



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**DERİN ÖĞRENME YÖNTEMLERİ İLE GPR B
TARAMA GÖRÜNTÜLERİNİN ANALİZİ**

Umut ÖZKAYA

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Temmuz 2020
KONYA
Her Hakkı Saklıdır

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Umut ÖZKAYA

Tarih: 17.08.2020

ÖZET

DOKTORA TEZİ

DERİN ÖĞRENME YÖNTEMLERİ İLE GPR B TARAMA GÖRÜNTÜLERİNİN ANALİZİ

Umut ÖZKAYA

Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Levent SEYFİ

2020, 125 Sayfa

Jüri

Prof. Dr. Ercan YALDIZ

Doç. Dr. Levent SEYFİ

Doç. Dr. Çetin KURNAZ

Dr. Öğr. Üye. Ömer Kaan BAYKAN

Dr. Öğr. Üye. Hüseyin Oktay ALTUN

Bu tez çalışmasında, GPR B tarama görüntülerinin derin öğrenme yöntemleri kullanılarak gömülü yapıları verimli bir şekilde analiz eden mimariler sunulmaktadır. Bu kapsamda GPR B tarama görüntüleri elde etmek amacıyla GprMax programından faydalanılmıştır. Simülasyon programı kullanılarak farklı özelliklere sahip dört veri seti oluşturulmuştur. Birinci veri setinde toplamda 180 adet GPR B tarama görüntüsü bulunmaktadır. Bu veri setindeki görüntülerde farklı şekil ve malzemeye sahip gömülü yapılar bulunmaktadır. Görüntülerde malzeme kalınlığından ve gömülü yapıların birbirine yakınlığından kaynaklanan yanlış alarm durumunun oluşmasına neden olan örüntüler mevcuttur. İkinci veri setinde ise veri artırım yöntemleri kullanılarak toplamda 4280 adet GPR B tarama görüntüleri elde edilmiştir. Bu görüntülerin oluşturulmasında farklı elektriksel özelliklere sahip bazı toprak ve malzemeler kullanılmıştır. Aynı zamanda farklı şekilsel özelliklerden de faydalanılmıştır. Üçüncü veri setinde ise toplamda 8505 adet GPR cihazından alınan gerçek GPR B tarama görüntüleri kullanılarak analizler gerçekleştirilmiştir. Bu analiz kapsamında GPR B tarama görüntülerinden tarama işleminin hangi tür GPR cihazı ile gerçekleştirildiği, tarama frekansları ve tarama yapılan sahanın toprak çeşidi tespit edilmeye çalışılmıştır. Dördüncü veri setinde 39 adet gerçek GPR B tarama görüntüleri bulunmaktadır. Bu görüntüler içerisinde oyuklar bulunan farklı beton bloklarından elde edilmiştir. Veri setlerinin analizinde veri seti yapısı göz önüne alınarak farklı analiz yöntemleri kullanılmıştır. Birinci veri setindeki veri sayısının azlığı nedeniyle ve analizini daha etkin bir şekilde gerçekleştirmek amacıyla derin sözlük öğrenme yapısı kullanılmıştır. Aynı zamanda karşılaştırmalı bir analiz gerçekleştirmek amacıyla farklı katman sayısı ve sınıflandırıcılarla eğitim ve test işlemi yapılmıştır. İkinci veri seti üzerine veri artırımı yapılarak Konvolüsyonel Sinir Ağlarının (KSA) eğitimi gerçekleştirilmiştir. KSA yapıları olarak AlexNet, VGG-16, GoogloNet, ResNet-50 ve SqueezeNet kullanılmıştır. Eğitim aşamasında bu modellerin rastgele, ön eğitilmiş ve transfer öğrenmesi kullanılmış yapıları üzerinde eğitimler gerçekleştirilmiştir. Aynı zamanda eğitim veri sayısının model üzerindeki hassasiyeti test edilmiştir. Bununla birlikte Konvolüsyonel Desktek Vektör Makineleri yapıları eğitilmiştir. Bu yapılar küçük, orta ve geniş modeller olmak üzere üç farklı modelden oluşmaktadır. Eğitimi tamamlanmış ağ yapıları hem simülasyon verileri ile hem de gerçek veriler ile test edilmiştir. Üçüncü veri setinde ise transfer öğrenmesi kullanılarak farklı KSA modellerinin eğitimi gerçekleştirilmiştir. Aynı zamanda iki adet farklı KSA mimarisi tasarlanarak ön eğitilmiş KSA yapılarının performansı ile karşılaştırmalar yapılmıştır. Belirtilen veri seti için ön eğitilmiş ağlar olarak AlexNet, VGG-19, GoogloNet, ResNet-50, InceptionNet ve DenseNet modelleri kullanılmıştır. Dördüncü veri setinde ise GPR B tarama görüntülerindeki oyuk

bölgelerin tespit için YOLO, Hızlı Bölgesel tabanlı Konvolüsyonel Sinir Ağları (Hızlı B-KSA) ve Daha Hızlı Bölgesel tabanlı Konvolüsyonel Sinir Ağları (Daha Hızlı B-KSA) yöntemleri kullanılmıştır. Elde edilen sonuçlar değerlendirildiğinde derin öğrenme yöntemlerinin GPR B tarama görüntülerinin analizinde oldukça başarılı olduğu görülmüştür.

Anahtar Kelimeler: Yere Nüfuz Eden Radar, GPR B Tarama, Derin Öğrenme, Konvolüsyonel Sinir Ağları, Sınıflandırma.



ABSTRACT

PhD THESIS

ANALYSIS OF GPR B SCAN IMAGES WITH DEEP LEARNING METHODS

Umut ÖZKAYA

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
KONYA TECHNIC UNIVERSITY
THE DEGREE OF DOCTOR OF PHILOSOPHY
IN ELECTRICAL AND ELECTRONICS ENGINEERING**

Advisor: Asso. Prof. Dr. Levent SEYFİ

2020, 125 Pages

Jury

Prof. Dr. Ercan YALDIZ

Asso. Prof. Dr. Levent SEYFİ

Asso. Prof. Dr. Çetin KURNAZ

Asst. Prof. Dr. Ömer Kaan BAYKAN

Asst. Prof. Dr. Hüseyin Oktay ALTUN

In this thesis, GPR B scan images are presented with architectures that efficiently analyze buried structures using deep learning methods. GprMax program was used to obtain two-dimensional GPR B scan images. Two data sets with different characteristics were generated by using simulation programs. A total of 180 GPR B Scan images are available in the first data set. These images in this data set have buried structures with different shapes and materials. There are patterns in the images that cause a false alarm condition due to the thickness of the material and the proximity of buried structures to each other. In the second data set, there are 4280 GPR B scan images in total by using data augmentation methods. Soil and materials with different electrical properties were used in the generation of these images. At the same time, different types of shape were used. Thirdly, a total of 9000 GPR B-G images obtained from GPR devices were analyzed. Within the scope of this analysis, it has been tried to determine type of GPR device, scanning frequencies and soil type in the surveyed area. The fourth data set contains 39 real GPR B scan images. These images were obtained from different concrete blocks with cavities. In the analysis of the data sets, several methods were used by considering the data set structure. Deep dictionary learning structure was used in order to realize the less number of data and analysis in the first data set. At the same time, different number of layers and classifiers were used to perform a comparative analysis. Training on Convolutional Neural Network (CNN) was carried out by performing on the second data set. CNN structures were used as AlexNet, VGG-16, GoogLeNet, ResNet-50 and SqueezeNet. During the training phase, trainings were carried out by using scratch, pre-trained and transfer learning structures of these models. At the same time, the sensitivity of training data on the model has been tested. In addition, Convolutional Support Vector Machines structures were trained. These structures are composed of three different models as small, medium and large type. Trained network structures have been tested with both simulation data and real data. In the third data set, different CNN pre-trained models were trained by using transfer learning. In the context of the proposed method for the specified data set, AlexNet, VGG-19, GoogLeNet, ResNet-50 and InceptionNet models were used. At the same time, two different CNN architectures were designed and comparisons were made with the performance of pre-trained CNN structures. In the fourth data set, YOLO, Fast Regional-based Convolutional Neural Networks (Fast R-CNN) and Faster Regional-based Convolutional Neural Networks (Faster R-CNN) methods were used to detect cavities regions in the GPR B scan images. The obtained results were found to be very successful.

Keywords: Ground Penetrating Radar, GPR B Scan, Deep Learning, Convolutional Neural Network, Classification.



ÖNSÖZ

Öncelikle tez çalışmamın her aşamasında bana destek olan ve değerli bilgi birikimiyle bana yol gösteren saygıdeğer danışman hocam Doç. Dr. Levent Seyfi'ye sonsuz teşekkürlerimi sunarım. Onun yardımını ve desteğini olmasaydı tezimi tamamlamak mümkün olmazdı.

Doktora tezim boyunca benden değerli fikirlerini esirgemeyen ve tez çalışmama sağladıkları katkılar dolayısıyla tez izleme komitesindeki komite üyelerine, tez savunma jüri üyelerine ve Konvolüsyonel Destek Makineleri modellerinin tasarlanması ve üçüncü veri setinin elde edilmesinden dolayı Doç. Dr. Farid Melgani, Doç. Dr. Massimo Donelli ve dördüncü veri setinin temin edilmesinden dolayı Arş. Gör. Mehmet UZBAŞ'a teşekkürü bir borç bilirim.

Son ve en değerlisi olarak, bugünlere gelmemde en büyük pay sahibi olan ve beni her konuda destekleyen değerli aileme teşekkür ederim.

Umut ÖZKAYA
KONYA-2020

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
ÖNSÖZ	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM	12
3.1. Yere Nüfuz Eden Radar (GPR) ve Elektromanyetik Teori	12
3.1.1. Yalıtkan malzemelerde elektromanyetik özellikler	13
3.1.2. Frekans ve çözünürlük arasındaki ilişki.....	17
3.2. Yere Nüfuz Eden Radar	17
3.2.1. Darbeli yere nüfuz eden radar	22
3.2.2. Frekans adımlı yere nüfuz eden radar	23
3.2.3. İleri bakan yere nüfuz eden radar	26
3.3. GprMax	27
3.3.1. Gömülü nesnelerin simülasyonu için gereken parametreler	28
3.3.2. GprMax yazılımı için simülasyon örneği	32
3.3.3. Tez çalışması kapsamında yaralanılan simülasyon ve gerçek veri setleri	35
3.4. Yapay Sinir Ağları	42
3.4.1. Yapay sinir	42
3.4.2. Çok katmanlı yapay sinir ağları	43
3.4.3. Geri yayılım algoritması	46
3.5. Konvolüsyonel Sinir Ağları	54
3.5.1. Konvolüsyon katmanı	55
3.5.2. Havuzlama katmanı	58
3.5.3. Tam bağlı katman	59
3.5.4. SoftMax	59
3.5.5. Destek vektör makinesi.....	60
3.5.6. Uzun kısa süreli bellek.....	61
3.5.7. K-En yakın komşu algoritması	62
3.6. Ön Eğitimli KSA yapıları ve Transfer Öğrenmesi	63
3.6.1. Ön eğitimli ksa yapıları.....	64
3.6.2. Transfer öğrenmesi	68
3.6.3. Kütüphaneler.....	70
3.7. Konvolüsyonel Destek Vektör Makineleri	74
3.7.1. Konvolüsyonel DVM katmanı	75
3.7.2. Havuzlama katmanı ve sınıflandırma	76
3.8. Derin Sözlük Öğrenme	77

3.8.1. Seyrek gösterim	77
3.8.2. Sözlük öğrenme	78
3.8.3. K-TDA algoritması	79
3.8.4. Kısıtlı boltzman makinesi	82
3.8.5. Yığın otomatik kodlayıcı	85
3.8.6. Derin sözlük öğrenme algoritması	87
3.9. Nesne tanıma tabanlı konvolüsyonel sinir ağları	90
3.9.1. You only look once (YOLO)	90
3.9.2. Hızlı bölgesel tabanlı konvolüsyonel sinir ağları	91
3.9.3. Daha hızlı-bölgesel tabanlı konvolüsyonel sinir ağları	91
3.10. Nvidia Jetson TX2 Modülü	92
3.11. Önerilen Yöntemler	93
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	99
5. SONUÇLAR VE ÖNERİLER	111
5.1 Sonuçlar	111
5.2 Öneriler	112
KAYNAKLAR	114
EKLER	120
ÖZGEÇMİŞ	123

SİMGELER VE KISALTMALAR

Simgeler

$a_{ğj}$: Yapay Sinir Giriş Değeri
$a(t)$: Darbe Sinyali
β_1, β_2	: Öğrenme Değişkenleri
β	: Faz Sabiti
b	: Bias Değeri
c	: Işık Hızı
d	: Derinlik Mesafesi
D	: Sözlük
ϵ	: Elektrik Geçirgenlik
ϵ_r	: Bağlı Elektrik Geçirgenlik
ϵ_0	: Boşluğun Elektrik Geçirgenliği
E	: Karese Hata
f_0	: Başlangıç Frekansı
k	: Dalga Numarası
L_a	: Malzemeden Kaynaklı Zayıflama Kaybı
L_m	: Anten Uyumsuzluk Kaybı
L_s	: Anten Yayılma Kaybı
L_{sc}	: Hedeften Saçılma Kaybı
L_T	: Anten Verim Kaybı
L_{T1}	: Havadan Malzemeye İletim Kaybı
L_{T2}	: Malzemeden Havaya Yeniden Aktarım Kaybı
μ	: Manyetik Geçirgenlik
μ_r	: Bağlı Manyetik Geçirgenlik
μ_0	: Boşluğun Manyetik Geçirgenliği
o_i, o_j	: Değişken Çıktılar
ρ	: Hedefin Yansıma Özelliği
p	: Olasılıksal Kaçınma Oranı
$p(t)$: Transfer Fonksiyonu
R	: Menzil
R_{max}	: En Derin Mesafe
s	: Seyreklik Seviyesi
t	: EM Dalganın Gidiş Dönüş Süresi
τ	: Darbe Süresi
T_d	: Geri Dönüş Zamanı
w_i	: i. İndis ağırlığı
w_{ij}	: Mevcut Ağırlık
w_{ij}^+	: Güncellenen Yeni Ağırlık
v	: Dalga Hızı
x	: Seyrek Katsayı
x_i	: i. İndis girdisi
$x(k)$: k. Atomdaki Seyrek Katsayı Değeri
Δf	: Yükselme Birim Zamanı
Γ	: Yansıma Katsayısı
σ	: Elektriksel İletkenlik
λ	: Dalga Boyu
ω	: Açısal Frekans

α	: Öğrenme Oranı
γ	: Momentum Oranı
$\ \cdot\ _F$: Frobenius Normu
ϕ	: Aktivasyon Fonksiyonu
η	: Öz Empedans

Kısaltmalar

ABD	: Amerika Birleşik Devletleri
ACF	: Auto Correlation Function
ADC	: Analog Digital Converter
BP	: Back Projection
CD-1	: Single Step Contrastive Divergence
CFAR	: Constant False Alarm Rate
CNN	: Convolutional Neural Network
DC	: Direct Current
DVM	: Destek Vektör Makinesi
DVMs	: Destek Vektör Makinesi Filtre Ağırlığı
E	: Elektrik Alan
EM	: Elektromanyetik
FDTD	: Finite Difference Time Domain
GDVM	: Gaussian Destek Vektör Makinesi
GİB	: Grafiksel İşlem Birimi
GLCM	: Gray Level Co-Occurrence Matrix
GLRLM	: Gray Level Run Length Matrix
GMM	: Gizli Markov Modeli
GSSI	: Geophysical Survey System Inc.
GPR	: Ground Penetrating Radar
H	: Manyetik Alan Şiddeti
KBM	: Kısıtlı Boltzman Makinesi
KDVM	: Konvolüsyonel Destek Vektör Makinesi
KSA	: Konvolüsyonel Sinir Ağları
K-TDA	: K- Tekil Değer Ayırıştırması
K-EYK	: K En Yakın Komşuluk
LNA	: Low Noise Amplifier
MİB	: Merkezi İşlem Birimi
MTİ	: Mikrodalga Tomografik İncersiyon
REDB	: Rektifiye Edilmiş Doğrusal Birim
RF	: Radyo Frekans
RGB	: Red-Green-Blue
UKSB	: Uzun Kısa Süreli Bellek
YNR	: Yere Nüfuz Eden Radar
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Yere Nüfuz eden Radar (YNR) İngilizce adıyla Ground Penetrating Radar (GPR) jeofizik inceleme için kullanılan tahribatsız bir test cihazıdır. Bununla birlikte, yer altı görüntüleme GPR kullanımını önemli ölçüde ilerlemiştir. GPR, yer altının iki boyutlu ve üç boyutlu görüntülerini elde ederek yer altındaki mayın, inşaat demiri, boru, çatlak ve boşlukların tespiti sağlanabilmektedir.

Yeraltındaki yapıların özelliklerini elde etmek için GPR verilerinin analizi gerekmektedir. Tahribatsız uzaktan algılama yöntemleri yapı ve malzeme mühendisliği alanında popüler hale geldiğinden, araştırmacılar daha çok GPR verilerinin işlenmesi üzerine yoğunlaşmışlardır (Muvhiiwa ve ark.). Her yıl mevcut yapıların, özellikle otoyolların ve köprülerin onarımı için milyarlarca dolar harcanmaktadır. Amerika’da altyapı iyileştirme çalışmaları kapsamında mevcut köprülerin dokuzda birinde yapısal eksiklikler olduğu tespit edilmiştir. Bu kapsamda ABD’de köprülerin onarımı ve bakımı için her yıl 12.8 milyar dolar harcanmaktadır. Mevcut bir yapının onarım planını belirlemek için doğru durum değerlendirmesinin yapılması gerekmektedir. Onarım maliyeti büyük ölçüde azaltmak ve yapıda var olan hasar veya arıza tehdidini ortaya çıkarmak için uzaktan algılama yöntemlerinden biri olan GPR’ın kullanımı gerekli olabilir.

