az metal içeren taklit mayınların tespitinde modelin performansında düşüş olduğu görülmektedir. Ancak genel başarımlar açısından bakıldığında, Random Forest algoritması tehdit içermeyen nesneleri yüksek recall değeriyle doğru şekilde sınıflandırabilmiş, ancak zaman zaman yanlış pozitifler üreterek tehdit içermeyen nesneleri tehdit olarak yanlış tahmin etme eğiliminde olmuştur.

Bu bulgular, K-NN ve SVM algoritmaları için elde edilen sonuçlarla da örtüşmektedir. Daha önce yapılan değerlendirmelerde olduğu gibi, Random Forest algoritmasının metal içeriği yüksek nesneleri daha iyi tanımlayabildiği, ancak düşük metal içeriğine sahip nesnelerde hata oranının arttığı görülmüştür.

6.4 Sınıflandırma Algoritmaların Performans Karşılaştırması

Yapılan deneylerde, kullanılan her üç algoritma da genel olarak başarılı sonuçlar elde etmiştir. Ancak Random Forest, tüm yöntemlerde istikrarlı ve yüksek doğruluk oranıyla öne çıkmıştır. K-NN algoritması, Random Forest algoritması gibi her yöntem için çok istikrarlı bir sonuç üretemese de hem ikili sınıflandırma için hem de çoklu sınıflandırma için yüksek doğruluk oranı elde etmiştir. SVM ise hem ikili sınıflandırma hem de çoklu sınıflandırma işlemlerinde diğer algoritmalara göre daha düşük başarı oranları göstermiştir; ancak özellikle belirli öznetelik çıkarma metotları ile kombine edildiğinde tatmin edici sonuçlar elde edebilmiştir.

6.5 Sonuçların Değerlendirilmesi

Tez çalışması boyunca elde edilen bulgular, GPR verilerinin işlenmesinde kullanılan öznetelik çıkarma yöntemlerinin ve sınıflandırma algoritmalarının performans üzerindeki etkilerini açık bir şekilde ortaya koymuştur. Özellikle ikili sınıflandırma ve çoklu sınıflandırma işlemlerinde, uygulanan ön işleme tekniklerinin ve öznetelik çıkarma yöntemlerinin doğru seçimi, sınıflandırma algoritmalarının başarı oranını doğrudan etkilemiştir. Bu doğrultuda, verilerin anlamlandırılması ve sınıflandırılması sürecinde kullanılan her bir adımın titizlikle seçilmesi, sonuçların doğruluğu ve güvenilirliği açısından kritik bir rol oynamıştır. Sonuç olarak, bu çalışma, GPR verilerinin doğru işlenmesinin, gömülü nesnelerin ikili ve çoklu sınıflandırmasında yüksek başarı sağlayabileceğini göstermiş ve bu alanda yapılacak yeni araştırmalara ışık tutmuştur.

- [1] H. Liang, L. Xing ve J. Lin, «Application and algorithm of ground-penetrating radar for plant root detection: A review,» *Sensors* 20(10), p. 2836, 2020.
- [2] A. B. Yoldemir ve M. Sezgin, «A Least Squares Approach to Buried Object Detection Using Ground Penetrating Radar,» *IEEE Sensors Journal*, pp. 11(6), 1337-1341, 2010.
- [3] D. Šipoš ve D. Gleich, «A Lightweight and Low-Power UAV-Borne Ground Penetrating Radar Design for Landmine Detection,» *sensors*, pp. 20(8), 2234, 2020.
- [4] ReliefWeb, «Clearing mines: 2022,» 2022. [Çevrimiçi]. Available: <https://reliefweb.int/report/world/clearing-mines-2022>.
- [5] A. P. Annan, «GPR—History, trends, and future developments,» *Subsurface Sensing Technologies and Applications* 3(4), pp. 253-270, 2002.
- [6] H. M. Jol, Ground penetrating radar: theory and applications, Amsterdam, Netherlands: Elsevier, 2009.
- [7] E. Pettinelli, B. Cosciotti, S. E. Lauro ve E. Mattei, «An overview of GPR subsurface exploration of planets and moons,» *The Leading Edge*, 41(10), p. 672–680, 2022.
- [8] A. Neal, «Ground-penetrating radar and its use in sedimentology: Principles, problems and progress,» *Earth-Science Reviews* 66(3-4), pp. 261-330, 2004.
- [9] H. Liang, L. Xing ve J. Lin, «Application and Algorithm of Ground-Penetrating Radar for Plant Root Detection: A Review,» *Sensors* , p. 2836, 2020.
- [10] A. P. Annan, Ground Penetrating Radar: Principles, Procedures & Applications, Mississauga, Ontario, Canada: Sensors & Software Inc., 2003.
- [11] S. A. Kovalenko, «Descartes-Snell law of refraction with absorption,» %1 içinde *Semiconductor Physics, Quantum Electronics & Optoelectronics*, 2001.
- [12] M. M. D. C. L. Moreira, «Object detection in GPR data using classical vision and YOLOv5,» 2022.