GPR, köprü ve yol bozulmalarını haritalamak için de kullanılan yaygın bir yöntemdir. Bununla birlikte GPR inşaat sektöründe ve mayın tarama faaliyetlerinde de sıklıkla kullanılır. Radar dalgaları tarama yapılan alanın nem durumuna oldukça duyarlıdır. Bu nedenle GPR gömülü yapılar içerisindeki yüksek nem içerikli alanın yerini bulmak için de kullanılabilir. Şimdiye kadar, GPR kullanımları ile farklı amaçlar için birçok sahada veriler üretmiştir. Günümüzde ise araştırmacılar elde edilen GPR verilerinin analizine odaklanmıştır. Bu kapsamda araştırmacılar çoğunlukla sinyal ve görüntü işleme tekniklerini kullanarak GPR veriler üzerinde analizler gerçekleştirmektedirler (Özdemir 2014).

Tez kapsamında GprMax programı kullanılarak birbirinden farklı özellikler taşıyan iki adet GPR B tarama görüntü veri seti üretilmiştir. Birinci veri setinde toplamda 180 adet görüntü bulunmaktadır. Veri setindeki GPR B tarama görüntülerinde tek ya da çoklu gömülü nesnelerin oluşturduğu örüntüler bulunmaktadır. Bu örüntüler malzemenin yapısal ve elektriksel özelliklerine bağlı olarak harici yansımalara sebebiyet verir. Bu tip istenmeyen örüntüler veri analizinde karşılaşılan zorluklardır.

İkinci veri setinde toplamda 4280 adet GPR B tarama görüntüsü üretilmiştir. Bu veri seti oluşturulurken farklı toprak sahasında ve derinliklerde beş adet malzeme ve üç adet farklı şekilde yapı kullanılmıştır. Bu görüntülerde farklı yapıların içerisinde bulunan farklı derinlikteki çeşitli malzemeler aynı örüntüye sahip olabilir. Bu durum veri setinin analizinin zorluğunu göstermektedir. Gerçek GPR B tarama görüntülerinde harici yansımalar ve gürültüler mevcuttur. Tez kapsamında kullanılan üçüncü veri seti tamamıyla gerçek GPR B tarama görüntülerinden oluşmaktadır. Veri setinin özellikleri incelendiğinde dört farklı toprak sahasında üç farklı markadaki GPR cihazıyla dokuz farklı frekansta tarama yapıldığı görülmektedir. Bu veri setinde toplamda 8505 adet GPR B tarama görüntüsü bulunmaktadır. Tez kapsamında kullanılan dördüncü veri setinde ise 39 adet gerçek GPR B tarama görüntüsü bulunmaktadır. Bu görüntüler farklı beton blok yapılarından elde edilmiş olup içerisinde çeşitli derinliklerde oyuklar bulunmaktadır. Tez kapsamında belirtilen problemlerin çözümü için farklı derin öğrenme modelleri kullanılmıştır.

Bu tez çalışmasında günümüzde birçok alanda kullanımı bulunan yere nüfuz eden radardan elde edilen GPR B tarama görüntüleri etkin bir şekilde kullanılarak mayın tarama sahası veya arkeolojik sahalarda gömülü cisimlerin özellikleri hakkında ön bilgi sağlanması amaçlanmaktadır. Aynı zamanda GPR B tarama görüntülerindeki özellikler derin öğrenme yöntemleriyle öğrenilip yanlış alarm durumlarının en az seviyeye indirilmesi amaçlanmaktadır. Böylece gömülü nesnenin ve tarama yapılan toprak çeşidinin tespitinde doğruluk oranının daha da artırılması planlanmaktadır. Yapılan literatür araştırmasında, kurulan sistemlerin yüksek doğruluk oranlarının olmadığı ve ön işleme algoritmalarına ihtiyaç duyduğu saptanmıştır. Ayrıca geçmişte yapılan çalışmalarda ön işleme algoritmalarının bulunması sistemi yavaşlattığından dolayı gerçek zamanlı bir tasarım yapılamamıştır. Bu tez kapsamında, bilgisayardan bağımsız bir gömülü sistem tasarlanmıştır. Diğer bir ifadeyle GPR B tarama görüntülerini işleyip anlık karar verebilen bir donanım oluşturulmuştur. Bu donanım ileride gerçek bir GPR sistemine entegre edilmeye hazır olacak şekilde tasarlanmıştır.

Gerçekleştirilen tez çalışması toplamda beş bölümden oluşmaktadır. Tezin birinci bölümü giriş kısmı olup ikinci bölümde kaynak araştırması adı altında GPR üzerine yapılan çalışmalar sunulmuştur. Üçüncü bölümde tez kapsamında kullanılan materyal ve yöntemden bahsedilmiştir. Dördüncü bölümde ise gerçekleştirilen çalışmalar ve elde edilen bulgular anlatılmıştır. Beşinci bölüm, son bölüm olup sonuçlar ve öneriler kısmından oluşmaktadır.

2. KAYNAK ARAŞTIRMASI

Al-Nuaimy ve ark. gömülü cisimlerin konumlarının belirlenmesi üzerine bir görüntü işleme yöntemi önermişlerdir. Geliştirilen yöntem, ön işleme, görüntü işleme, özellik çıkarma algoritması ve sınıflandırıcı olarak da yapay sinir ağlarını içermektedir. Radar verilerinde otomatik olarak alanların seçilmesi işlemi, kullanılan algoritmanın hesaplama süresini azaltmaktadır. Gömülü cisimlerden yansıyan sinyallerin birleşiminden meydana gelen görüntülerdeki farklı alanların Welch Güç Spektral yoğunluğu hesaplanarak elde edilen veriler geri yayılım algoritmasının eğitimi için kullanılmıştır. Gömülü cisimlerin konumunu ve derinliğini tespit etmek için hiperbolik desenlere Hough dönüşümü uygulanmıştır. Bu işlem sayesinde daha yüksek çözünürlüklü görüntülerin elde edilmesi ve hesaplama süresinin azaltılması sağlanmıştır. Önerilen yöntem yer altındaki boruları, kabloları, kara mayınlarını gerçek zamanlı olarak tespit edebilmektedir (Al-Nuaimy ve ark., 2000).

Gader ve ark.'nın gerçekleştirdikleri çalışmada kara mayınlarının tespitinde yere nüfuz eden radar görüntülerindeki hiperbollerini analiz edebilmek için Gizli Markov Modeli (GMM) kullanmışlardır. Önerilen yöntem çerçevesinde GPR cihazı ile üç farklı coğrafi bölgeden alınan gerçek zamanlı radargram verileri işlenmiştir. GPR cihazının hareketine bağlı olarak değişen gömülü cisim hiperbollerinin gürültülerden temizlenmesi amacıyla etkin bir GMM geliştirilmiştir. Modelin değişkenleri Baum-Welch algoritması ile optimize edilmiş ve kara mayınlarının tespiti için eğitilmiştir. Modelin test edilmesi için kullanılan veriler 6000 m² çakıllı araziden temin edilmiştir. Bu arazide 300 adetten fazla plastik ve metal olmayan kara mayınları bulunmaktadır (Gader ve ark., 2001).

J. Groenenboom ve ark. tasarladıkları model; sistem tasarımı, veri toplama ve veri işleme olmak üzere üç aşamadan oluşmaktadır. Elde edilen veriler metalik olmayan bir GPR cihazı tarafından temin edilmiştir. Taramanın yapıldığı test sahasında plastik, ahşap ve metalden yapılmış anti tank ve anti personel kara mayınları bulunmaktadır. Pratik ölçümlerde bazı sınırlamalardan ötürü veriler düzensiz bir hat üzerinde elde edilmiştir. Bu düzensizlik durumu, veri ön işleme ve görüntü işleme yöntemleri ile giderilmiştir. Kullanılan bu teknikler sayesinde sığ yüzeyde bulunan gömülü kara mayınlarının radar görüntülerinden tespiti sağlanmıştır (Groenenboom, 2002).

P. Gader ve ark. yapmış oldukları çalışmada kural tabanlı özellik çıkarım işlemi ve adaptif beyazlatma işlemi uygulamıştır. Bu işlemler, farklı derinliklerde beyazlatma

istatistiklerinin bağımsız olarak uyarlanması ve kural tabanlı özellik çıkarımı yöntemlerinin birleştirilmesine dayanan anormal durumların tespiti için kullanılır. Sabit yanlış alarm oranı (Constant False Alarm Rate - CFAR) detektörleri, derinliğe bağlı uyarlamalı beyazlatılmış verilerde anormal durum tespiti yapabilmektedir. CFAR belirlenmesinde istatistiksel maliyet fonksiyonu kullanılmaktadır. CFAR oranı yükseldikçe toprak altında anormal durumların varlığı ortaya çıkabilir. Bu durumda derinliğe bağlı özelliklerin çıkarımı gerçekleştirilir. Bu çalışma kapsamında CFAR ve kural tabanlı özellik çıkarım yöntemlerinin birleştirilmesinin sağladığı faydalar analiz edilmiştir. Önerilen algoritma ve analiz yöntemleri, GPR ile açık test alanından elde edilen veriler üzerine uygulanmıştır (Gader ve ark., 2004).

Shihab ve ark. yapmış oldukları çalışmada gömülü silindirik nesnelerin çapının belirlenmesinde yeni bir matematiksel denklem modeli sunmuşlardır. Ayrıca orta derinliklerde bulunan gömülü nesnelerin bağıl geçirgenliğini daha doğru bir şekilde tahmin etmişlerdir. Bu çalışma kapsamında radargram verilerine bir dizi görüntü işleme yöntemleri uygulandıktan sonra görüntü içerisindeki hiperbolik desenlerin belirlenmesinde eğri uydurma yöntemi kullanılmıştır. Önerilen bu yöntem sayesinde gömülü silindirik nesnelerin yarıçapı ve bulunduğu derinlik mesafesi %1 hata oranı ile doğru bir şekilde tahmin edilmiştir (Shihab ve ark., 2004).

Benedetto ve ark. asfalt yol yüzeyindeki bozuklukları ve çatlakları tespit etmek amacıyla GPR verileri üzerinde işaret işleme algoritması önermişlerdir. Kullanılan algoritma sayesinde otomatik bir şekilde GPR verilerinin analizi gerçekleştirilerek asfalt yollardaki bozukluklar ve çatlaklar sınıflandırılmıştır. Asfalt yolun bozukluk seviyesinin belirlenmesinde çoklu eşikleme işlemi yapılmıştır. Belirlenen ilk eşik seviyesi yol bozukluğunun tespitinde kullanılırken, ikinci eşik seviyesi ise yol bozukluğunun şeklinin belirlenmesinde kullanılmıştır. Uzaktan algılamanın istenen düzeyde yapılabilmesi için Neyman-Pearson radar testi ile deneyler gerçekleştirilmiştir. Deneysel ölçümler ile birlikte gerekli ayarlamalar gerçekleştirilmiştir. Sistemin çalışma performansı alıcı anten çalışma karakteristiği göz önüne alınarak değerlendirilmiştir. Elde edilen işaretlerin özellikleri, korelasyon işlemine tabi tutularak performans uygunluğu test edilmiştir (Benedetto ve ark., 2005).

Caorsi ve ark. gerçekleştirdikleri çalışmada yapay sinir ağlarını, gömülü silindirik nesnelerin geometrik ve dielektrik özelliklerini belirlemede kullanmışlardır. Hedef gömülü nesneden saçılan elektrik alanlarından elde edilen veriler yapay sinir ağına giriş olarak verilmiştir. Çalışma kapsamında basit bir simülasyon içerisinde yere nüfuz eden

radardan alınan verilerin farklı yapay sinir ağı modellerinden elde edilen sonuçlar karşılaştırılmıştır. Son olarak ise önerilen algoritmanın değişken ve gürültülü ortamlara karşı uyumluluğu test edilmiştir (Caorsi ve Cevini, 2005).

Roth ve ark. önerdikleri konvolüsyon modelleri ile GPR saçılma alanlarını frekans ve zaman ortamında analiz etmişlerdir. Oluşan saçılma problemini Born veya fiziksel optik yöntemi ile düzgünleştirerek uzak alan ters saçılma probleminin ve GPR sistemindeki alıcı/verici antenlerin modellenmesi sağlanmıştır. Ölçüm verilerinin üzerine üç boyutlu zaman ortamında sonlu farklar (Finite-Difference Time-Domain-FDTD) yöntemi kullanılarak konvolüsyon modellerinin testi gerçekleştirilmiştir. Gömülü hedeflerin boyutları ve bulunduğu derinliğin hesabı, darbe cevap yaklaşım modelini kullanan ters konvolüsyon işlemi ile belirlenmiştir. Bu işlemler sonucu elde edilen bulgular ile deney ortamından elde edilen bulgular karşılaştırılarak yüksek bir doğruluk oranı tespit edilmiştir (Roth ve ark., 2005).

Windsor ve ark. gerçekleştirdikleri çalışmada yer altındaki gömülü silindirik boruların çapının belirlenmesinde genelleştirilmiş Hough dönüşümü uygulamışlardır. Gerçekleştirilen uygulamada 600 MHz merkez frekansına sahip GPR cihazı ile 1 m veya daha derinde bulunan silindirik boruların görüntülenmesi sağlanmıştır. Tarama görüntülerinde gömülü nesnelere temsil eden hiperbollerin belirginleştirilmesi amacıyla genelleştirilmiş Hough dönüşümü uygulanmıştır. Bu yöntem, 1 m derinlikte bulunan 0.18 m yarıçaplı gömülü beton borunun bulunduğu ortamda denenmiş ve boru yarıçapı 0.174 m olarak belirlenmiştir (C. G. Windsor, 2005).

Hichem Frigui ve ark. kara mayınlarının tespitinde gerçek zamanlı bir sistem tasarımı gerçekleştirmişlerdir. Sistemde adaptif ön işleme birimi, GMM tabanlı bir algılayıcı, düzeltici eğitim bileşeni ve arka plan model tanımlayıcısı bulunmaktadır. Ön işleme, frekans ortamındaki sinyal işlemeye dayanır. Aynı zamanda ön işleme, yer seviyesinde hizalama ve arka plan kaldırmayı gerçekleştirir. GMM detektörü daha önceden önerilen bir sistemin gelişmiş versiyonudur. Zaman verimliliğini artırmak ve gerçek zamanlı uygulamalara imkan sağlanabilmesi için bir dizi ön ve son işleme algoritmaları kullanılır. Önerilen sistemde kullanılan düzeltici eğitim bileşeni yanlış sınıflandırmayı en aza indirmek ve eğitim aşaması öncesi başlangıç parametrelerine en iyi değerleri atamak için kullanılır. Düzeltici eğitim bileşeni on-line veya off-line modunda kullanılabilir. Arka plan model parametrelerini ayarlayabilmek için arka plan güncelleme bileşeni uygulanır. Önerilen yazılım sistemi GPR cihazına entegre bir şekilde üç farklı coğrafi konumdan alınan veriler ile test edilmiştir. İlk konumdan alınan

veriler algoritmanın eğitimi için kullanılmış geri kalan iki konumdan alınan veriler test için kullanılmıştır. Elde edilen sonuçlar sistem performansının %10-50 arasında artığını göstermektedir (Frigui ve ark., 2005).

Lambot ve ark. GPR cihazı ölçümlerinden toprak yapısının dielektrik sabitin ve içerisindeki su miktarının analizini, ortak yüzey yansıması ve tam dalga evirmesi yöntemiyle gerçekleştirmiştir. Tam dalga yaklaşımında anten etkileri frekans ortamında filtrelenirken, tam dalga evirimi zaman ortamında yüzey yansımalarına odaklanır. Uygulanan sentetik deneyler toprağın elektrik iletkenliğini ihmal edilebilir etkilerini araştırmak için gerçekleştirilmiştir. Sonuç olarak, gerçek ölçüm ve modelleme hatalarına ilişkin tahminlerin kararlılığını analiz etmek için laboratuvar ortamında bir dizi deneme gerçekleştirilmiştir. Su içeriğinin belirlenmesinde ortak yüzey yansıması yönteminin kullanılması uygun olmakla birlikte, tam dalga evrimi yöntemi kullanılarak daha iyi sonuçlar elde edilmiştir (Lambot ve ark., 2006).

Kovalenko ve ark. gerçek zamanlı GPR uygulamalarında plastik kaplı kara mayınlarının tespiti üzerine çalışma gerçekleştirmişlerdir. Önerilen algoritmada GPR cihazı tarafından alınan bir boyutlu geri dönüş sinyallerinde referans dalga formunun varlığını araştıran doğrusal olmayan bir sinyal işlemcisi kullanılmaktadır. Referans dalga biçimi, belirli bir ortamdaki gömülü hedeflerin sınıfını temsil eder. Farklı dalga biçimi cevapları ile sinyaldeki gürültü ve dağınıklıklar bastırılır. Referans dalga biçimi ve diğer algoritma parametreleri, kontrollü bir ortamdan elde edilen veri kümeleri tarafından eğitildikten sonra belirlenir. Eğitim işlemi tamamlandıktan sonra algoritma, eğitim sahalarından farklı olarak test sahalarında da başarılı bir şekilde uygulanabilmektedir. Önerilen algoritma, deneysel veriler üzerinde test edilmiştir. Sistem performansı, arka planın kaldırılması ve bir referans dalgacık formu ile çapraz korelasyon yoluyla dağınıklıkların bastırıldığı şemalarla değerlendirilmiştir. Performans karşılaştırması, alıcı sistemine ait karakteristik eğrileri açısından yapılmıştır. Önerilen algoritmanın, çapraz korelasyon temelli dağınıklık bastırma yöntemi ile karşılaştırıldığında yaklaşık iki buçuk kat yanlış alarm oranını düşürdüğü tespit edilmiştir (Kovalenko ve ark., 2007).

Pasolli ve ark. GPR B tarama görüntülerinin otomatik olarak analizinin gerçekleştirilmesi için örüntü tanıma algoritması geliştirmişlerdir. Önerilen algoritma ön işleme, bölütleme, nesne tanıma ve malzeme tanıma aşamalarından oluşmaktadır. Nesne tanıma işleminde denetimsiz öğrenme yöntemlerinden biri olan genetik algoritma kullanılarak doğrusal/hiperbolik desenler tespit edilmiştir. Gömülü nesnelere

malzemelerinin tespitinde ise Destek Vektör Makinesi (DVM) ile sınıflandırma yapılmıştır. Sentetik görüntüler kullanılarak nesne ve malzeme tanıma üzerine oldukça iyi sonuçlar elde edilmiştir (Edoardo Pasolli ve Redha Attoui, 2008).

Pasolli ve ark. gerçekleştirdikleri diğer bir çalışmada GPR görüntülerindeki gömülü nesne özelliklerinin çıkarılması üzerine yeni bir yöntem geliştirmişlerdir. Genetik algoritma ile gömülü nesnelerin oluşturdukları desenlerin özellikleri çıkarıldıktan sonra gömülü nesnenin boyutlarını tahmin edebilmek için Gaussian regresyon analizi gerçekleştirilmiştir. Önerilen yöntem sonucunda tahmin edilen gömülü nesnelerin boyutları ile gerçek boyutların birbirine oldukça yakın olduğu gözlemlenmiştir (Pasolli ve ark., 2009).

Porsani ve ark. yapmış oldukları çalışmada yer altındaki beton borular ve çelik tankların tespit edilmesini ve konumunun belirlenmesini amaçlamışlardır. Kullanılan antenlerin merkez frekansları değiştirilerek karşılaştırmalı bir analiz yapılmıştır. Brezilya'nın Sao Paulo şehrindeki test sahasında, 2 metre derinliğe kadar gömülü olan boru ve tankların tespiti yapılmaya çalışılmıştır. 100 ve 200 MHz merkez frekansı kullanılarak gömülü çelik tanklar ve beton boruların tespiti başarıyla sağlanmıştır. Kullanılan bu iki farklı merkez frekans ile yüzey altı görüntü kalitesini iyileştirme ve farklı gömülü hedefleri ayırt etme potansiyelinin ortaya çıktığı ifade edilmiştir. Önerilen yöntemin jeoteknik çalışmalarda uygulanabilirliğe sahip olduğu yargısına varılmıştır (Porsani ve ark., 2010).

Liu ve Benedetto yapmış oldukları çalışmada homojen olmayan ortam koşullarının etkilerini ve elektromanyetik dalganın yayılımından kaynaklanan sorunları en aza indirmişlerdir. Çalışma kapsamında gömülü hiperbolik desenlerin tespitinde eğri uydurma yöntemine dayalı bir metot geliştirmişlerdir. Elde edilen deneysel sonuçlar, tüm hedeflerin doğru bir şekilde tespit edildiğini göstermektedir (Yayu Liu, 2010).

Benedetto ve ark. yapmış oldukları çalışmada GPR verilerini kullanarak toprak içeriğindeki nem oranının hesaplanmasında frekans ortamında analizler gerçekleştirmişlerdir. Nemlilik oranının hesabında GPR spektrumunda yüksek mertebeli özelliklerin çıkarımı gerçekleştirilmiştir. Elde edilen deneysel sonuçlar teorik beklentileri doğrulamakta ve toprak nem içeriğini tahmin etmek için önerilen yaklaşımın etkinliğini göstermektedir (Benedetto ve Benedetto, 2011).

El-Mahallawy ve Hashim GPR görüntüleme sistemleri ile yer altındaki gömülü cisimlerin belirlenmesinde ayırık kosinüs dönüşümü katsayılarını ve DVM algoritmasını

kullanarak gömülü cisimlerin malzemelerini belirlemişlerdir. Farklı tiplerdeki özellikler ile yansıyan sinyalin genliği ve istatistiksel bazı özellikler giriş matrisi olarak DVM algoritmasına aktarılmıştır. Elde edilen sınıflama sonuçlar ayırık kosinüs dönüşümü tabanlı yaklaşım kullanılarak elde edilen sonuçlar ile karşılaştırılmıştır. Algoritmalarda kullanılan veriler FDTD tabanlı bir GPR simülatörü ile üretilmiştir. Veri üretiminde gömülü nesnelerin malzemeleri, konumları ve diğer boyut parametreleri değiştirilmiştir. Önerilen algoritma speckle (benek) gürültüsü eklenmiş GPR verilerine de uygulanmıştır. Ön işleme teknikleri olarak 2 boyutlu Medyan ve Adaptif Weiner filtresi kullanılmıştır. Adaptif Weiner filtresinin ön işlem olarak kullanılması diğer tekniklere göre daha başarılı performans göstermiştir (El-Mahallawy ve Hashim, 2013).

Singh ve Nene patlayıcı nitelikli gömülü nesnelerin konumunu ve malzemesini gerçek zamanlı tespit eden bir tasarım gerçekleştirmişlerdir. Yer altı görüntüleme uygulamaları için kullanılan GPR cihazı maden ve boruların tespitinin yanı sıra kara mayınlarının tespitinde kullanılmaktadır. GPR görüntüleme, analizi zorlaştıran gürültü ve dağınıklar bulunmaktadır. Önerilen ön işleme algoritmaları ile bu sorunun etkileri en aza indirilmiştir. GPR görüntülerinde bulunan hiperbolik desenler üzerinde eğri uydurma ve yapay sinir ağları kullanılarak gömülü nesnelerin konumu tahmin edilmiştir (Singh ve Nene, 2013).

Williams ve ark. buz katmanlarındaki çatlak ve yarıkların tespitinde GPR B tarama görüntülerini kullanmışlardır. Gerçek zamanlı bir analizin yapılabilmesi için alt örnekleme GMM ve DVM kombinasyonlu bir algoritma kullanmışlardır. 2012'de Greenland bölgesinden elde edilen 129 adet GPR görüntüsü çapraz doğrulama için ayrılmıştır. Yanlış pozitif durumunu en aza indirmek için önerilen GMM+DVM algoritmasının eğitimi gerçekleştirilmiş ve çapraz doğrulama ile elde edilen sonuçlar değerlendirilmiştir. Kullanılan yöntem sayesinde yanlış pozitif oranı 0.0007 oranına düşürülmüştür. Ayrıca kullanılan yöntem sayesinde hesaplama yükü azaltılmıştır (Williams ve ark., 2014).

Gonzalez-Huici ve ark. GPR verileri ile kara mayınlarının tespitinde Stolt Migration (SM), Back Projection (BP) ve Mikrodalga Tomografik İncersiyon (MTI) yöntemlerini kullanmıştır. Kullanılan algoritmalarından elde edilen sonuçlar genel olarak kullanılan GPR veri filtreleme sonuçları ile karşılaştırılmıştır. Analizlerin gerçekleştirilmesi amacıyla, homojen olmayan topraklarda farklı hedeflerin sığ derinliklerde gömüldüğü, özel olarak hazırlanmış bir test alanından elde edilen deneysel veriler kullanılmıştır. Önerilen yaklaşımların performansı, tek bir piksel tabanlı ve

ortalama enerji algılama algoritması kullanılarak elde edilen doğruluklar (ROC eğrileri) açısından nicel olarak değerlendirilmiştir. Bu analize dayanarak, MTİ yönteminin, tespit edilmesi çok zor olan küçük mayınlar için diğer algoritmalarından daha iyi performans gösterdiği görülmüştür. Öte yandan, MTİ ve BP teknikleri orta büyüklükteki mayınların tespitinde benzer performanslar elde ettiği ve filtreleme yaklaşımlarına göre daha büyük boyutlardaki mayınların bulunduğu ortam için sonuçların iyileştirilemediği görülmüştür. Ayrıca, SM hem orta hem de küçük mayınlar için en düşük performansı sergilemiştir (Gonzalez-Huici ve ark., 2014).

Manandhar ve ark. gerçekleştirdikleri çalışmada kullandıkları yöntemi sıralı bir GMM dizisi çoklu-örnek öğrenme çerçevesi kullanarak geliştirmişlerdir. Önerilen algoritmanın eğitimi, gömülü hedef ve gömülü hedef dışı olmak üzere gerçekleştirilmiştir. Kullanılan modelin parametreleri değişken tabanlı Bayes teoremine göre çıkarılmış ve sayısal olarak verimli hale getirilmiştir. Kara mayınlarının bulunduğu iki sentetik ve iki gerçek veri seti üzerinde yapılan deneysel sonuçlar, önerilen yaklaşımın standart bir GMM'den daha iyi performans verdiğini göstermiştir (Manandhar ve ark., 2015).

Liu ve ark. yaptıkları çalışmada GPR polarizasyon duyarlılığını artırmak ve iki doğrusal polarizasyonun alınması için dairesel polarize spiral anten ve iki ortogonal yönelimli Vivaldi anteni içeren basit bir hibrid çift polarizasyona sahip GPR sistemi önermişlerdir. Doğrusal bir nesneyi tespit etmek için GPR cihazının iki Vivaldi anteni olan bir spiral antenin hibrid kombinasyonunun, bir ultra geniş bant içinde çalıştığı ve küçük anten dispersiyonuna sahip olduğu gözlemlenmiştir. Ayrıca, uygun anten izolasyonuna sahip olduğu anlaşılmıştır. Önerilen GPR sisteminin, doğrusal yeraltı nesnelere tespit etmede geleneksel tek kutuplu bir cihaz üzerinde geliştirilmiş performansı, laboratuvar ortamında bir kum havuzu içerisinde test edilmiştir. Önerilen sistem ile tek bir verici ile tamamen uyumlu çift polarizasyon ölçümleri gerçekleştirmenin de mümkün olduğu bildirilmiştir (Liu ve ark., 2015).

Krueger ve ark. önerdikleri modelde GPR verileri üzerinde farklı sözlük stratejilerini kullanarak ve sözlük boyutunu artırıp azaltarak son derece pratik hesaplama yapabilen hızlı Fourier dönüşümünün kullanılabilirliğini göstermişlerdir (Krueger ve ark., 2015).

Feng ve ark. gerçekleştirdikleri çalışmada polarimetrik özellikleri elde etmek için H- α ayrışmasını kullanmışlardır. H- α ayrışmasını ve migrasyonunu birleştirerek, gömülü nesnelere geometrik bilgileri elde edilebilmektedir. Bu teknik kullanılarak

laboratuvar ortamında 3 boyutlu tam polarimetrik GPR veri seti elde edilmiştir. Ayrıca, bir yüzey altı H-alfa renk kodlu yeniden yapılandırılmış hedef görüntüsü elde edilmiş ve laboratuvar ortamında gömülü dört hedef belirlenebilmiştir (Feng ve ark., 2015).

Yu ve ark. yaptıkları çalışma kapsamında geleneksel dokuz bölgeli H- α sınıflandırma şemasının, gürültü ve dağınıklığın varlığı nedeniyle GPR hedeflerini sınıflandırmada etkili olması için değiştirilmesinin gerekli olduğunu göstermişlerdir. Beyaz gürültü ve dağınıklığın tamamen polarimetrik saçılma verisinden elde edilen H- α özellikleri üzerindeki etkileri araştırılmış ve yeni bir dört bölgeli H- α sınıflandırma şeması geliştirilmiştir. Bu yeni şema kullanılarak doğrusal olarak polarize olmuş ve olmamış hedefler sınıflandırılmış ve dış mekân ölçüm örnekleri üzerine uygulanmıştır (Yu ve ark., 2017).

Zhou ve ark. yaptıkları çalışmada GPR verilerini tam otomatik görüntü işleme algoritmaları ile değerlendirmişlerdir. GPR B tarama görüntüleri üzerinde ön işleme yöntemi olarak açık tarama kümeleme algoritması metodu olan parabolik eğri uydurma tekniği ile ikili eşikleme gerçekleştirilmiştir. Bu sayede hiperbolik desenlerin bölütlenmesi gerçekleştirilmiştir. Simülasyon ve gerçek dünyadaki veri setleri üzerinde yapılan deneyler, önerilen modelin etkinliğini göstermektedir (Zhou ve ark., 2018).

Lei ve ark. gerçekleştirdikleri çalışmada gömülü nesnelere tespiti ve çerçeveselendirilmesi için otomatik bir yöntem sunmaktadır. Nesne tespit algoritması olarak hızlı bölgesel tabanlı konvolüsyonel sinir ağları kullanılmıştır. Önerilen yöntem otomatik ve verimli bir şekilde GPR B tarama görüntülerinden bilgi çıkararak sentetik ve gerçek GPR veri setlerinin analizinde önemli performans göstermiştir (Lei ve ark., 2019).

Zhou ve ark. çalışmalarında GPR verileri kullanılarak verimli bir plastik boru algılama modeli önerilmişlerdir. Önerilen model, elektrik alan yerleştirme modeli ve GPR B tarama görüntü yorumlama modelinden oluşmaktadır. Elektrik alan yerleştirme modeli yeraltı plastik boruların elektrik alan verilerinden yaklaşık konumlarını hızlı bir şekilde tahmin eder. Sonrasında GPR B tarama görüntü yorumlama modeli ise gömülü borunun derinliğini ve yarıçapını yorumlar. Önerilen modelde gömülü boruların derinliği ve yarıçapı verimli bir şekilde tespit edildiği kanıtlanmıştır (Zhou ve ark., 2019).

Kim ve ark. yapmış oldukları çalışmada üç boyutlu C tarama görüntülerinden oluşan GPR görüntülerini kullanarak derin öğrenme tabanlı bir yer altı nesne sınıflandırma tekniği önermektedir. Otomatik yer altı nesne sınıflandırmasında

kullanılmak üzere 3-B GPR verilerinin işlenmesinde kullanım için derin konvolüsyonel sinir ağı tekniği kullanılmıştır. Önerilen yöntemin performansı Güney Kore'nin Seul kentindeki kentsel yollardan elde edilen 3-B GPR yol tarama verileri kullanılarak deneysel olarak doğrulanmıştır. Yöntemin sınıflandırma performansı, sadece B tarama görüntülerini kullanan geleneksel bir yöntemle karşılaştırılmıştır (Kim ve ark., 2019).

Zhang ve ark. gerçekleştirdikleri çalışmada GPR verilerinin işlenmesi için yarı uyarlamalı daldırma filtresi oluşturularak f-x düzleminde ampirik mod ayrışmasının genişletilmiş versiyonu kullanılmıştır. Önerilen yöntem ile GPR B taramalarında daldırma yapılarını, alt yatay katmanları ve rastgele gürültünün çoğunu ayırabilmektedir (Zhang ve ark., 2019).

Jiao ve ark. çalışmalarında yansıma sinyalinin kutuplanması ve görüntü örüntülerini karakterize ederek, delaminasyon, hava boşluğu ve nem dâhil olmak üzere beton yapıdaki üç büyük hatayı tespit etmeye çalışmışlardır. Kutuplanma özelliğini incelemek için histogram eşitleme ve binarizasyon olmak üzere bir dizi ön işleme algoritmaları kullanılmıştır. Örüntü analizi için F-K geçişi, görüntü eşikleme ve ana sinyal çıkarma işlemi gerçekleştirilir. Algoritmaların performansını değerlendirmek için 900 MHz tarama frekansına sahip GPR ile hem simülasyon verileri hem de alan testi verileri kullanılmıştır. Deneysel sonuçlar, beton yapıdaki üç ana kusuru tanımlamak ve karakterize etmek için yüksek performans göstermektedir (Jiao ve ark., 2020).

Bestagini ve ark. önerdikleri yöntemde farklı kutuplanmaları kullanarak GPR ile elde edilen hacimsel verileri analiz etmek için otomatik kodlayıcı olarak bilinen bir tür konvolüsyonel sinir ağından yararlanır. Gerçek veriler üzerinde yapılan deneyler dikkate alındığında önerilen tekniğin çok az eğitim gerektirdiğini ve zorlu veri setlerinde % 93'den daha yüksek doğruluk elde etmek için veri ön işleme algoritmaları gerektirmediğini göstermektedir (Bestagini, 2020).

Meşecan ve ark. gerçekleştirdikleri çalışmada GprMax programından elde ettikleri simülasyon verilerini kullanarak gömülü nesnelere bulmak için üç aşamalı bir yöntem ile özellik vektörleri oluşturulmuştur. Özellik vektörü elde etmek için n-satır ortalama kullanarak ön işleme, görüntü ölçeklendirme ve ilgi alanını bir özellik vektörüne dönüştürme algoritmaları kullanılır. Sınıflandırma algoritması olarak K En Yakın Komşuluk (K-EYK) kümeleme yöntemi kullanılarak %90.3'lük bir tespit performansı elde edilmiştir (Meşecan ve ark., 2020).

3. MATERYAL VE YÖNTEM

3.1. Yere Nüfuz Eden Radar (GPR) ve Elektromanyetik Teori

Gömülü nesnelere algılamak ve tespit etmek için birkaç yöntem mevcuttur. Yüzeysel algılama teknikleri olarak kullanılan yöntemler sismik, elektriksel direnç, nükleonik, yer çekimi yüzey araştırması, termografik ve GPR olarak sıralanabilir. Bu yöntemler arasında GPR, mühendisler ve bilim adamları arasında kullanımı en çok olanıdır. GPR cihazı, yer altını araştırmak amacıyla tasarlanmış bir tekniktir. GPR'in uygulama alanı çok çeşitlidir. Ayrıca, gelişmiş sinyal işleme teknikleri, özel sistem tasarımı ve işletim uygulamaları ile birlikte bu tekniğin kalitesi artmaktadır.

GPR, dielektrik süreksizliğe sahip olan yer altı katmanlarını ve farklı geometrik yapıdaki nesnelere tespit edebilir. GPR sistemi tercihen belirli bir hedef tipini tespit etmek için tasarlanabilir. Sinyal zayıflaması ve çalışma frekansı, belirli bir uygulama için GPR sistem tasarımında iki ana faktördür. Yüksek iletkenliğe sahip ortamlar daha yüksek oranda sinyal zayıflamasına sahiptirler. Bu ortamlarda sinyal zayıflaması daha düşük bir çalışma frekansı kullanılarak azaltılabilir ancak bu durum elde edilen görüntü çözünürlüğünü azaltmaktadır. GPR'nin başarılı bir şekilde çalışması aşağıdaki faktörlere bağlıdır:

- GPR sinyalinin yer düzlemi ile oluşturduğu kuplaj,
- GPR sinyalinin en az zayıflama ile hedefe yeterli miktarda nüfuz edebilmesi,
- Hedeften yansıyan sinyaller,
- İyi çözünürlük ve düşük gürültü seviyeleri elde edilebilmesi için tespit edilen sinyalin yeterli bir bant genişliğine sahip olması.