- [13] U. EOS, «Ground penetrating radar: Concepts and examples,» 2006. [Çevrimiçi]. Available: <https://www.eoas.ubc.ca/courses/eosc350/content/methods/gpr-06.htm>.
- [14] D. J. Daniels, «Surface-penetrating radar,» *Electronics & Communication Engineering Journal*, 8(4), pp. 165-182, 1996.
- [15] M. I. Skolnik, Radar Handbook, New York: McGraw-Hill, 1970.
- [16] T. Constructor, «How does ground penetrating radar (GPR) work?,» 2022. [Çevrimiçi]. Available: <https://theconstructor.org/practical-guide/ndt/how-ground-penetrating-radar-gpr-work/43370/>.
- [17] Wikipedia, «Wikipedia,» [Çevrimiçi]. Available: https://en.wikipedia.org/wiki/Ground-penetrating_radar.
- [18] D. J. (. Daniels, Ground penetrating radar (Vol. 1), IET, 2004.
- [19] H. M. (. Jol, Ground penetrating radar: Theory and applications, Elsevier, 2008.
- [20] CLU-IN, «Ground Penetrating Radar,» CLU-IN, [Çevrimiçi]. Available: https://clu.in.org/characterization/technologies/default2.focus/sec/Geophysical_Methods/cat/Ground_Penetrating_Radar/.
- [21] R. Nayak ve S. Maiti, «A review of Bow-Tie antennas for GPR applications,» *IETE Technical Review*, 2018.
- [22] T. Tuovinen, E. T. Salonen ve M. Berg, «An artificially anisotropic antenna substrate for the generation of circular polarization,» *IEEE Transactions on Antennas and Propagation* 64(11), pp. 4937-4942, 2016.
- [23] L. Pajewski, F. Tosti ve W. Kusayanagi, «Civil Engineering Applications of Ground Penetrating Radar,» *Antennas for GPR systems*, pp. 41-67, 2015.
- [24] G. Geo, «What is an air reflection in GPR data?,» 2022. [Çevrimiçi]. Available: <https://www.guidelinegeo.com/help-articles/what-is-an-air-reflection-in-gpr-data/>.
- [25] R. Persico, Introduction to Ground Penetrating Radar: Inverse Scattering and Data Processing, Hoboken, NJ, USA: Wiley-IEEE Press, 2014.
- [26] G. Geo, «What antenna frequency should I use for my GPR investigation?,» 2022. [Çevrimiçi]. Available: <https://www.guidelinegeo.com/help-articles/what-antenna-frequency-should-i-use-for-my-gpr-investigation/>.
- [27] K. Z. Jadoon, S. Lambot, E. C. Slob ve H. Vereecken, «Analysis of horn antenna transfer functions and phase-center position for modeling off-ground GPR,» *IEEE Transactions on Geoscience and Remote Sensing* 49(5), pp. 1649-1662, 2011.