Uygulamada kullanılan çalışma frekansı ve bant genişliğine göre nüfuz etme derinliği ve tarama görüntüsü çözünürlüğü değişmektedir. GPR'in başarılı bir şekilde faaliyet gösterebilmesi için yeterli miktarda sinyal/dağınıklık oranına, uzamsal ve derinlik çözünürlüğüne sahip olması gerekir.

3.1.1. Yalıtkan malzemelerde elektromanyetik özellikler

Farklı fiziksel ortamlarda EM dalgaların birbirleri ile etkileşimi karmaşık olabilir. Kuantum fiziği bu etkileşimleri tanımlayabilmek amacıyla kesin modeller kullanır. Bu modeller Maxwell tarafından öne sürülen, yayılan ve yansıyan elektrik (E) ve manyetik (H) alan vektör denklemleri tarafından tanımlanır (Yu ve ark., 2016).

Bir malzemenin manyetik geçirgenliği (μ), EM alan içerisinde malzemenin manyetize olmasını sağlar. Birimi Henry/metre (H/m) olarak ölçülen manyetik geçirgenlik, malzemenin manyetik özelliğini gösteren bir ölçüttür. Bağlı manyetik geçirgenlik μ_r ile temsil edilir ve Eşitlik 3.1'de gösterildiği gibi hesaplanır.

$$\mu_r = \mu / \mu_o \quad (3.1)$$

Ferromanyetik malzemelerin ($\mu_r \gg 1$) frekansa bağlı olarak manyetik geçirgenliği değişmektedir (Ma ve ark., 2018). Ferromanyetik özellik göstermeyen malzemelerin bağlı manyetik geçirgenliği ($\mu_r \approx 1$) yaklaşık 1 olarak kabul edilir. Böylece bu tip malzemelerin manyetik geçirgenliği boşluğun manyetik geçirgenliğine eş değer varsayılır.

Elektrik geçirgenlik (ϵ), malzemenin elektriksel kutuplanabilirliğinin bir ölçütü olarak tanımlanır. EM dalgaının malzeme içerisinde ilerleme hızı elektrik geçirgenliğine bağlı olarak değişir. Dielektrik sabitinin yüksek olduğu malzemelerde EM dalgalar daha yavaş ilerler. Bundan dolayı radar dalgaları malzeme içerisinde ışık hızından yavaş ilerler. Fakat bazı malzemeler radar tarafından gönderilen enerjiyi soğurarak EM dalgayı daha da yavaşlatır.

Malzemenin bağlı elektrik geçirgenlik hesabı Eşitlik 3.2'deki formül ile hesaplanır.

$$\epsilon_r = \epsilon / \epsilon_o \quad (3.2)$$

Radar uygulamalarında elektriksel iletkenlik, malzemenin iletim kabiliyetini gösteren bir özelliktir. σ sembolü ile gösterilir ve birimi S/m'dir. İletkenliği yüksek olan

malzemeler EM dalganın iletimini zorlaştırır. Bu nedenle iletkenliği yüksek ortamda ilerleyen EM dalgada zayıflama ve dağılma gerçekleşerek sadece sığ kesimlere nüfuz edebilir. İletkenliği düşük malzemelerde ise EM dalganın ilerleyişi kolaylaşacağından EM dalga daha derinlere nüfuz edebilir (Sun ve ark., 2003).

GPR, EM dalganın iletimi ile çalıştığından düşük iletkenliğe sahip kuru kum, buz ve kuru beton gibi ortamlarda daha derinleri araştırabilirken iletkenliği yüksek olan tuzlu su ve ıslak beton gibi ortamlarda ise daha sığ alanları araştırabilir.

Tanımlanan mesafe içerisinde kendini tekrarlayan dalgaların kat ettiği mesafeye dalga boyu (λ) adı verilir (Belli ve ark., 2011). Dalga boyunun hesabı Eşitlik 3.3'e göre yapılır.

$$\lambda = \frac{2\pi}{\beta} = 2\pi \frac{v}{\omega} = \frac{v}{f} \quad (3.3)$$

GPR antenleri arasında dalga boyunun yarısından fazla bir mesafe bulunuyorsa tarama yönüne dik olarak hizalanmış yapıları kolayca tespit edebilir. Eğer antenler arasında çeyrek dalga boyundan daha fazla fakat yarım dalga boyundan daha az bir mesafe bulunuyorsa sadece birbiri üzerine yığılmış yapıların tespiti gerçekleştirilebilir.

GPR'nin menzili ortamdaki kayıplar dikkate alınarak belirlenir. Bu kayıplar yayılma kayıpları, yansıma kayıpları ve malzeme nedenli kayıplar olmak üzere sınıflandırılır.

GPR sinyali verici antenden çıkıp alıcı antene geri gelene kadar çeşitli kayıp aşamalarından geçer. Antenden hedefe olan belirli bir mesafe için, toplam yol kaybının L_T hesabı Eşitlik 3.4'de gösterilmiştir (Daniels, 2004).

$$L_T = L_e + L_m + L_{t1} + L_{t2} + L_a + L_s + L_{sc} \quad (3.4)$$

Eşitlik 3.4'de bulunan değişkenler sırasıyla L_e anten verimi kaybı, L_m anten uyumsuzluğu kaybı, L_{t1} havadan malzemeye iletim kaybı, L_{t2} malzemedan havaya yeniden aktarım kaybı, L_a malzemedan kaynaklanan zayıflama kaybı, L_s anten yayılma kaybı ve L_{sc} hedeften saçılma kaybıdır.

EM dalganın açısal frekansı ω olarak tanımlanırsa Eşitlik 3.5'deki gibi hesaplanır.

$$\omega = 2\pi f \quad (3.5)$$

Faz sabiti (β), ortam özellikleri ve açısal frekansa bağlı olarak Eşitlik 3.6'daki gibi ifade edilir (Salon ve Dangelo, 1988):

$$\beta = \omega \sqrt{\frac{\mu\epsilon}{2} \left[\sqrt{1 + \left[\frac{\sigma}{\omega\epsilon} \right]^2} + 1 \right]^{0.5}} \quad (3.6)$$

Elektriksel iletkenliği çok düşük olan malzemeler için faz sabiti yaklaşık olarak Eşitlik 3.7'deki gibi kabul edilir.

$$\beta = \omega \sqrt{\mu\epsilon} \quad (3.7)$$

EM dalgaların yayılma sabiti ve yansımaya katsayısının hesabında öz empedans (η) oldukça önem arz eder. Eşitlik 3.8'de öz empedansın formülü verilmektedir.

$$\eta = \sqrt{\frac{\mu}{\epsilon}} \quad (3.8)$$

Snell kırılma yasasından faydalanılarak yansımaya (Γ) ve iletim katsayıları (τ) Eşitlik 3.9 ve Eşitlik 3.10'daki gibi hesaplanır.

$$\Gamma = \frac{\eta_2 \cos \theta_i - \eta_1 \cos \theta_t}{\eta_2 \cos \theta_i + \eta_1 \cos \theta_t} \quad (3.9)$$

$$\tau = \frac{2\eta_2 \cos \theta_i}{\eta_2 \cos \theta_i + \eta_1 \cos \theta_t} \quad (3.10)$$

Eşitlik 3.9 ve Eşitlik 3.10'daki η_1 ve η_2 birinci ve ikinci ortamdaki öz empedansları temsil eder. θ_i ve θ_t geliş ve kırılma açıları olarak ifade edilir.

Bir dalganın malzeme içerisinde ilerleme hızı, m/s biriminde Eşitlik 3.11 ile hesaplanır.

$$v = \frac{\omega}{\beta} \quad (3.11)$$

Boş uzayda EM dalganın hızı, ışık hızına eşit olup Eşitlik 3.12'deki gibi ifade edilebilir:

$$c = \frac{\omega}{\beta_o} = \frac{\omega}{\omega \sqrt{\mu_o \epsilon_o}} = \frac{1}{\sqrt{\mu_o \epsilon_o}} \approx 3 \times 10^8 \text{ m/s} \quad (3.12)$$

Elektromanyetik dalganın yayılma hız bilgisinin bilinmesi durumunda gömülü nesnenin bulunduğu derinliği hesaplayabilmek mümkündür. Malzeme homojen ve izotropik bir yapıya sahip olup iletkenliği oldukça düşükse yayılma hızı Eşitlik 3.13'e göre hesaplanır.

$$v = \frac{c}{\sqrt{\epsilon_r}} \quad (3.13)$$

Gömülü nesnenin bulunduğu derinlik mesafesi d ile sembolize edilirse Eşitlik 3.14'e göre hesaplamak mümkündür.

$$d = v \frac{t}{2} \quad (3.14)$$

Eşitlik 3.12'de bulunan c ışık hızını, ϵ_r ortamın bağıl elektriksel geçirgenliğini ve Eşitlik 3.14'deki v dalganın ortamdaki hızını, t ise EM dalganın hedefe gidiş geliş süresini belirtir. Yayılma hızı, bağıl elektriksel geçirgenliğin artmasıyla azalır. EM dalga ortamda farklı bir malzeme içine girdiğinde hızında ve dalga boyunda değişiklikler meydana gelir.

GPR taramalarında dağınıklık, gerçek gömülü hedefe benzer saçılma özelliklerine sahip istenmeyen sinyaller olarak tanımlanır. Dağınıklık, verici ve alıcı anten arasında meydana gelebilecek uyumsuzluklardan da kaynaklanabilir. Zemin yüzeyi ile anten arasında çoklu yansımalar da dağınıklık oluşturur. Dağınıklık miktarı anten türüne göre değişmektedir.

3.1.2. Frekans ve çözünürlük arasındaki ilişki

GPR tarama görüntüleri kısmi olarak sinyal dalga boyu veya çalışma frekansı ile ilişkilidir. Yüksek frekans (kısa dalga boyu) ile çalışan GPR ile elde edilen tarama görüntülerinin çözünürlükleri oldukça yüksektir. Kısa dalga boylu EM dalgaları daha dar alanlara odaklanarak detayları ortaya çıkarabilmektedir. Düşük frekanslı radarların ürettiği uzun dalga boyuna sahip EM dalgalar daha düşük çözünürlüklü tarama görüntüleri oluşturur. Bununla beraber düşük frekanslı EM dalgalar daha derinlere nüfuz edebilecektir (Schroedl, 2006).

Derinlik çözünürlüğü, GPR ile belirli bir derinlikte birkaç farklı türde gömülü nesnenin bulunduğu durumlarda önemlidir. Farklı gömülü nesne türlerini ayırt etmek için daha geniş bant genişliğine sahip bir sinyal gerekir. Alınan sinyalin bant genişliği, iletilen sinyalden daha önemlidir. Alıcı bant genişliği, alınan sinyalin güç spektrumu ile belirlenebilir.

3.2. Yere Nüfuz Eden Radar

Yer altı görüntüleme ve mikrodalga görüntüleme uygulamalarında sıkça kullanılan yere nüfuz eden radarlar, günümüzde en popüler araştırma konuları arasında yer almaktadır. Mikrodalga yayılımı prensibine göre çalışan bu radar tipleri yer altında veya insan yapımı olan yapıların altında bulunan gömülü cisimlerin algılanmasında kullanılır. Gömülü cisimlerin tespitiyle beraber toprak katmanlarının belirlenmesi, gömülü cisimlerin bulunduğu derinliğin algılanması gibi yer altı görüntüleme uygulamalarında etkin bir şekilde kullanılmaktadır. Literatürde bu radar tipi geniş bantlı yüzey altı görüntüleme radarı veya yer altı radarı olarak da adlandırılır (Daniels, 2004).

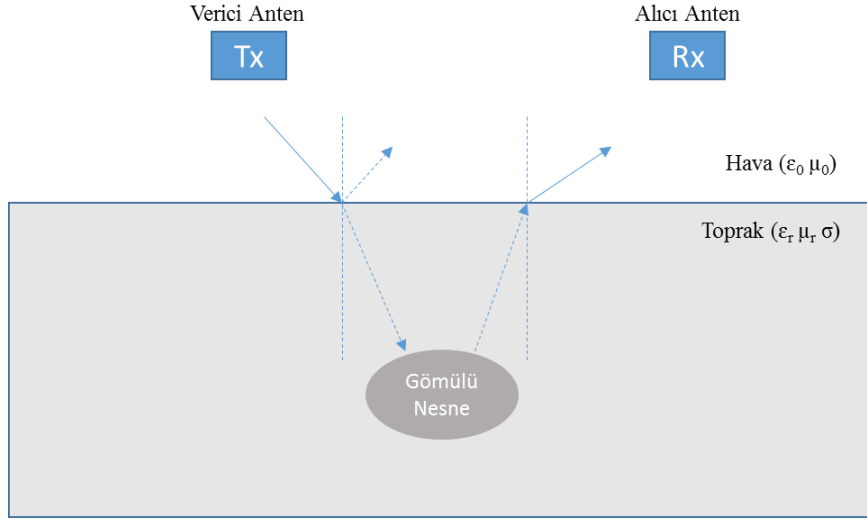
Geniş arazi alanlarında kullanılan yere nüfuz eden radarların oluşturduğu taramalar, gömülü nesnenin cinsi, malzemesi ve nesnenin bulunduğu ortama göre farklılık gösterir. Yer altı görüntüleme teknikleri daha çok nükleer silah tespiti, mayın

tespiti, yer altı sığınakların tespiti ve duvar arkasındaki nesnelere tespitinde oldukça yaygın bir uygulama alanına sahiptir.

Savunma sanayisinde ve arama kurtarma operasyonlarında duvar arkasındaki nesnelere algılanması oldukça önemlidir. Genellikle S bandı içerisinde çalışan radarlar duvar arkası nesnelere algılanmasında daha çok tercih edilir. Bu radar çeşitleri 20-30 cm kalınlığında bir duvarın arkasındaki nesneyi 15-20 m mesafeden tespit edebilme kabiliyetine sahiptir. Aynı zamanda bu radarlar seyir bir araca monte edilerek gerilla savaşlarında önemli avantajlar sağlayabilir. Bunun yanı sıra deprem nedeniyle oluşan göçüklerin altında gerçekleştirilen arama-kurtarma operasyonlarında bu radar tipleri oldukça katkı sağlamaktadır. Bu cihazlar göçük altında bulunan insanın konumunu belirlerken aralarda bulunan duvar sayısı hakkında da bilgi verebilmektedir (Xu ve ark., 2002).

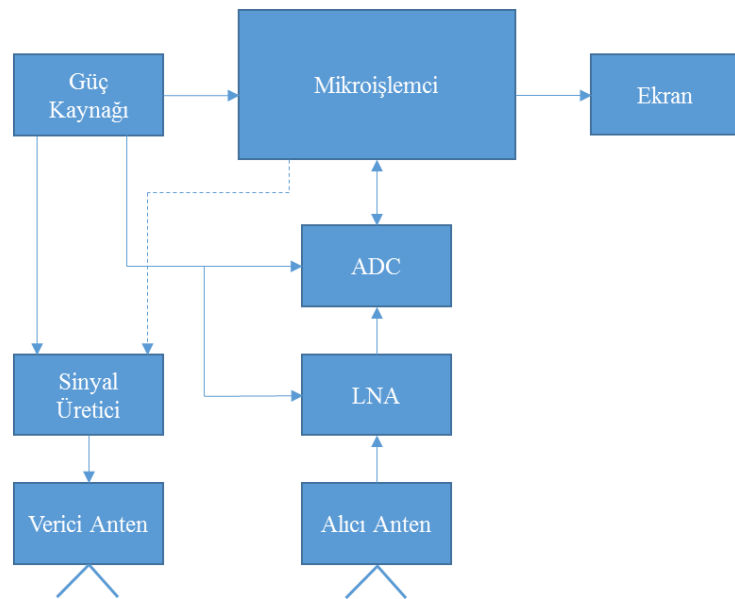
Terörün küreselleştiği dünyada kara mayınlarının varlığı her toplumu etkileyen önemli bir problemdir. Günümüze kadar alınan bir takım önlemler ile mayınların tespiti ve temizlenmesi çerçevesinde çalışmalar sürmektedir. Fakat günümüzde birçok farklı tipte mayınların bulunması hassas bir tespit işleminin yapılabilmesine engel olmaktadır. Gömülü nesnelere araştırılması adına kullanılan teknikler olarak metal detektörleri, optik algılayıcılar, kimyasal tespit, sonar teknolojiler ve yere nüfuz eden radarlar yer almaktadır. Kara mayınlarının tespitinde uygulanabilirlik açısından kullanılan teknikler arasında yere nüfuz eden radarlar ön plana çıkmaktadır (Wang ve ark., 2005).

Şekil 3.1'de görüldüğü üzere yere nüfuz eden radarlar, zemin düzlemine gönderdiği elektromanyetik dalgalardan geri saçılmış dalganın analizini gerçekleştirir. GPR cihazı gömülü malzemelerin elektriksel özelliklerinden meydana gelen süreksizlikleri algılayabilmesinin yanı sıra metal olmayan nesnelere tespitini de sağlamaktadır. Genellikle yere nüfuz eden radarlar 0.5-3 GHz bant aralığında çalışırlar. Dizi anten yapılarının kullanılmasıyla yere nüfuz eden radarlardan daha yüksek çözünürlükte iki boyutlu ve üç boyutlu görüntüleme yapılabilmektedir.