- [28] L. Bianchini Ciampoli, F. Tosti, N. Economou ve F. Benedetto, «Signal processing of GPR data for road surveys,» *Geosciences* 9(2), p. 96, 2019.
- [29] E. Sheils, A. O'Connor, D. Breysse, F. Schoefs ve S. Yotte, «Development of a two-stage inspection process for the assessment of deteriorating infrastructure,» *Reliability Engineering & System Safety* 95(3), pp. 182-194, 2010.
- [30] C. Warren, «Numerical modelling of high-frequency ground-penetrating radar antennas,» 2009.
- [31] J. A. Doolittle ve J. R. Butnor, «Soils, peatlands, and biomonitoring,» *Ground penetrating radar: Theory and applications*, p. 524, 2009.
- [32] M. Sezgin ve M. N. Alpdemir, «Classification of buried objects using deep learning on GPR data,» *2023 IEEE International Conference on Advanced Systems and Emergent Technologies (IC_ASET)*, pp. 01-05, 2023.
- [33] N. J. Cassidy ve H. M. Jol, «Ground penetrating radar data processing, modelling and analysis,» %1 içinde *Ground penetrating radar: Theory and applications*, 2009, pp. 141-176.
- [34] J. G. Proakis, «Digital signal processing: Principles, algorithms, and applications,» *Pearson Education India 4th ed.*, 2007.
- [35] L. J. Christiano ve T. J. Fitzgerald, «The band pass filter,» *International Economic Review* 44(2), pp. 435-465, 2003.
- [36] R. C. Gonzalez, «Digital image processing,» *Pearson Education India*, 2009.
- [37] H. Ishida ve K. Araki, «Design and analysis of UWB band pass filter with ring filter,» %1 içinde *IEEE MTT-S International Microwave Symposium Digest*, 3, 1307-1310, 2004.
- [38] A. V. Oppenheim, «Discrete-time signal processing,» *Pearson Education India*, 1999.
- [39] E. Pasolli, F. Melgani ve M. Donelli, «Automatic analysis of GPR images: A pattern-recognition approach,» *IEEE Transactions on Geoscience and Remote Sensing* 47(7), pp. 2206-2217, 2009.
- [40] L. Mertens, R. Persico, L. Matera ve S. Lambot, «Automated detection of reflection hyperbolas in complex GPR images with no a priori knowledge on the medium,» *IEEE Transactions on Geoscience and Remote Sensing* 54(1), pp. 580-596, 2015.
- [41] R. Szeliski, *Computer vision: Algorithms and applications*, Springer Nature, 2022.

- [42] Y. Liu, C. Fang, X. Ji, B. Zhao ve D. Chen, «Gabor filter banks used for crevasse detection with ground-penetrating radar data,» *18th International Conference on Ground Penetrating Radar*, pp. 372-375, November 2020.
- [43] W. Burger ve M. J. Burge, *Digital image processing: An algorithmic introduction*, Springer Nature, 2022.
- [44] N. D. Hoang, «Image processing-based spall object detection using Gabor filter, texture analysis, and adaptive moment estimation (Adam) optimized logistic regression models,» *Advances in Civil Engineering 2020(1)*, p. 8829715, 2020.
- [45] F. Li, F. Yang, R. Yan, X. Qiao, H. Xing ve Y. Li, «Study on significance enhancement algorithm of abnormal features of urban road ground penetrating radar images,» *Remote Sensing 14(7)*, p. 1546, 2022.
- [46] A. Tzanis, «Detection and extraction of orientation-and-scale-dependent information from two-dimensional GPR data with tuneable directional wavelet filters,» *Journal of Applied Geophysics*, pp. 48-67, 2013.
- [47] L. Prasad ve S. S. Iyengar, *Wavelet analysis with applications to image processing*, CRC Press, 2020.
- [48] C. M. Akujuobi, «Wavelets and wavelet transform systems and their applications,» %1 içinde *Springer International Publishing*, Berlin/Heidelberg, Germany, 2022.
- [49] G. Othman ve D. Q. Zeebaree, «The applications of discrete wavelet transform in image processing: A review,» *Journal of Soft Computing and Data Mining 1(2)*, pp. 31-43, 2020.
- [50] M. Jansen, *Wavelets from a statistical perspective*, Chapman and Hall/CRC, 2022.
- [51] Y. Yang, Z. Su ve L. Sun, «Medical image enhancement algorithm based on wavelet transform,» *Electronics Letters 46(2)*, pp. 120-121, 2010.
- [52] J. Wang ve K. Huang, «Medical image compression by using three-dimensional wavelet transformation,» *IEEE Transactions on Medical Imaging 15(4)*, pp. 547-554, 1996.
- [53] M. A. Gungor ve K. Gencol, «Developing a compression procedure based on the wavelet denoising and JPEG2000 compression,» *Optik, 218*, p. 164933, 2020.
- [54] L. Zhang, T. Ling, B. Yu, F. Huang ve S. Zhang, «Intensive interferences processing for GPR signal based on the wavelet transform and FK filtering,» *Journal of Applied Geophysics, 186*, p. 104273, 2021.
- [55] G. Lu, W. Zhao, E. Forte, G. Tian, Y. Li ve M. Pipan, «Multi-frequency and multi-attribute GPR data fusion based on 2-D wavelet transform,» *Measurement, 166*, p. 108243, 2020.

- [56] J. Smith, «Fourier analysis in signal processing,» *Journal of Signal Processing*, pp. 45(3), 212-225, 2012.
- [57] K. Lee, «Frequency domain techniques in image processing,» *IEEE Transactions on Image Processing*, pp. 18(4), 312-319, 2010.
- [58] M. Allen, « Applications of Fourier transform in radar imaging,» *Radar Systems Journal*, pp. 30(2), 178-190, 2015.
- [59] D. James, «Spectral analysis with Fourier transform,» *Wiley Publishing*, 2014.
- [60] W. Hsieh, «Fourier techniques in GPR data processing,» *Geophysics Letters*, pp. 35(5), 289-298, 2017.
- [61] H. Park, «Signal enhancement in GPR using frequency filtering,» *Journal of Applied Geophysics*, pp. 69(3), 145-154, 2018.
- [62] L. Xu, «GPR data denoising using Fourier transform,» *Earth Science and Signal Processing*, pp. 21(4), 223-231, 2016.
- [63] P. Brown, « Improving subsurface imaging with Fourier transform,» *GPR Research Review*, pp. 48(2), 200-210, 2019.
- [64] Y. Zhao, «Frequency domain analysis of ground penetrating radar signals,» *IEEE Radar Conference*, pp. pp. 412-418, IEEE.
- [65] M. Sezgin, «A novel detection warning signal creation method for hand-held GPR applications,» *Proceedings of the XIII International Conference on Ground Penetrating Radar*, pp. 1-6, 2010.
- [66] M. Sezgin, «Two dimensional template matching method for buried object discrimination in GPR data,» *Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XIV*, 7303, SPIE, pp. 701-709.
- [67] M. Sezgin, «Simultaneous buried object detection and imaging technique utilizing fuzzy weighted background calculation and target energy moments on ground penetrating radar data,» *EURASIP Journal on Advances in Signal Processing*, 2011(1), pp. 1-12, 2011.
- [68] M. N. H. Ö. E. & Ç. E. Sezgin, «A false alarm reduction method for GPR sensor fixed at varying heights,» *Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXV*, 11418, SPIE, pp. 43-54.
- [69] S. E. E. & L. L. Tjora, «Evaluation of methods for ground bounce removal in GPR utility mapping,» *Proceedings of the Tenth International Conference on Ground Penetrating Radar, 2004. GPR 2004*, pp. (Vol. 1, pp. 379-382), june 2004.
- [70] F. J. A. & O. A. S. Abujarad, «Clutter removal for landmine using different signal processing techniques,» *Proceedings of the Tenth International Conference on Ground Penetrating Radar, 2004. GPR 2004*, pp. 697-700.