Şekil 3.1. Yere nüfuz eden radar çalışma senaryosu

Yere nüfuz eden radarlar nano saniye mertebesinde darbe sinyali üretebilme özelliğine sahiptirler. Yapısında bulunan verici anten sayesinde darbe sinyalini ortama gönderirler. Bu sinyal herhangi bir hedef ile karşılaştığında yansarak alıcı antene gelir. Yere nüfuz eden radardaki alıcı ve verici antenler birbirini ile aynı yapıdadır. Alıcı antenden elde edilen bilgiler örnekleme, filtreleme ve görüntüleme gibi süreçlerle devam ettirilir. Yere nüfuz eden radarın iç yapısı Şekil 3.2’de blok diyagram ile gösterilmiştir. Yere nüfuz eden radar sabit bir hız ile tarama gerçekleştirdiğinde gömülü hedeflerin kesit alanı görüntülerini elde eder. Eğer bu tarama işlemi enine ve boyuna olacak şekilde gerçekleştirilirse tarama işlemi yapılmış alanın üç boyutlu modeli elde edilebilir.




Şekil 3.2. Yere nüfuz eden radarın iç yapısı (Grandjean ve ark., 2000)

Yere nüfuz eden radarların kullandığı sinyal tipine göre dürtü ve frekans adımlı modelleri mevcuttur. Özellikle arkeolojik çalışmalarda ve mayın tespitinde yüksek frekansa sahip elektromanyetik dalga dürtüleri kullanan dürtü yere nüfuz eden radarlar tercih edilir. Bu radarların örnekleme frekansı ve tarama kabiliyeti oldukça yüksektir. Diğer bir model olan frekans adımlı yere nüfuz eden radarların frekans bandı tarama platformuna göre belirlenmesi gerekir. Ayrıca sürekli dalga formunu kullanan bu radar tiplerinde sinyal oldukça karmaşık bir şekilde işlenir.

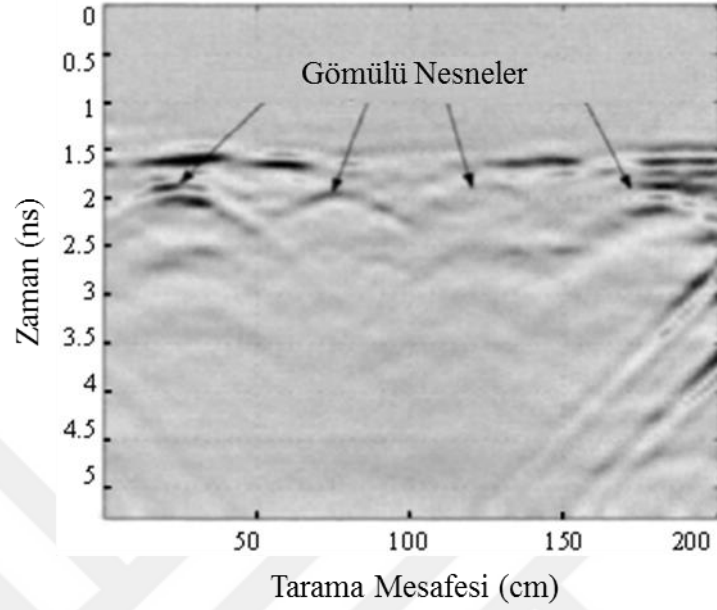
Yere nüfuz eden radarların verici anteninden gönderilen elektromanyetik dalganın iletilmesiyle ve alıcı anten tarafından alınması arasındaki geçen süreye göre gömülü nesnenin derinliği tespit edilir. Tarama işlemi gerçekleştirilen platformun elektriksel özellikleri ortamda ilerleyen elektromanyetik dalganın hızını değiştirebilir. Bunun yanı sıra gömülü nesnelere farklı malzemelere sahip olabilir. Gömülü nesnelere yansıyan radar sinyalleri, ortamın ve nesnenin fiziksel ve elektriksel özelliklerine göre farklılık gösterebilir. Yere nüfuz eden radarlar belirli adımlarda taramalar gerçekleştirerek yansımaları kaydeder.

Yere nüfuz eden radarlar üç farklı tarama işlemi gerçekleştirirler. Bu taramalar sırasıyla A-tarama, B-tarama ve C-tarama teknikleridir. A-tarama işlemi sabit bir konumdan ölçüm yapılarak gerçekleştirilir. Şekil 3.3'de gösterildiği gibi tek boyutlu A-tarama sinyali zaman ve genlik eksenlerinden oluşur. Bu sinyaller gömülü nesnelere yansıyan elektromanyetik dalganın alıcı anten tarafından toplanması ile elde edilir.



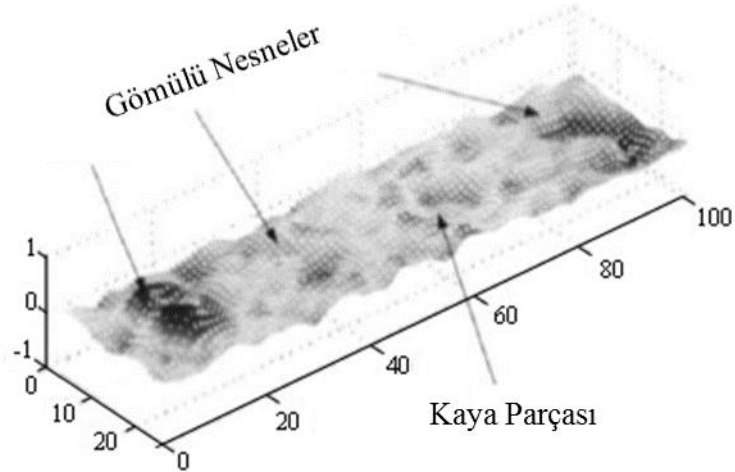
Şekil 3.3. A tarama sinyali

B-tarama görüntüsü, bir hat boyunca elde edilen A-tarama sinyallerinin birleştirilmesi ile elde edilir. Şekil 3.4'de görülen B tarama görüntüsü iki boyutlu veriye sahiptir.



Şekil 3.4. B tarama sinyali

C-tarama görüntüsü birden fazla hat boyunca elde edilen B-tarama görüntülerinin birleştirilmesinden meydana gelir. Şekil 3.5'deki C-tarama görüntüsü üç boyutlu olup gömülü nesne hakkında daha fazla bilgi içermektedir.



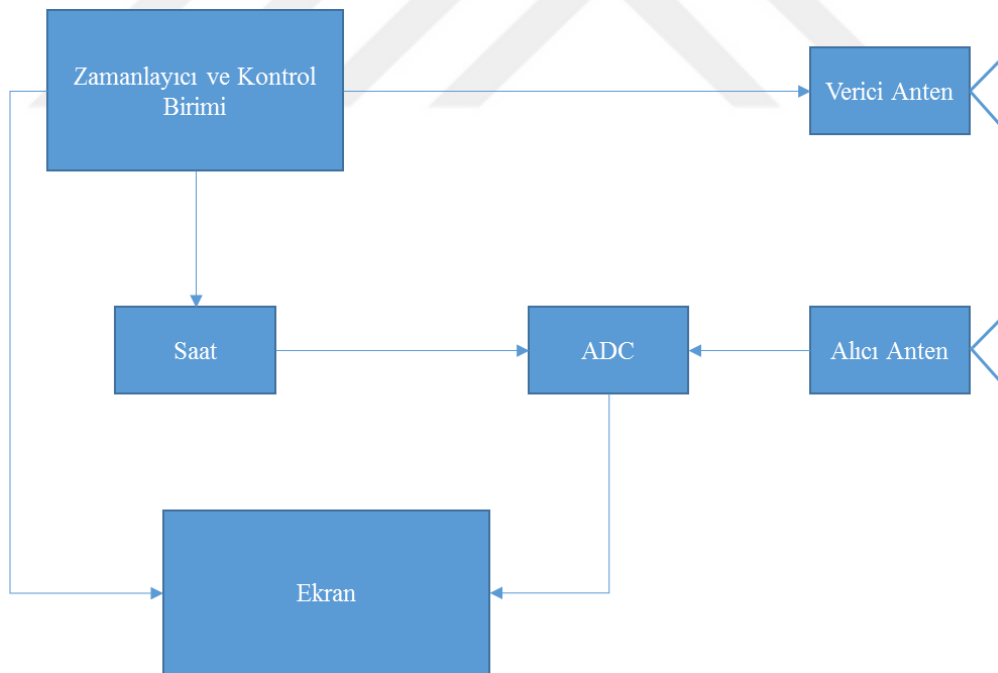
Şekil 3.5. C tarama görüntüsü

3.2.1. Darbeli yere nüfuz eden radar

Yüksek frekanslı ve nano saniye mertebesinde ayırık darbeler üreten darbeli yere nüfuz eden radarlar, aynı örnekleme frekansı ile verileri kaydetmektedir. Yere nüfuz eden radarın içerisindeki darbe üretici ile üretilen darbe verici antene ulaşır. Antenin özelliklerine göre 300 MHz-22.4 GHz arasında geniş bantta piko saniye seviyelerinde darbe sinyalleri ortama iletilir (Unal ve ark., 2013).

1970'li yıllarda ticari amaçlar için üretilen darbeli yere nüfuz eden radarlar birçok jeofizik uygulamalarında aktif olarak kullanılmıştır. Yüksek tarama kabiliyeti ve yüksek örnekleme hızı ile bu radar çeşidi gömülü mayın ve hedefleri tespit edebilmektedir. Ayrıca sinyal işleme biriminin diğer radar tiplerine göre oldukça basit olması tespit ve uyarı sistemlerinde büyük katkı sağlamaktadır.

Şekil 3.6'da görüldüğü üzere darbeli yere nüfuz eden radarda ADC, verici elektrolitleri, anten, saat, zamanlayıcı ve kontrol birimi bulunmaktadır. Zamanlayıcı birim ile verici antene kısa DC darbeler gönderilir.



Şekil 3.6. Darbeli yere nüfuz eden radarın iç yapısı (Kaur ve ark., 2016)

Alıcı anten ile alınan yansıma sinyalleri kaydedilerek çeşitli sayısallaştırma ve alt örnekleme işlemlerinden geçirilirler. Darbeli yere nüfuz eden radarın tasarımında bazı değişkenlerin belirlenmesi gerekir. Açısal çözünürlük, örnekleme frekansı ve darbe

genişliğine bağlı olan değişkenlerdendir. Açısal çözünürlük birden fazla gömülü nesnenin algılanmasında önemli bir değişkendir. Açısal çözünürlüğün hesabında kullanılan Eşitlik 3.15’de v dalganın hızını temsil ederken, τ ise darbe süresini gösterir.

$$\text{Açısal Çözünürlük} = \frac{v \cdot \tau}{2} \quad (3.15)$$

En derin mesafede (R_{max}) bulunan gömülü nesnelerin algılanmasına etki eden diğer bir değişken de T_R darbe tekrarlama aralığıdır. Darbe tekrarlama aralığına bağlı olarak R_{max} değerinin hesaplanması Eşitlik 3.16’da verilmiştir.

$$R_{max} = \frac{v \cdot T_R}{2} \quad (3.16)$$

3.2.2. Frekans adımli yere nüfuz eden radar

Belirli bir frekans bandı içerisinde sürekli dalga modu ile tarama gerçekleştiren frekans adımli yere nüfuz eden radarlarda elektromanyetik dalga saçılma denklemlerinin çözümü frekans ortamında gerçekleştirilir. Tarama ortamındaki hedef bilgileri, geri yansıyan dalga işaretinin frekans ortamındaki genlik ve faz bilgilerinden oluşur. Nüfuz etme derinliğinin fazla olduğu ve hızlı tarama uygulamaları için işaret işleme kolaylığı sağlayan darbeli yere nüfuz eden radarlar tercih edilir. Yüzeğe yakın olarak konumlanmış gömülü cisimlerin görüntülenmesinde çözünürlüğü ve dinamik aralığı oldukça yüksek frekans adımli yere nüfuz eden radar sistemleri kullanılır. Taranması planlanan ortamın niteliğine ve kullanıcı isteklerine bağlı olarak frekans bandı geniş ve darbe gücü yüksek yere nüfuz eden radarlar tercih edilir.

Frekans adımli sürekli dalga radarları yer altına belirli frekans aralığında göndermiş olduğu elektromanyetik dalgaların hedef cisimlere çarparak yansıyan sinyalleri alıcı anten ile geri toplar. Görüntüleme işlemi, geri yansıyan sinyallerin faz farkına ve gömülü nesnenin elektrik geçirgenliğe bağlı olarak gerçekleştirilir. Frekans adımli sürekli dalga radarları farklı derinlik seviyelerine göre frekans bandının ayarlanabilmesi, hassas ölçümler gerçekleştirilebilmesi, yüksek güçte sinyaller

üretebilmesi, dinamik aralığının yüksek olması ve alınan sinyallerdeki gürültüleri azaltabilmesi sağladığı avantajlar arasında yer almaktadır.

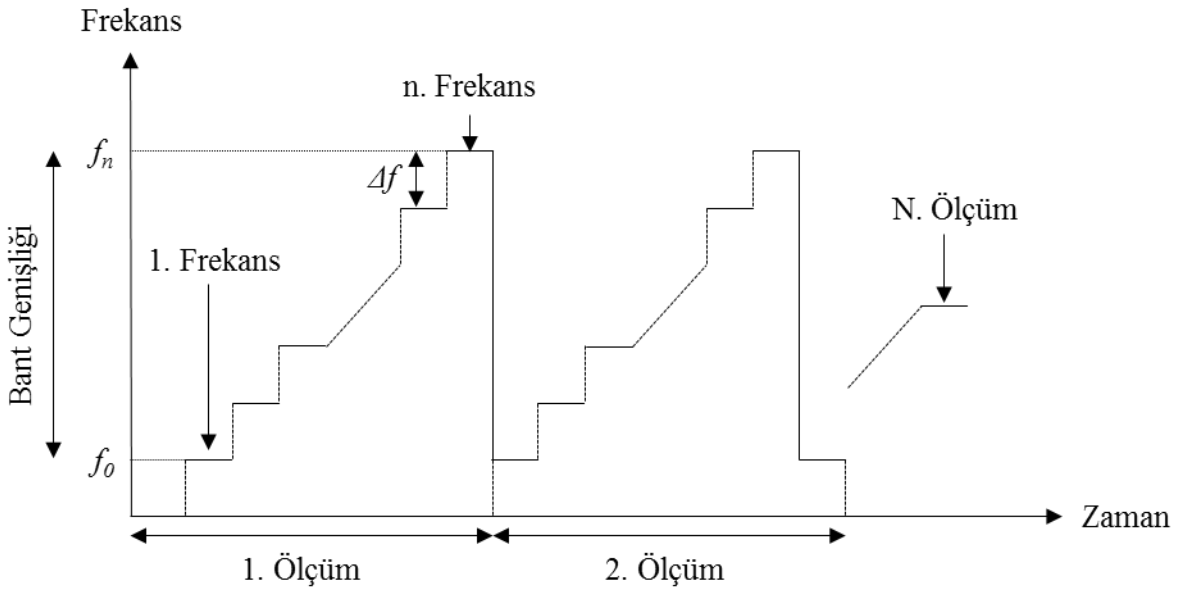
Frekans adımli sürekli dalga radarları üstün özelliklerine rağmen piyasada pek fazla kullanılmaz. Veri toplama süresinin uzun olması bunun başlıca nedenidir. Her tarama adımında harcanan süre, anahtarlama zamanı, gömülü nesnelerin bulunduğu derinlik mesafesi ve gereken sinyal gürültü oranının elde edilmesi için gereken süre gibi faktörlere bağlıdır (Wang ve ark., 2020).

Frekans adımli sürekli dalga radarları dalga frekansını gerilim kontrollü osilatör sayesinde belirler. Alınan ve gönderilen sinyal zamana bağlı bir fonksiyondur. Gerçekleşen değişim doğrusal bir yapıda ve dalganın geri dönüş zamanı T_d olarak kabul edilirse;

$$T_d = \frac{2R}{v} \quad (3.17)$$

Eşitlik 3.17’de R menzil mesafesini temsil eder.

Şekil 3.7’de görüldüğü gibi gönderilen sinyal yapısı incelendiğinde dalga şekli yükselen adım frekanslarından oluşmaktadır. Sinyalin her adımdaki faz ve genlik bilgileri ölçülerek analizler gerçekleştirilir. Ölçümdeki karmaşık diziye sahip faz bilgisi aynı zamanda hedef hakkında bilgiler sağlar.



Şekil 3.7. Sürekli dalga radarında frekans adımlarının gösterimi

Şekil 3.7’de gösterilen dalganın başlangıç frekansı f_0 ve dalganın sabit bir şekilde yükselme birim frekansı Δf olarak ifade edilmiştir. Herhangi bir n . örnek sinyalin frekansı Eşitlik 3.18’de göre hesaplanır.

$$f_n = f_0 + n\Delta f \quad n = 0, 1, \dots, M - 1 \quad (3.18)$$

Uzay boşluğunda R menzil mesafesine sahip noktasal bir verici-alıcı anten için geri yansıyan dalganın elektrik alan bileşenin ifadesi Eşitlik 3.19 ile temsil edilir.

$$E_z(n) = \rho e^{-j4\pi \frac{f_n d}{v}} \quad n = 0, 1, \dots, M - 1 \quad (3.19)$$

v dalganın ortama göre değişen hızını belirtirken ρ hedefin yansıtma özelliğini gösterir. d ise uzaklığı temsil eder. Herhangi bir kayıpsız ve homojen ortam için hız ifadesi;

$$v = \frac{c}{\sqrt{\epsilon_r}} \quad (3.20)$$

Aynı zamanda elektrik alanın dalga sayısı göre ifadesi Eşitlik 3.21’de gösterilmiştir.

$$E_z(k) = \rho e^{-jk(2d)} \quad (3.21)$$

k dalga sayısı Eşitlik 3.23’e göre elde edilir.

$$k = 2\pi \frac{f_n}{v} \quad (3.22)$$

3.2.3. İleri bakan yere nüfuz eden radar

Genel kullanım amacına uygun olarak yere nüfuz eden radarlar ile gömülü ve tehlike arz eden cisimler tespit edilmeye çalışılır. Patlayıcı özellikli gömülü maddelerin tespitinde bir araç üzerine yerleştirilen yere nüfuz eden radarın antenleri ileri bakacak şekilde konumlandırılır. Bu tip tasarıma ileri bakan yere nüfuz eden radar adı verilir. Mayınların ve patlayıcı özellikli maddelerin tespitinde radar aracının güvenli mesafede bulunması gerekir. Böylece gömülü mayınlar daha önceden tespit edilir ve herhangi bir can kaybına neden olunmaz. İleri bakan yere nüfuz eden radarlarda dizi anten yapıları bulunur. Antenler vasıtasıyla EM dalga belirli bir açıyla toprağa doğru yönlendirilir. Bu sayede radar belirli mesafeleri anlık olarak tarayabilir. Ayrıca bu işlem radarın güvenli bir menzilde tarama yapabilmesine izin verir.

Literatürde ileri bakan yere nüfuz eden radarlar ile ilgili farklı ülkeler tarafından yürütülen birçok proje bulunmaktadır. ALARIC adıyla bilinen ve ABD tarafından tasarlanan geniş banda sahip ileri bakan yere nüfuz eden radar, 0.3-3.0 GHz arasında yer altı görüntülemesi yapabilmektedir. Geliştirilen bu sistem askeri uygulamalar için olup elde edilen bulgular paylaşılmış ve gerçek zamanlı olarak gömülü nesnelere tespit edebileceği belirtilmiştir (Wong, 2010; Youn, 2010). Hawaii Üniversitesi bünyesinde tasarlanan yere nüfuz eden radar sistemi rezonans frekansı ve polarizasyon özelliklerini kullanarak patlayıcı gömülü malzeme tespitini gerçekleştirebilmektedir. Elde edilen sonuçların umut vadettiği belirtilmiş ve ileri bakan yere nüfuz eden radarların tehlikeli gömülü maddelerin tespitinde etkin bir şekilde kullanılacağı ifade edilmiştir.

Askeri uygulamalar ve kara mayınlarının tespitinde kullanılan yere nüfuz eden radarlar ileri bakan ve tepe görüşlü radarlar olmak üzere temelde iki kategoriye ayrılır. Tepe görüşlü yere nüfuz eden radar sistemlerindeki antenler yere oldukça yakın şekilde konumlandırılmıştır. Radar kesit alanının oldukça büyük olması sebebiyle tepe görüşlü yere nüfuz eden radarların tespit etme kabiliyetleri yüksektir. Bu radar tipleri kullanılarak elde edilen görüntülerde zemin yüzeyinden gelen güçlü yansımaların azaltılması gerekir. Ayrıca tepe görüşlü yere nüfuz eden radarların tarama işlemi için gereken süre oldukça fazladır. İleri bakan yere nüfuz eden radarların radar kesit alanları tepe görüşlü radarlara göre daha küçüktür. Bu durum her ne kadar dezavantaj olarak görünse de birçok avantaja sahiptir. İleri bakan yere nüfuz eden radarlar zeminden yansıyan EM dalgalarından pek etkilenmez. İleri hareket edebilme yeteneği sayesinde aynı nokta için birden fazla analiz gerçekleştirebilir. Günümüzde ileri bakan yere nüfuz

eden radarların kara mayınlarını yüksek bir oranla tespit edebilme yeteneği dikkate alındığında elde edilen tarama görüntülerinin yüksek çözünürlüğe sahip olması gerekir (Rodes ve ark., 2020).

3.3. GprMax

GprMax gömülü nesnelere tespitinde elektromanyetik dalga yayılımını simüle etmek için kullanılan popüler bir açık kaynaklı yazılımdır. İlk kez 1996 yılında geliştirilen GprMax programı sürekli olarak güncellenerek kullanıma sunulmuştur. Öncelikle yere nüfuz eden radar simülatörü olarak tasarlanmıştır. Bununla birlikte, farklı uygulamalar için elektromanyetik dalga yayılımını modellenerek yararlanılabilir. GprMax, yere nüfuz eden radarın sayısal modellenmesi için Maxwell denklemini zaman ortamında sonlu farklar (FDTD) yöntemi ile üç boyutlu çözmek için Yee'nin algoritmasını kullanır (Warren ve ark., 2016). GprMax'da kullanılan yazılım Python'da veya Cython'da yazılmış performans açısından kritik bazı kısımlardan oluşmaktadır. GprMax simülasyon aracının kurulumu ve güncelleme işlemi oldukça basittir (Giannakis ve ark., 2016). GprMax simülasyon programının güncel 2020 sürümünde, yeni özellikler aşağıdaki gibi sunulmuştur;

- Anizotropik malzeme modelleme

Ahşap ve fiber takviyeli kompozitler gibi malzemelerin doğru bir şekilde modellenmesinin yapılabilmesi için GprMax programında nesnelere diyagonal anizotropisi belirtilmesi gerekir. İzotropik malzemeler, x, y ve z yönlerinde aynı değerlere sahip olduğu anlamına gelir. Bu yeni özellik ile x, y ve z'deki tüm yönlerde ayrı ayrı değerler tanımlanabilir.

- Dispersif malzeme modelleme

GprMax simülasyon yazılımını kullanarak dispersif malzemeler, tek kutuplu Debye modeli kullanılarak temsil edilebilir. GPR'da kullanılan ortak frekans aralığı ile bu yaklaşımı kullanarak birçok malzemeyi modellemek mümkündür. Bununla birlikte, su, insan dokusu, altın, soğuk plazma ve toprak gibi malzemeler için çok kutuplu Debye, Drude ve Lorentz işlevleri sıklıkla kullanılır. GprMax'ın 2020 sürümünde bu işlevler kullanılabilir.

- Toprak zeminin gerçekçi geometrik özelliklere ve dielektrik sabitlerine göre modellenmesi

GprMax'ın yeni sürümünde daha gerçekçi geometrik özelliklere ve dielektrik sabitlerine sahip toprak yapıları oluşturulabilir. Bu özellik ile birlikte toprak zeminin dielektrik özellikleri, dağınmık malzeme işlevselliği kullanılarak tanımlanabilir.

- Heterojen cisimlerin ve toprak tiplerinin oluşturulması

Deneysel model içerisinde heterojen toprak zeminin dielektrik özelliklerini tanımlamak için kullanılır. Bu modelde, toprağın kütle yoğunluğu, toprak tipini yapılandırmak için kullanılan kum parçacık yoğunluğu, kum, kil ve su hacimsel miktarı gibi değişkenler belirtilebilir.

- Yüzey pürüzlülüğü

GprMax'ın bu özelliği pürüzlü yüzeyler içeren gerçekçi toprak özelliklerine sahip heterojen yapılar oluşturmak için kullanılır.

- Toprak zemin yüzeyinin nemliliğinin ve gerçekçiliğinin artırılması

Toprak zemininin nemlilik oranını değiştirmek amacıyla elektriksel özellikleri değiştirilebilir. Ayrıca, çim yüksekliği ve kök sayısı gibi bazı özellikleri dahi tanımlamak mümkündür.

- Ticari anten modellerinin oluşturulabilmesi

GprMax yazılımında Geophysical Survey Systems, Inc. (GSSI) 1.5 GHz (Model 5100) anten ve MALA Geoscience 1.2 GHz anten gibi önceden tanımlanmış anten çeşitleri bulunmaktadır.

3.3.1. Gömülü nesnelerin simülasyonu için gereken parametreler

Gömülü nesneyi GprMax simülasyon programında simüle etmek için .in uzantılı komut dosyasının oluşturulması gerekir. Bu komut dosyası Not Defteri veya Matlab programı ortamında hazırlanabilir. GprMax simülasyon yazılımında kullanılan komutlar farklı başlıklar halinde incelenmiştir. Simülasyon programı ile üretilen veri setinde kullanılan komutların listesi ve sözdizimi aşağıdaki başlıklar altında verilebilir:

- #title: str1

Bu komut, "str1" sözdiziminin boşluk karakteri içerebildiği ve başlığın tek bir satır olması gereken model için bir isim ataması yapar.

- #domain: f1 f2 f3

Modeli boyutlandırmak için kullanılan bu komut ve "f1 f2 f3" sözdizimi, modelin x, y ve z yönlerindeki boyutudur. Örneğin, 500 x 1000 x 1000 mm'lik bir model tanımlamak için "#domain: 0.5 1.0 1.0" komutu kullanılabilir.

- #dx_dy_dz: f1 f2 f3

Bu komut, x, y ve z yönlerinde olan "f1 f2 f3" değişkenleri ile alanın ayrıklaştırılmasını belirlemek için kullanılır. Örneğin, modelin dx = dy = dz = 10 mm parametreleriyle ayrıklaştırma alanı "#dx_dy_dz: 0.01 0.01 0.01" olarak tanımlanabilir.

- #time_window: i1

Bu komut kullanıcının toplam gerekli simülasyon süresini veya gerekli sayıda iterasyonu belirlemesini sağlar. "#time_window: 1000" komutu, pencereleme süresinin 1000 adet olacağı anlamına gelir.

- #material: f1 f2 f3 f4 str1

Bu komut, yapısal parametreler ile simülasyonda kullanılacak malzemeyi tanıtmaya yardımcı olur. "f1", elektriksel geçirgenliğe karşılık gelir, "f2" iletkenliktir, "f3", manyetik geçirgenliğe karşılık gelir, "f4", manyetik kayıptır ve "str1", simülasyonda kullanılacak malzemenin bir tanımlayıcısıdır.

- #fractal_box: f1 f2 f3 f4 f5 f6 f7 f8 f9 f10 i1 str1 str2 [i2] [c1]

Bu komut, fraktal dağıtılmış özelliklere sahip ortogonal paralel montaja sahip modelde normal malzemeye karşılık gelir. "f1 f2 f3", paralel borunun sol alt koordinatını ve "f4 f5 f6", paralel borunun sağ üst koordinatlarını (x, y, z) belirtir. "f7" malzeme kalınlığına karşılık gelir. "f8 f9 f10", fraktal kutuyu x, y ve z yönlerinde ağırlıklandırmak için kullanılır. "i1", fraktal dağılım için kullanılacak malzemelerin sayısıdır, "str1", materyali tanımlamak için kullanılır ve "str2", fraktal kutusunun kendisinin tanımlayıcısıdır. "[i2]", fraktallerin oluşturulması sırasında rastgele isteğe bağlı parametredir ve "[c1]", sadece y ve n değerlerini alan dielektrik ortam parametresidir.

- #waveform: str1 f1 f2 str2

Oluşturulan modelde kullanılması planlanan dalga formlarının oluşturmasını sağlar. "str1", dalga şeklini gösteren değişkendir. Gaussian dalga formu, Ricker dalga formu ve sürekli sinüs dalga formu modelde kullanılan bazı dalga şekillerindedir. "f1" parametresi kullanılan dalga formunun genliğinin ölçeklenmesini sağlar. "f2" parametresi kullanılan dalga formunun merkez frekansını gösterir. Birimi Hertz'dir. "str2" parametresi kullanılan kaynağın senaryo içerisinde tanımlayıcısıdır. "#waveform: gaussiandotnorm 1 1.2e9 my_gauss_pulse" normalize edilmiş türevli Gauss dalga formuna sahip ve 1.2 GHz'lik bir merkez frekanslı dalgayı belirtir.

- #hertzian_dipole: c1 f1 f2 f3 str1 [f4 f5]

Bu komutta "c1" kaynağın polarizasyonunu belirtir. Antenin konumu x, y veya z eksenlerinde bulunabilir. "f1 f2 f3" modelde bulunan kaynağın koordinatlarını belirtir. "f4 f5" isteğe bağlı kullanılan parametrelerdir. "f4" kullanılan kaynağın gecikme süresini gösterir. "f5" kaynağın senaryodan kaldırma zamanını belirtir. Eğer zaman penceresi kaynağın senaryodan kaldırılma zamanından daha uzunsa, kaynak kaldırma zamanı tamamlanmadan önce kaynak durdurulur. Senaryodan kaynak kaldırma süresi zaman penceresinden daha uzun olması durumunda kaynak zaman penceresi içerisinde aktif olarak çalışacaktır. "f4 f5" kullanılmadığı durumda kaynak zaman penceresi içerisinde aktif olarak çalışır. "str1", senaryo içerisinde kaynakla beraber kullanılan dalga formunun tanımlayıcısıdır. "#waveform: ricker 1 600e6 my_ricker_pulse" ve "#hertzian_dipole: x 0.05 0.05 0.05 my_ricker_pulse" komutlarında 600 MHz merkez frekansına sahip Ricker dalga formu ile x yönünde polarize olan Hertzian dipol antenin kullanılacağı belirtilmektedir.

- #rx: f1 f2 f3 [str1 str2]

Bu komut sayesinde senaryo içerisinde taramanın gerçekleştirileceği başlangıç ve bitiş noktalarının pozisyonlarının eklenmesini sağlar. "f1 f2 f3" modelde bulunan alıcı antenin x, y ve z eksenlerindeki koordinatlarıdır. "str1" alıcı antenin tanımlayıcısıdır. "str2" alıcı antenin değişkenini gösterir. Ex, Ey, Ez, Hx, Hy, Hz, Ix, Iy ve Iz büyüklüklerinden biri seçilebilir.

- #src_steps: f1 f2 f3 ve #rx_steps: f1 f2 f3

Senaryo içerisindeki tüm basit kaynakların (#src_steps) veya tüm alıcı antenlerin (#rx_steps) konumunun değişme miktarını gösterir. "f1 f2 f3" model içerisindeki tüm basit kaynakların (x, y, z) eksenlerinde adım miktarlarını göstermektedir.

- #cylinder: f1 f2 f3 f4 f5 f6 f7 str1 [c1]

Bu komut modele silindir yapılar eklemek için kullanılır. Silindirin yönü değiştirilebilir. Komutun sözdizimi şöyledir: "f1 f2 f3", silindirin bir yüzünün koordinatları (x, y, z) merkezidir ve "f4 f5 f6" diğer yüzünün merkez koordinatlarını belirtir. "f7", silindirin yarıçapı ve "str1" daha önce tanımlanmış olan malzeme tanımlayıcısıdır. "[c1]", sadece y ve n değerlerini alan dielektrik düzgünleştirme parametresidir. Örneğin, #cylinder: 0.5 0.1 0.5 0.5 0.8 0.5 0.1 pec, silindirin 0.7 m uzunluğunda ve mükemmel elektrik iletkeni olan 100 mm yarıçaplı y yönünde olduğu anlamına gelir.

- #box: f1 f2 f3 f4 f5 f6 str1 [c1]

Bu komut ile model içerisinde belirli özelliklere sahip dikdörtgen kesitli yapılar yerleştirmeye imkân tanınır. "f1 f2 f3", (x, y, z) eksenlerinde dikdörtgen kesitin sol alt koordinatlarıdır. "f4 f5 f6", (x, y, z) eksenlerinde dikdörtgen kesitin sağ üst koordinatlarıdır. "str1", model dosyasında önceden tanımlanmış olan malzemenin tanımlayıcısıdır. "c1", dielektrik düzgünleştirmesinin açılmasını ve kapatılmasını sağlayan isteğe bağlı parametredir. "#box: 0.5 0.5 0.5 0.7 0.8 0.5 pec" komutunda mükemmel iletken yapı x-y düzlemine yerleştirilmiştir.

- #triangle: f1 f2 f3 f4 f5 f6 f7 f8 f9 f10 str1 [c1]

Bu komut model içerisinde belirli özelliklere sahip üçgen kesitli yapı eklenmesini sağlar. "f1 f2 f3", (x, y, z) eksenlerinde üçgen kesitin ilk köşe koordinatları, "f4 f5 f6" ikinci köşe koordinatları, "f7 f8 f9" üçüncü köşe koordinatlarıdır. "f10", üçgen prizmanın kalınlığını gösterir. Kalınlığın sıfır olması durumunda üçgen kesitli yapıyı oluşturur. "str1", girdi model dosyası içerisinde önceden tanımlanmış olan malzemenin tanımlayıcısıdır. "c1", dielektrik düzgünleştirmesinin açılmasını ve kapatılmasını sağlayan isteğe bağlı parametredir. "#triangle: 0.5 0.5 0.5 0.6 0.4 0.5 0.7

0.9 0.5 0.0 pec", mükemmel bir elektrik iletken malzemeye sahip olan xy düzleminde üçgen kesitli bir yapıdır.