- [71] Q. L. T. & W. R. Gao, «A novel KICA method for ground bounce removal with GPR,» *2006 CIE International Conference on Radar, IEEE*, pp. 1-4, 2006.
- [72] P. K. B. S. D. & G. S. P. Sharma, «Critical analysis of background subtraction techniques on real GPR data,» *Defence Science Journal*, 67(5), 2017.
- [73] M. & H. H. Rashed, «Background matrix subtraction (BMS): A novel background removal algorithm for GPR data,» *Journal of Applied Geophysics*, pp. 106, 154-163, 2014.
- [74] L. L.-j. K. & Z.-o. Z. Ting-jun, «Symmetry filtering method for GPR clutter reduction,» *2008 International Conference on Microwave and Millimeter Wave Technology*, pp. (Vol. 3, pp. 1515-1517). IEEE, 2008.
- [75] U. S. & A.-N. W. Khan, «Background removal from GPR data using eigenvalues,» *Proceedings of the XIII International Conference on Ground Penetrating Radar*, pp. pp. 1-5, IEEE, Haziran 2010.
- [76] H. Brunzell, «Clutter reduction and object detection in surface penetrating radar,» 1997.
- [77] H. & M. W. Zhihua, «The application of KL transform to remove direct wave in ground penetrating radar records,» *Fourth International Conference on Image and Graphics (ICIG 2007)*, pp. 133-138, 2007.
- [78] R. C. A. D. A. C. I. & S. F. Solimene, «Ground clutter removal in GPR surveys,» *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(3), pp. 792-798, 2013.
- [79] Y. & F. G. Y. Luo, «GPR clutter reduction and buried target detection by improved Kalman filter technique,» *2005 International Conference on Machine Learning and Cybernetics*, pp. Vol. 9, pp. 5432-5436, IEEE, 2005.
- [80] M. Sezgin ve B. Sankur, «Survey over image thresholding techniques and quantitative performance evaluation,» *Journal of Electronic Imaging*, 13(1), pp. 146-168, 2004.
- [81] J. Zhang ve Z. Chen, «A review of adaptive thresholding techniques for image segmentation in GPR,» *Journal of Applied Geophysics*, 154, pp. 174-183.
- [82] X. Chen ve W. Wang, «Multi-level thresholding using genetic algorithms for image segmentation,» *Computers & Electrical Engineering*, 63, pp. 277-284, 2017.
- [83] Y. Liu ve T. Xu, «Deep learning-based automatic thresholding for image segmentation: A survey,» *International Journal of Computer Vision*, 129, pp. 2-19, 2021.

- [84] J. Serra ve P. (. Soille, «Mathematical morphology and its applications to image processing,» *Springer Science & Business Media*, (vol. 2), 2012.
- [85] P. Maragos, «Differential morphology and image processing,» *IEEE Transactions on Image Processing*, 5(6), pp. 922-937, 1996.
- [86] N. Tatsumi ve R. V. Pierre, «Automated image processing: Past, present, and future of blood cell morphology identification,» *Clinics in Laboratory Medicine*, 22(1), pp. 299-315, 2002.
- [87] S. Särkkä ve L. Svensson, «Bayesian filtering and smoothing,» *Cambridge University Press*, 17, 2023.
- [88] J. Zhang, C. Li, M. M. Rahaman, Y. Yao, P. Ma, J. Zhang ve M. Grzegorzec, «A comprehensive review of image analysis methods for microorganism counting: From classical image processing to deep learning approaches,» *Artificial Intelligence Review*, pp. 1-70, 2022.
- [89] G. Gupta, «Algorithm for image processing using improved median filter and comparison of mean, median and improved median filter,» *International Journal of Soft Computing and Engineering (IJSCE)* 1(5), pp. 304-311, 2011.
- [90] E. Gose, R. Johnsonbaugh ve S. Jost, *Pattern recognition and image analysis*, Prentice-Hall, Inc., 1996.
- [91] M. Nishimoto, S. Ueno ve Y. Kimura, «Feature extraction from GPR data for identification of landmine-like objects under rough ground surface.,» *Journal of Electromagnetic Waves and Applications*, vol. 20, no. 12, p. pp. 1577–1586, 2006.
- [92] M. Sezgin, F. Kurugollu, I. Tasdelen ve S. & Ozturk, «Real-time detection of buried objects by using GPR.,» *In Detection and Remediation Technologies for Mines and Minelike Targets IX, SPIE*, vol. 5415, p. pp. 447–455, Sept. 2004.
- [93] J. Zhang, Q. Liu ve B. Nath, «Landmine feature extraction and classification of GPR data based on SVM method.,» *International Symposium on Neural Networks, Springer*, pp. 636-641, aug 2004.
- [94] A. Kumar ve G. Zhang, «Texture analysis using Gabor filters for improved detection in GPR data.,» *Journal of Applied Geophysics*, vol. 74, p. pp. 177–184, 2011.
- [95] C. S. Chen ve Y. Jeng, «Improving GPR imaging of the buried water utility infrastructure by integrating the multidimensional nonlinear data decomposition technique into the edge detection,» *Water*, 13(21), p. 3148, 2021.
- [96] T. C. J. Mizutani ve S. Yotsumoto, «The 3D localization of subsurface pipes from Ground Penetrating Radar images using edge detection and point cloud segmentation,» *Measurement*, 115102., 2024.