3.3.2. GprMax yazılımı için simülasyon örneği

Bu örnek, toprak içerisinde gömülü metal bir silindir için oluşturulmuştur. GPR B tarama görüntüsünü GprMax'ta oluşturmak için model giriş dosyası "cylinder_Bscan_2D.in" adıyla Şekil 3.8'de gösterilmiştir. Bu model dosyası Not Defteri ile oluşturulabilir.

```

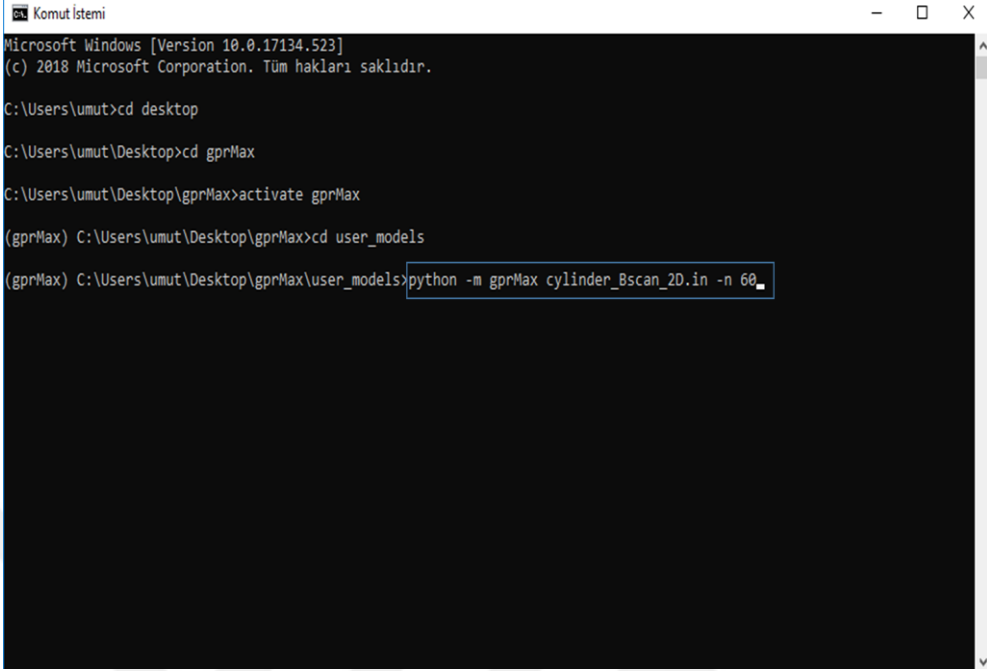
1 #title: B-scan from a metal cylinder buried in a dielectric half-space
2 #domain: 0.240 0.210 0.002
3 #dx_dy_dz: 0.002 0.002 0.002
4 #time_window: 3e-9
5
6 #material: 6 0 1 0 half_space
7
8 #waveform: ricker 1 1.5e9 my_ricker
9 #hertzian_dipole: z 0.040 0.170 0 my_ricker
10 #rx: 0.080 0.170 0
11 #src_steps: 0.002 0 0
12 #rx_steps: 0.002 0 0
13
14 #box: 0 0 0 0.240 0.170 0.002 half_space
15 #cylinder: 0.120 0.080 0 0.120 0.080 0.002 0.010 pec
16

```

Şekil 3.8. GprMax için örnek giriş model dosyası

Bu giriş dosyasında "rx_steps", kaynağı çalıştırmak için modelde tarama adımını gösterir. Bu sayede her çalışmada modelde bulunan alıcı ve verici antenlerin 2 mm hareket ettiği anlamına gelir. A-taraması tek bir adımda gerçekleştirilirken B-taramasını oluşturmak için anten alanın büyüklüğü içinde hareket ettirilmelidir. Örnek olarak, 120 mm'lik bir mesafeden B taraması görüntüsü elde etmek için, tarama adım boyutu 2 mm olduğundan 60 adet A taramasının elde edilmesi gerekir. Modeli çalıştırmak için gereken komutlar Şekil 3.9'da GprMax simülasyon programından ekran görüntüsü

alınarak gösterilmiştir. Programı çalıştırmak için, GprMax komut penceresinden etkinleştirilmelidir.



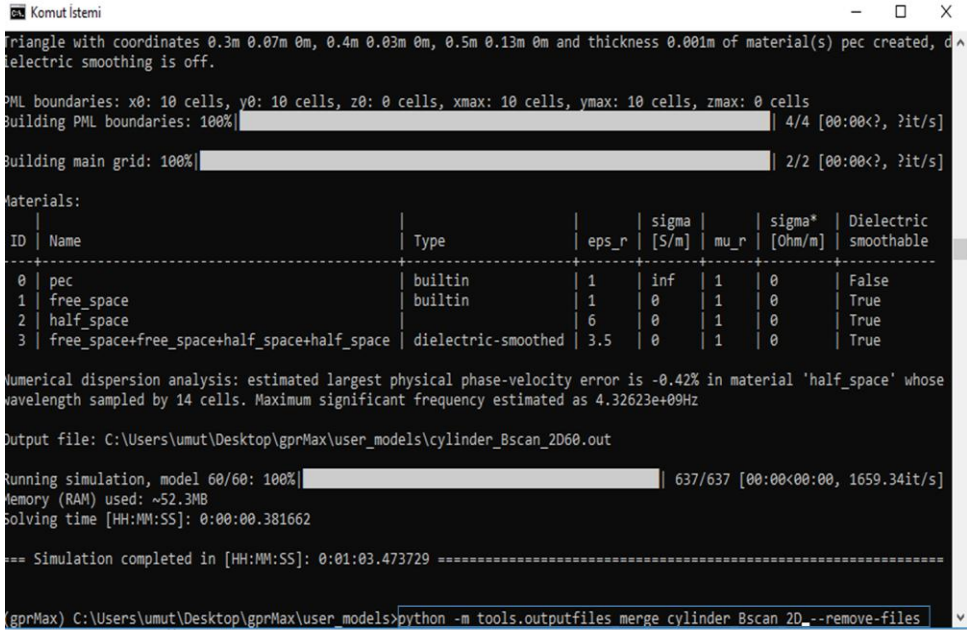
```

Komut İstemi
Microsoft Windows [Version 10.0.17134.523]
(c) 2018 Microsoft Corporation. Tüm hakları saklıdır.

C:\Users\umut>cd desktop
C:\Users\umut\Desktop>cd gprMax
C:\Users\umut\Desktop\gprMax>activate gprMax
(gprMax) C:\Users\umut\Desktop\gprMax>cd user_models
(gprMax) C:\Users\umut\Desktop\gprMax\user_models>python -m gprMax cylinder_Bscan_2D.in -n 60_
  
```

Şekil 3.9. Antenlerin 2 mm adımla 60 kez hareket ettirilmesi

Komut GprMax simülasyon programında çalıştığında, A taramalarına karşılık gelen 60 adet çıkış üretir. GPR B taramasını oluşturmak için bu A taramalarının birleştirilmesi gerekir. Tüm A taramalarını tek bir dosyada birleştirme komutu Şekil 3.10'da verilmiştir.



```

Komut İstemi
triangle with coordinates 0.3m 0.07m 0m, 0.4m 0.03m 0m, 0.5m 0.13m 0m and thickness 0.001m of material(s) pec created, dielectric smoothing is off.

PML boundaries: x0: 10 cells, y0: 10 cells, z0: 0 cells, xmax: 10 cells, ymax: 10 cells, zmax: 0 cells
Building PML boundaries: 100% | 4/4 [00:00<?, ?it/s]
Building main grid: 100% | 2/2 [00:00<?, ?it/s]

Materials:
ID | Name | Type | eps_r | sigma [S/m] | mu_r | sigma* [Ohm/m] | Dielectric smoothable
-----|-----|-----|-----|-----|-----|-----|-----
0 | pec | builtin | 1 | inf | 1 | 0 | False
1 | free_space | builtin | 1 | 0 | 1 | 0 | True
2 | half_space | dielectric-smoothed | 6 | 0 | 1 | 0 | True
3 | free_space+free_space+half_space+half_space | dielectric-smoothed | 3.5 | 0 | 1 | 0 | True

Numerical dispersion analysis: estimated largest physical phase-velocity error is -0.42% in material 'half_space' whose wavelength sampled by 14 cells. Maximum significant frequency estimated as 4.32623e+09Hz

Output file: C:\Users\umut\Desktop\gprMax\user_models\cylinder_Bscan_2D60.out

Running simulation, model 60/60: 100% | 637/637 [00:00<00:00, 1659.34it/s]
Memory (RAM) used: ~52.3MB
solving time [HH:MM:SS]: 0:00:00.381662

== Simulation completed in [HH:MM:SS]: 0:01:03.473729 =====
(gprMax) C:\Users\umut\Desktop\gprMax\user_models>python -m tools.outputfiles.merge cylinder_Bscan_2D_--remove-files
  
```

Şekil 3.10. GPR B taramasını oluşturmak için 60 adet a taramasını birleştirme komutu

GPR A taramasının tek bir dosyada birleştirilmesinden sonra, B-taraması sonucu Şekil 3.11'deki komut kullanılarak görülebilir. Komutun görsel çıktısı, Şekil 3.12'de verilmiştir.

```

Komut İstemi
PML boundaries: x0: 10 cells, y0: 10 cells, z0: 0 cells, xmax: 10 cells, ymax: 10 cells, zmax: 0 cells
Building PML boundaries: 100% | 4/4 [00:00<?, ?it/s]
Building main grid: 100% | 2/2 [00:00<?, ?it/s]

Materials:
ID | Name | Type | eps_r | sigma [S/m] | mu_r | sigma* [Ohm/m] | Dielectric smoothable
-----|-----|-----|-----|-----|-----|-----|-----
0 | pec | builtin | 1 | inf | 1 | 0 | False
1 | free_space | builtin | 1 | 0 | 1 | 0 | True
2 | half_space | builtin | 6 | 0 | 1 | 0 | True
3 | free_space+free_space+half_space+half_space | dielectric-smoothed | 3.5 | 0 | 1 | 0 | True

Numerical dispersion analysis: estimated largest physical phase-velocity error is -0.42% in material 'half_space' whose wavelength sampled by 14 cells. Maximum significant frequency estimated as 4.32623e+09Hz

Output file: C:\Users\umut\Desktop\gprMax\user_models\cylinder_Bscan_2D60.out


Running simulation, model 60/60: 100% | 637/637 [00:00<00:00, 1659.34it/s]
Memory (RAM) used: ~52.3MB
Solving time [HH:MM:SS]: 0:00:00.381662

=== Simulation completed in [HH:MM:SS]: 0:01:03.473729 ===

(gprMax) C:\Users\umut\Desktop\gprMax\user_models>python -m tools.outputfiles_merge cylinder_Bscan_2D --remove-files
(gprMax) C:\Users\umut\Desktop\gprMax\user_models>python -m tools.plot_Bscan cylinder_Bscan_2D_merged.out Ez

```

Şekil 3.11. GPR B taramasını görüntü olarak gösterme komutu



Şekil 3.12. Elde edilen GPR B taramasının görüntüsü


3.3.3. Tez çalışması kapsamında yaralanılan simülasyon ve gerçek veri setleri

GPR performansını etkileyebilecek en önemli parametreler gömülü nesnenin dielektrik sabiti ve elektriksel iletkenliğidir. Aynı zamanda, toprak tipi GPR performansını etkileyen ana unsurlardan biridir. Çünkü daha iletken bir toprak (daha ıslak veya daha fazla kil içeriğine sahip olan), kuru kum gibi düşük iletken bir toprakla karşılaştırıldığında daha fazla enerji soğurur. Gömülü malzemenin yüksek iletkenliği GPR sinyalinin zayıflamasına neden olur. Bir diğer önemli faktör de gömülü hedefin bulunduğu derinliktir.

3.3.3.1. Birinci veri seti


Tez çalışmasında kullanılmak üzere GprMax programını kullanarak birbirinden farklı özelliklerde iki ayrı veri seti üretilmiştir. Birinci veri seti 2630×1437 boyutlarında 180 adet GPR B-tarama görüntülerinden oluşmaktadır. Veri seti oluşturulurken iki farklı malzeme çeşidi ve iki farklı şekil kullanılmıştır. Malzeme olarak mükemmel iletken ve naylon; şekil çeşidi olarak ise dikdörtgen ve dairesel geometriler kullanılmıştır. Malzemelerin elektriksel özellikleri Çizelge 3.2'de verilmektedir.

GprMax'dan elde edilen senaryo çıktıları Matlab programı kullanılarak tekrardan çizdirilmiştir. Şekil 3.13'deki GPR B-tarama görüntüleri incelendiğinde, gömülü malzemelerin şekillerine bağlı olarak farklı desenler görülmektedir. Bu görüntüler bilgisayar tarafından çeşitli algoritmalar ile değerlendirilebilir ve gömülü nesnelerin özellikleri yorumlanabilir. Ancak, gömülü olan her cismin kendine özgü özellikleri bulunduğundan GPR B-tarama görüntüsünde farklı yansımalar oluşabilir.



Şekil 3.13. GprMax programı kullanılarak elde edilen GPR B tarama görüntüleri

Gömülü nesnelere şekil bakımından değerlendirildiğinde senaryolar içerisinde dikdörtgen, silindirik ve üçgen kesitli yapılar kullanılmıştır. Aynı zamanda gömümü nesnelere naylon, silikon, mükemmel iletken, tahta ve alüminia olmak üzere 5 farklı malzemeden oluşmaktadır. Genel olarak, GPR B-tarama görüntüleri incelendiğinde zemin düzlemi ve farklı yansımalar görülebilir. Bu yansılardan dolayı, farklı nesnelere algılanması veya yanlış alarm durumu ortaya çıkabilir. Bu yansımaların oluşumu gömülü malzemelerin kalınlığından kaynaklanır. Ayrıca, birden fazla gömülü nesne tarafından oluşturulan örüntülerin kesişmesi, yanlış alarm durumunun oluşmasında diğer bir faktördür.



Şekil 3.14. Yanlış alarm içeren GPR B tarama görüntüleri a) Malzemenin et kalınlığından kaynaklanan yansımalar b) Gömülü cisimlerin oluşturduğu desenlerin birbiri ile karışması

3.3.3.2. İkinci veri seti

Oluşturulan ikinci veri setinde toplamda 1070 adet GPR B tarama görüntüsü üretilmiştir. Bu görüntüler üzerine veri artırım yöntemleri uygulanmıştır. Veri artırım yöntemleri sonucunda toplamda 4280 adet GPR B tarama görüntüsü elde edilmiştir. Bu veri setindeki GPR B tarama görüntülerinde, tek bir gömülü cisim bulunmaktadır. Veri seti oluşturulurken üç farklı toprak çeşidi, beş farklı malzeme çeşidi ve üç farklı şekil kullanılmıştır. Toprak çeşidi olarak ıslak, nemli ve kuru toprak kullanılarak toprağın elektriksel özellikleri değiştirilmiştir. Malzeme olarak alüminia, naylon, mükemmel iletken, tahta ve silikon kullanılmıştır. Şekil olarak dikdörtgen, üçgen ve dairesel kesitlere sahip gömülü nesnelere oluşturulan ortam içerisinde bulunmaktadır. Gömülü malzemeler toprak türünü göre seçilmiştir. Malzeme ve toprak ortamının elektriksel özellikleri olabildiğince farklılaştırılarak GPR B tarama görüntülerinde hiperbolik

desenlerin oluşması sağlanmıştır. Kullanılan toprak ve malzeme çeşitlerinin elektriksel özellikleri sırasıyla Çizelge 3.1 ve Çizelge 3.2’de verilmiştir.


Çizelge 3.1. Senaryoda kullanılan toprak nesnelerin elektriksel özellikleri

Toprak Cinsi	Dielektrik Katsayısı (ϵ_r)	İletkenlik (σ)
Islak Toprak	20	0.1
Kuru Toprak	3	0.001
Nemli Toprak	8	0.01

Çizelge 3.2. Senaryoda kullanılan gömülü nesnelerin elektriksel özellikleri

Malzeme Cinsi	Dielektrik Katsayısı (ϵ_r)	İletkenlik (σ)
Alüminia	9.3	0.27
Naylon	5	0.01
Mükemmel İletken	1	10^6
Silikon	11	0.0015
Tahta	2.2	0.01

Bu veri setinin oluşturduğu zorluklardan biri farklı toprak ortamlarında farklı derinlikte bulunan farklı malzemelerin aynı örüntülere sahip olabilmesidir. Aynı zamanda toprağın nemlilik durumu değiştiğinde GPR cihazının algılama derinliği düşeceğinden dolayı bazı malzemeler farklı örüntülere sahip olabilmektedir. Bu veri setine ait B-tarama görüntüler Şekil 3.15’de verilmiştir.



Şekil 3.15. a) Toprak Türü: Nemli Toprak, Malzeme Türü: Mükemmel İletken, Şekil Türü: Dikdörtgen Kesitli b) Toprak Türü: Kuru Toprak, Malzeme Türü: Tahta, Şekil Türü: Dairesel Kesitli c) Toprak Türü: Islak Toprak, Malzeme Türü: Naylon, Şekil Türü: Dairesel Kesitli d) Toprak Türü: Kuru Toprak, Malzeme Türü: Silikon, Şekil Türü: Üçgen Kesitli e) Toprak Türü: Kuru Toprak, Malzeme Türü: Alüminia, Şekil Türü: Dairesel Kesitli


3.3.3.3. Üçüncü veri seti

Tez kapsamında kullanılan üçüncü veri seti Trento Üniversitesi, Bilgisayar ve Bilgi Teknolojileri Bölümünde görev alan Doç. Dr. Farid Melgani ve Doç. Dr. Massimo Donelli tarafından temin edilmiştir. Veri seti tamamıyla gerçek GPR B tarama görüntülerinden oluşmaktadır. Veri seti, üç adet birbirinden farklı markalara sahip GPR


cihazları ile sahada tarama yapılmasıyla elde edilmiştir. GPR cihazlarını birbirinden ayırmak adına GPR 1, GPR 2 ve GPR 3 olarak adlandırılmıştır. GPR 1 cihazı ABD yapımı olup Geophysical Survey Systems, Inc (GSSI) firması tarafından üretilmiştir. GPR 2 cihazı İsveç yapımı olup MALA firması üretimini yapmıştır. Son olarak ise GPR 3 cihazı İtalyan yapımı olup Ingegneria Dei Sistemi (IDS) firması tarafından kullanıma sunulmuştur. Bu cihazların tarama frekansları dikkate alındığında 200 MHz, 250 MHz, 270 MHz, 350 MHz, 400 MHz, 500 MHz, 600 MHz, 800 MHz ve 900 MHz frekansları kullanılmıştır. Tarama işleminin yapıldığı dört farklı saha belirlenmiştir. Bu sahalarda alüvyon (Silt), kireçli (Limestone), Gneiss 14/20 ve Gneiss 0/20 toprak yapıları bulunmaktadır. Bu toprak çeşitleri birbirinden farklı elektriksel özelliklere sahiptirler. Alüvyonlu toprağın sahip olduğu dielektrik sabiti $\epsilon_r=13$ olarak tespit edilmiştir. Sahada kullanılan EM dalga zayıflamasının 15 ile 45 dB/m arasında olduğu belirlenmiştir. GPR cihazının alt frekansında nüfuz derinliği 1.5 m iken üst frekansında iken nüfuz derinliği 1 m'ye kadar düşmektedir. Kireçli toprak yapısının tespit edilen dielektrik sabiti $\epsilon_r=6$ 'dır. EM dalganın zayıflaması 6 ile 20 dB/m arasındadır. Alt frekans için GPR cihazının nüfuz etme derinliği 1.5 m iken üst frekans için 1 m'dir. Gneiss 14/20 sahasında belirlenen dielektrik sabiti $\epsilon_r=3$ 'tür. EM dalga zayıflaması 1.5 ile 4.5 dB/m arasında gerçekleşmektedir. Bu sahada mevcut GPR cihazları en az 4.5 m nüfuz etme derinliğine sahiptir. Gneiss 14/20 test sahasında elde edilen dielektrik sabiti $\epsilon_r=5.5$ 'tir. Sinyal zayıflaması 9 ile 27 dB/m arasında oluşur. Alt frekans için GPR cihazının nüfuz etme derinliği 2.5 m iken üst frekansta bu değer 1.5 m'ye kadar düşmektedir (Derobert ve Pajewski, 2018). Tanımlanan bu veri setinde toplamda 8505 adet GPR B tarama görüntüsü bulunmaktadır. Çizelge 3.3 'de GPR cihazlarının tarama yapabileceği frekanslar verilmiştir. Veri setindeki bazı GPR B tarama görüntüleri özellikleri ile beraber Şekil 3.16'da gösterilmiştir.