- [97] R. Sun, T. Lei, Q. Chen, Z. Wang, X. Du, W. Zhao ve A. K. Nandi, «Survey of image edge detection,» *Frontiers in Signal Processing*, 2, , p. 826967, 2022.
- [98] W. Lei, F. Hou, J. Xi, Q. Tan, M. Xu, X. Jiang ve Q. Gu, «Automatic parabola detection and fitting in GPR B-scan image,» *Automation in Construction*, pp. 106, 102839, 2019.
- [99] Q. Dou, L. Wei, D. R. Magee ve A. G. Cohn, «Real-time parabola recognition and fitting in GPR data,» *IEEE Transactions on Geoscience and Remote Sensing*, pp. 55(1), 51-62, 2016.
- [100] J. Flusser, T. Suk ve B. Zitová, «2D and 3D Image Analysis by Moments,» *John Wiley & Sons*, 2016.
- [101] J. M. Huie, A. P. Summers ve S. M. Kawano, «SegmentGeometry: A tool for measuring second moment of area in 3D slicer,» *Integrative Organismal Biology*, 4(1), p. obac009, 2022.
- [102] Z. H. Zhou, «Machine learning,» *Springer Nature*, 2021.
- [103] E. Alpaydin, Introduction to machine learning, MIT Press, 2020.
- [104] C. M. & N. N. M. Bishop, «Pattern recognition and machine learning,» *Springer*, pp. Vol. 4, No. 4, p. 738, 2006.
- [105] I. Goodfellow, «Deep learning,» *MIT Press*, 2016.
- [106] A. Géron, «Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow,» *Concepts, Tools, and Techniques to Build Intelligent Systems. 2nd Edition*, 2019.
- [107] C. D. Manning, P. Raghavan ve H. Schütze, «Introduction to Information Retrieval,» *Cambridge University Press*, 2008.
- [108] F. Pedregosa, « Scikit-learn: Machine learning in python Fabian.,» *Journal of machine learning research*, 12, 2825, 2011.
- [109] P. C. M. & D. S. J. Cunningham, «Supervised learning,» %1 içinde *Machine learning techniques for multimedia: Case studies on organization and retrieval* , Springer Berlin Heidelberg, 2008, pp. 21-49.
- [110] R. & N.-M. A. Caruana, «An empirical comparison of supervised learning algorithms,» *Proceedings of the 23rd international conference on Machine learning*, pp. 161-168, 2006.
- [111] V. Nasteski, « An overview of the supervised machine learning methods,» *Horizons*, 4 , pp. 51-62, 2017.
- [112] H. B. Barlow, «Unsupervised learning,» *Neural Computation*, 1, pp. 295-311, 1989.

- [113] M. E. & A. K. (. Celebi, «Unsupervised learning algorithms,» *Cham: Springer*, 9, p. 103, 2016.
- [114] K. P. & Y. M. S. Sinaga, «Unsupervised K-means clustering algorithm,» *IEEE Access*, 8, pp. 80716-80727, 2020.
- [115] S. & D. S. K. Ghosh, «Comparative analysis of k-means and fuzzy c-means algorithms,» *International Journal of Advanced Computer Science and Applications*, 4(4), 2013.
- [116] V. K. D. & T. P. Kumar, «Unsupervised learning dimensionality reduction algorithm PCA for face recognition,» *2017 International Conference on Computing, Communication and Automation (ICCCA)*, pp. 32-37, IEEE, 2017.
- [117] M. A. & V. O. M. Wiering, «Reinforcement learning,» *Adaptation, Learning, and Optimization*, pp. 12(3), 729, 2012.
- [118] C. Szepesvári, «Algorithms for reinforcement learning,» *Springer Nature*, 2022.
- [119] V. H. P. I. R. B. M. G. & P. J. François-Lavet, «An introduction to deep reinforcement learning,» *Foundations and Trends® in Machine Learning*, pp. 11(3-4), 219-354, 2018.
- [120] J. F. & S. R. S. Hernandez-Garcia, «Understanding multi-step deep reinforcement learning: A systematic study of the DQN target,» *arXiv preprint arXiv:1901.07510*, 2019.
- [121] R. S. M. D. S. S. & M. Y. Sutton, «Policy gradient methods for reinforcement learning with function approximation,» *Advances in neural information processing systems*, p. 12, 1999.
- [122] R. J. Hyndman, «Forecasting: principles and practice,» *OTexts*, 2018.
- [123] D. M. Powers, «Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation,» *arXiv preprint*, 2020.
- [124] S. Raschka, «Model evaluation, model selection, and algorithm selection in machine learning,» *arXiv preprint arXiv:1811.12808*, 2018.
- [125] J. Liang, «Confusion matrix: Machine learning,» *POGIL Activity Clearinghouse*, 3(4), 2022.
- [126] T. Dietterich, «Overfitting and undercomputing in machine learning,» *ACM Computing Surveys (CSUR)*, pp. 27(3), 326-327, 1995.
- [127] X. Ying, «An overview of overfitting and its solutions,» *Journal of Physics: Conference Series*, pp. 1168, 022022, IOP Publishing, 2019.

- [128] B. Charbuty ve A. Abdulazeez, «Classification based on decision tree algorithm for machine learning,» *Journal of Applied Science and Technology Trends*, pp. 2(1), 20-28, 2021.
- [129] R. A. Disha ve S. Waheed, «Performance analysis of machine learning models for intrusion detection system using Gini Impurity-based Weighted Random Forest (GIWRF) feature selection technique,» *Cybersecurity*, pp. 5(1), 1, 2022.
- [130] S. J. Rigatti, «Random forest,» *Journal of Insurance Medicine*, pp. 47(1), 31-39, 2017.
- [131] A. Parmar, R. Katariya ve V. Patel, «A review on random forest: An ensemble classifier,» %1 içinde *International conference on intelligent data communication technologies and internet of things (ICICI) 2018*, Springer International Publishing, 2019, pp. 758-763.
- [132] N. Altman ve M. Krzywinski, «Ensemble methods: bagging and random forests,» *Nature Methods*, pp. 14(10), 933-935, 2017.
- [133] Y. Liu, Y. Wang ve J. Zhang, «New machine learning algorithm: Random forest,» %1 içinde *Information Computing and Applications: Third International Conference, ICICA 2012, Chengde, China, September 14-16, 2012. Proceedings 3*, Springer Berlin Heidelberg, 2012, pp. 246-252.
- [134] T. M. Oshiro, P. S. Perez ve J. A. Baranauskas, «How many trees in a random forest?,» %1 içinde *Machine Learning and Data Mining in Pattern Recognition: 8th International Conference, MLDM 2012, Berlin, Germany, July 13-20, 2012. Proceedings 8*, Springer Berlin Heidelberg, 2012, pp. 154-168.
- [135] P. K. Syriopoulos, N. G. Kalampalikis, S. B. Kotsiantis ve M. N. Vrahatis, «k-NN classification: A review,» *Annals of Mathematics and Artificial Intelligence*, pp. 1-33, 2023.
- [136] P. Cunningham ve S. J. Delany, «K-nearest neighbour classifiers: A tutorial,» *ACM Computing Surveys (CSUR)*, pp. 54(6), 1-25, 2021.
- [137] S. Zhang, X. Li, M. Zong, X. Zhu ve D. Cheng, «Learning k for k-NN classification,» *ACM Transactions on Intelligent Systems and Technology (TIST)*, pp. 8(3), 1-19, 2017.
- [138] S. Suthaharan ve S. Suthaharan, «Support vector machine,» *Machine learning models and algorithms for big data classification: Thinking with examples for effective learning*, pp. 207-235, Springer, 2016.
- [139] V. Kecman, «Support vector machines—an introduction,» %1 içinde *Support vector machines: Theory and applications*, Springer Berlin Heidelberg, 2005, pp. 1-47.
- [140] J. M. Moguerza ve A. Muñoz, «Support vector machines with applications,» 2006.

- [141] B. Yegnanarayana, Artificial neural networks, PHI Learning Pvt. Ltd, 2009.
- [142] A. Krenker, J. Bešter ve A. Kos, «Introduction to the artificial neural networks,» %1 içinde *Artificial Neural Networks: Methodological Advances and Biomedical Applications*, 2011, pp. 1-18.
- [143] S. Walczak, «Artificial neural networks,» %1 içinde *Advanced methodologies and technologies in artificial intelligence, computer simulation, and human-computer interaction*, IGI Global, pp. 40-53.
- [144] J. Zou, Y. Han ve S. S. So, «Overview of artificial neural networks,» %1 içinde *Artificial neural networks: methods and applications*, 2009, pp. 14-22.
- [145] Y. LeCun, Y. Bengio ve G. Hinton, «Deep learning,» *Nature*, 521(7553), pp. 436-444, 2015 .
- [146] Y. Bengio, I. Goodfellow ve A. Courville, Deep learning, Cambridge, MA, USA: MIT Press, 2017.
- [147] J. D. Kelleher, Deep learning, MIT Press, 2019.
- [148] Z. Li, F. Liu, W. Yang, S. Peng ve J. Zhou, «A survey of convolutional neural networks: analysis, applications, and prospects,» *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), pp. 6999-7019, 2021.
- [149] L. R. Medsker ve L. Jain, «Recurrent neural networks,» %1 içinde *Design and Applications*, 5(64-67), 2001, p. 2.
- [150] A. Gillioz, J. Casas, E. Mugellini ve O. Abou Khaled, «Overview of the Transformer-based Models for NLP Tasks,» %1 içinde *2020 15th Conference on Computer Science and Information Systems (FedCSIS)*, IEEE, 2020, pp. 179-183.
- [151] L. Deng ve D. Yu, «Deep learning: methods and applications,» *Foundations and Trends® in Signal Processing*, 7(3-4), pp. 197-387, 2014.
- [152] M. N. Alpdemir ve M. Sezgin, «Analysis of Deep CNN-based Ground Penetrating Radar (GPR) Image Classification Process using Explainable AI,» *2023 Innovations in Intelligent Systems and Applications Conference (ASYU)*, pp. 1-7, IEEE, 2023.
- [153] J. Leckebusch, «Ground-penetrating radar: A modern three-dimensional prospection method,» *Archaeological Prospection*, pp. 10(4), 213-240, 2003.
- [154] H. Öztürk, H. Nazli, K. Yeğin, E. Bıçak, M. Sezgin, M. Dağ ve B. Turetken, «Millimeter-wave detection of landmines,» *Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XVIII*, pp. Vol. 8709, pp. 263-268, SPIE, Haziran 2013.

- [155] J. G. Sánchez, J. M. Costa-García, J. Fonte ve D. González-Álvarez, «Exploring ephemeral features with ground-penetrating radar: An approach to Roman military camps,» *Remote Sensing*, pp. 14(19), 4884, 2022.
- [156] J. Kositsky, R. Cosgrove, C. A. Amazeen ve P. Milanfar, «Results from a forward-looking GPR mine detection system,» *Detection and Remediation Technologies for Mines and Minelike Targets VII*, pp. 206-217, SPIE, 2002.
- [157] C. S. Lent, « Learning to program with MATLAB: Building GUI tools,» *John Wiley & Sons*, 2022.
- [158] E. Hossain, «App Designer and Graphical User Interface in MATLAB,» %1 içinde *MATLAB and Simulink Crash Course for Engineers*, Springer International Publishing, 2022, pp. 299-316.
- [159] MathWorks, «App Designer,» MATLAB, [Çevrimiçi]. Available: <https://www.mathworks.com/products/matlab/app-designer.html>.
- [160] S. Tania ve R. Rowaida, «A comparative study of various image filtering techniques for removing various noisy pixels in aerial image,» *International Journal of Signal Processing, Image Processing and Pattern Recognition* 9(3), pp. 113-124, 2016.

Konferans Bildirileri

1. Koçak, B., Sezgin, M., & Yeşildirek, A. (2024, June). *A study on evaluation of background subtraction and pattern recognition methods for classification of GPR B-scan data*. In *Proceedings of the International British Congress on Interdisciplinary Scientific Research & Practices* (pp. 441-448). London, UK.
2. Koçak, B., Sezgin, M., & Yeşildirek, A. (2024, November). *Evaluation of background subtraction and pattern recognition methods for classification of GPR B-scan data*. In *2024 15th National Conference on Electrical and Electronics Engineering (ELECO)* (pp. 1-5). IEEE.