Çizelge 3.3. Tarama işlemi için kullanılan GPR cihazlarının Frekans özellikleri


GPR Çeşidi	Tarama Frekansları (MHz)
GPR 1	200, 270, 350, 400, 500, 900
GPR 2	250, 500, 800
GPR 3	200, 600, 900




a)




b)




c)



d)



e)




f)

Şekil 3.16. a) Cihaz Türü: YNR 3 Cihazı, Tarama Frekansı: 200 MHz, Toprak Çeşidi: Kireçli Toprak b) Cihaz Türü: YNR 2 Cihazı, Tarama Frekansı: 250 MHz, Toprak Çeşidi: Kireçli Toprak c) Cihaz Türü: YNR 2 Cihazı, Tarama Frekansı: 250 MHz, Toprak Çeşidi: Alüvyonlu Toprak d) Cihaz Türü: YNR 2 Cihazı, Tarama Frekansı: 250 MHz, Toprak Çeşidi: Gneiss 14_20 e) Cihaz Türü: YNR 1 Cihazı, Tarama Frekansı: 400 MHz, Toprak Çeşidi: Gneiss 0_20 f) Cihaz Türü: YNR 1 Cihazı, Tarama Frekansı: 270 MHz, Toprak Çeşidi: Gneiss 0_20

3.3.3.4. Dördüncü veri seti

Tez kapsamında kullanılan dördüncü veri seti Konya Teknik Üniversitesi, Maden Mühendisliği Bölümünde görev alan Arş. Gör. Mehmet Uzbaşı tarafından temin edilmiştir. Veri setinde toplamda 39 adet GPR B tarama görüntüsü mevcuttur. Beton blokların GPR cihazı ile taranması sonucunda görüntüler oluşturulmuştur. Bu tarama işlemi beton bloklar içerisindeki oyuk yerlerin tespiti için gerçekleştirilmiştir. Mevcut görüntü sayısına göre 31 adet GPR B tarama görüntüsü eğitim için 8 adet GPR B tarama görüntüsü de test işlemi için ayrılmıştır (Uzbaşı, 2016). Şekil 3.17’de kullanılan dördüncü veri setinden örnek verilmiştir.



Şekil 3.17. İçerisinde oyuklar bulunan beton bloklardan elde edilen GPR B tarama görüntü örneği


Tez kapsamında kullanılan veri setlerinde farklı problemlere derin öğrenme yöntemleri ile çözüm bulunmaya çalışılmıştır. Birinci veri setinde çözülmesi gereken iki temel problem mevcuttur. Bu problemler, malzeme kalınlığından kaynaklanan harici yansımalar ve birbirine yakın çoklu gömülü nesnelerin tarama desenlerinin çakışmasıdır. Bu problemler görüntü içinde yanlış alarm durumuna sebep olmaktadır. İkinci veri setinde ise temel problem farklı gömülü nesnelere farklı toprak sahalarında aynı hiperbolik desene sahip olabilmektedir. Aynı zamanda gömülü nesnelerin algılanamaması söz konusudur. Üçüncü veri setinde farklı GPR cihazı ve farklı frekanslarda tarama yapılan farklı toprak sahaları aynı özellikler sergileyebilmektedir. Bu problem toprak çeşidinin doğru bir şekilde belirlenmesini etkilemektedir. Dördüncü veri setinde ise beton bloklar içerisinde meydana gelen oyuk veya çatlakların belirlenmesi oldukça zor bir problemdir. Veri setlerinde bulunan farklı problemlerin çözümü için derin öğrenme yöntemlerinden faydalanılmıştır.

3.4. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insanların merkezi sinir sistemlerindeki biyolojik sinir ağlarından esinlenen bir modeldir. YSA regresyon ve sınıflandırma problemlerinde oldukça yaygın olarak kullanılır. Bu kısımda YSA kavramlarının genel bir değerlendirmesi sunulmakta ve günümüzde en yaygın kullanılan teknikler ve terimler vurgulanmaktadır.

3.4.1. Yapay sinir

Yapay bir sinir, yapısında girdiler, bias ve çıktı değerinden oluşur. Çıkış değerleri üzerinde aktivasyon fonksiyonu uygulanarak ağda gerçekleşebilecek doğrusallık durumu giderilebilir. Aktivasyon fonksiyonu olarak genellikle sigmoid çıkışı veya Rektifiye Edilmiş Doğrusal Birim (REDB) tercih edilir. Şekil 3.18 yapay bir sinir modelini ve bağlantılarını göstermektedir.

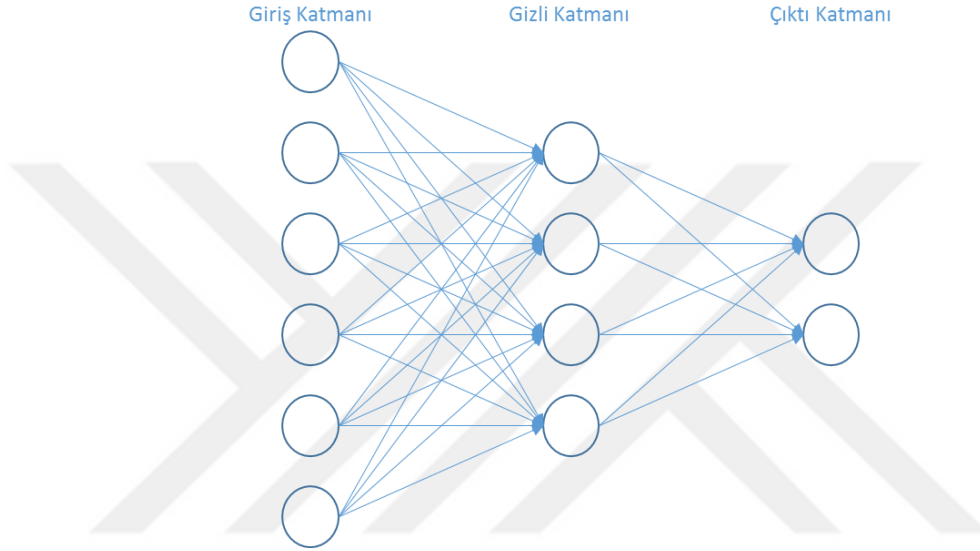


Şekil 3.18. Bir yapay sinir modeli

Bir yapay sinirin çıkışı, ağırlıklı girdilerin ve bias değerinin toplam bir fonksiyonu olarak hesaplanır. Eğer ağırlıklı toplam $z = \sum w_j \cdot x_j + b$ ve yapay sinir değerlendirme fonksiyonu σ olarak tanımlanırsa, o zaman $\sigma = \sigma(z)$ ifadesi ilgili yapay sinirin çıktısıdır.

3.4.2. Çok katmanlı yapay sinir ağları

Çok katmanlı ağlar, katmanlı bir şekilde bir araya gelen birçok yapay sinirden oluşur. İlk katmana girdi katmanı, son katmana ise çıktı katmanı adı verilir. Ara katmanlar ise gizli katmanlar olarak tanımlanır. Gizli katmanları sayesinde doğrusal olarak ayırlamayan verilerin ayırt edilebilmesi mümkündür. Şekil 3.19’da üç katmanlı yapay sinir ağının genel görünümü bulunmaktadır.



Şekil 3.19. Üç katmanlı yapay sinir ağı yapısı

Gizli katmanların sayısı ve gizli katmanlardaki düğüm sayısı çok katmanlı yapay sinir ağı tasarımında önemli sorunlardandır. Literatürde, gizli katmanların sayısını belirlemek için genel bir formül bulunmamaktadır. Elde edilen tecrübeler gizli katmanların sayısının artırılmasının eğitim hatasını azaltabileceğini, ancak algoritmanın karmaşıklığını artırdığını ve sistemin genelleme yeteneğinin azalmasına neden olduğunu göstermektedir. Ayrıca, gizli katmanların sayısı arttıkça, sistemin ağırlıklarını güncelleyemediği ve daha fazla yerel minimum noktalarına takıldığı gözlemlenmiştir. Öte yandan, bu katmanlardaki gizli katman ve düğümlerin sayısı sistem için yeterli değilse, modelin düzgün çalışmadığı görülmüştür. Gizli katman sayısında olduğu gibi gizli katmandaki düğüm sayısının belirlenmesi de başka bir tasarım konusudur. Çok fazla sayıda düğümün olması yapay sinir ağının eğitim süresini daha uzun hale getirecek ve ağın genelleme yeteneğinin kaybolmasına sebep olacaktır. Düğüm sayısının az olduğu durumda ise yapay sinir ağı çok az sayıda bilgi kullanmasından


dolayı karmaşık modelleri çözemeyecektir. Bu parametreler, eğitim sonuçlarına göre eğitim sürecinde belirlenir.

Çok katmanlı yapay sinir ağlarında düğümlerdeki aktivasyon fonksiyonları genellikle doğrusal olmayan fonksiyonlardan seçilir. Yaygın olarak kullanılan aktivasyon fonksiyonları sigmoid, tanh ve rektifiye edilmiş doğrusal birimdir.

Sigmoid aktivasyon fonksiyonu literatürde log-sigmoid veya lojistik fonksiyon olarak da bilinir. Sigmoid fonksiyonu Eşitlik 3.23'de gösterilmiştir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.23)$$

Şekil 3.20'de sigmoid aktivasyon fonksiyonunun grafiksel olarak gösterimi bulunmaktadır.




Şekil 3.20. Sigmoid fonksiyonu

REDB aktivasyon fonksiyonu Eşitlik 3.24'de matematiksel olarak ifade edilmiştir.

$$\sigma(x) = \max(0, x) \quad (3.24)$$

Şekil 3.21'de görüldüğü üzere REDB aktivasyon işleminden geçen yapay sinirler herhangi bir doygunluğa sahip olmamaktadır.




Şekil 3.21. REDB fonksiyonu

Tanh doğrusal olmayan aktivasyon fonksiyonunun formülü Eşitlik 3.25’de verilmiştir.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (3.25)$$

Şekil 3.22’de Tanh aktivasyon fonksiyonunun grafiksel gösterimi verilmiştir. Bu gösterimde Tanh aktivasyon fonksiyonu negatif ve pozitif bölgelerde doyuma ulaşabilmektedir.




Şekil 3.22. Tanh fonksiyonu

3.4.3. Geri yayılım algoritması

Çok katmanlı yapay sinir ağının eğitim sürecinde ileri besleme ve geri yayılım olmak üzere iki temel işlem bulunmaktadır. Yapay sinir ağının eğitim sürecinde ilk olarak yapay sinir ağı içerisinde bulunan ağırlık ve bias değişkenlerine başlangıç değerleri atanır. Sonrasında her örnek için ileri besleme adımı uygulanarak ağda bulunan düğüm çıkışları hesaplanır. Bu hesaplamalar tamamlandıktan sonra geri yayılım algoritması ile ağırlık ve bias değerleri güncellenir. Bu işlemler optimum çözümü yakınsayıncaya kadar birbirini takip eder.

3.4.3.1. İleri besleme adımı

İleri besleme adımında Şekil 3.23’de görüldüğü üzere düğümler, kendilerine karşılık gelen ağırlıklar ile çarpılır ve sonuçlar toplanarak bias değeri eklenmesi yapılır. Elde edilen sonuç toplamı, doğrusal olmayan bir aktivasyon fonksiyonunda işlenir. Aktivasyon fonksiyonunun çıkışı bu düğümün değeri haline gelir. Bu işlem giriş düğümlerinden başlayarak çıkış katmanındaki düğüm değerleri hesaplanana kadar tüm düğümlere uygulanır.



Şekil 3.23. İleri Besleme Adımı

3.4.3.2. Geri yayılım adımı

İleri besleme adımı tamamlandığında, gerçek çıktı değerleri ile hesaplanan çıktı değerleri arasında bir fark vardır. Bu iki çıktı değeri arasındaki farkı hesaplayarak öngörülen hata, çıktı katmanında kolayca hesaplanabilir. Ancak, iç katmanlardaki hatayı hesaplamak oldukça zordur. İç katmanlardaki hata hesaplanamıyorsa, ağırlıkların güncellenmesi mümkün değildir. Uzun yıllar boyunca, iç düğümlerdeki hatayı

hesaplamak için etkili bir yöntem geliştirilememiştir. Pantic ve ark. geri yayılım adımını kullanarak gerçek çıkış değeri ile hesaplanan çıkış değeri arasındaki hatayı en aza indirmek amacıyla ağıdaki bağlantıların ağırlıklarını tekrar tekrar ayarlayan yeni bir algoritma önerdiler (Pantic ve Rothkrantz, 2004). Bu işlem sırasında, iç katmanlardaki düğümlerin belirli kalıpları öğrenilmesi mümkün olabilmektedir.

Bu algoritma aynı zamanda herhangi bir ağırlığın toplam hata üzerine etkisini de araştırır. Hata bazen kayıp veya maliyet olarak da adlandırılır. Bu bilgiyi elde etmek amacıyla yapay sinir ağındaki ağırlıkları ile ilgili toplam hatanın türevi hesaplanmalı ve ağırlıklar bu bilgilere göre güncellenmelidir. Gradyan Azalış algoritmasında Eşitlik 3.26 ile basit bir şekilde ağırlıkların güncellenmesi gerçekleştirilir.

$$w_{ij}^+ = w_{ij} - \alpha \frac{\partial E}{\partial w_{ij}} \quad (3.26)$$

Eşitlik 3.26'da E ifadesi hatayı belirtirken, w_{ij} mevcut ağırlığı gösterir. α öğrenme oranı katsayısı ve w_{ij}^+ güncellenen yeni ağırlıktır. Hata minimum değere ulaşana kadar algoritma tarafından ağırlıklar güncellenir. Bu denklemdeki en zor işlem ise türev işleminin hesabıdır. Düğümlerde aktivasyon fonksiyonu olarak sigmoid fonksiyonu ve çıkış düğümündeki karesel hatanın kullanıldığı üç katmanlı bir sinir ağı yapısı düşünüldüğünde Eşitlik 3.27 kullanılır.

$$E = \frac{1}{2}(t - y)^2 \quad (3.27)$$

E karesel hatayı gösterirken, t eğitim örneğinin gerçek çıktısını ifade eder. y mevcut ağırlıklara göre hesaplanan çıkış değeridir.


$$\frac{\partial E}{\partial w_{ij}} = o_i \delta_j \quad (3.28)$$

$$\delta_j = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial a\check{g}_j} \quad (3.29)$$

$$\delta_j = \begin{cases} (o_j - t_j)o_j(1 - o_j) & \text{Eğer } j \text{ yapay sinirin çıkışı ise} \\ (\sum_{i \in L} \delta_i w_{ji})o_j(1 - o_j) & \text{Eğer } j \text{ yapay sinirin girişi ise} \end{cases} \quad (3.30)$$

Eşitliklerdeki o_i ve o_j değişkenleri çıkışları belirtirken $a\check{g}_j$ yapay sinirlerin giriş değeridir.

Eşitlik 3.24'de bir çıktı ağırlığının güncellemesi için gereken işlemler görselleştirilmiştir. Algoritmada ana düşünce zincir kuralını kullanarak ağırlıklara bağlı olarak hatanın türevini elde etmektir.



Şekil 3.24. Zincir kuralı

3.4.3.3. Geri yayılım algoritmasının özellikleri

Geri yayılım algoritması, küresel minimuma yakınsamayı her zaman garanti etmez. Eğitim sürecinde çeşitli yerel minimumlar olabilir ve bu alanlarda eğitim sürecinde takılmalar yaşanabilir.

Yakınsamayı optimize etmenin yollarından biri de uyarlamalı öğrenme oranını kullanmaktır. Başlangıçlardaki salınımlardan kaçınmak amacıyla öğrenme oranı yüksek bir değerle başlatılır ve süreç boyunca kademeli olarak azaltılır. Uygulanan uyarlanabilir öğrenme hızı teknikleri ile algoritmanın küresel minimuma yakınsama ihtimali artırılabilir.

Yaygın olarak kullanılan daha ileri bir yöntem ise momentum sabiti kullanmaktır. Bu yöntem dağdan aşağı yuvarlanan top fikrinden esinlenmiştir. Topun mevcut hızı da kendi momentumuyla belirlenir. Örneğin, bir dağdan aşağı yuvarlanan bir top yerel minimum noktasına takılmaz. Çünkü hızı yalnızca bulunduğu noktanın eğimine bağlı değildir. Topun önünde bir tepe olsa da elde ettiği hız nedeniyle tepeyi aşabilir.

Momentum sabiti, Eşitlik 3.31’de olduğu gibi öğrenme sürecine eklenebilir.

$$\Delta w_{ij}(t) = -\alpha \frac{\partial E}{\partial w_{ij}} + \gamma \Delta w_{ij}(t-1) \quad (3.31)$$

γ momentum oranının etkisi bir önceki iterasyondaki ağırlıklara $\Delta w_{ij}(t-1)$ yansıtılır. Eşitlikte momentum sabitinin kullanılması ile yerel minimumlara takılma olasılığının önüne geçilmiş olunur.

Hofmann ve ark. tarafından önerilen Adaptif Gradyan algoritmasında uyarlamalı bir öğrenme oranı kullanmışlardır (Hofmann ve ark., 2008). Bu strateji genellikle standart Gradyan Azalış algoritması üzerindeki küresel minimuma yakınsamayı geliştirir.

t iterasyonu anındaki w_{ij} ağırlıklarının türevi Eşitlik 3.32’deki gibi tanımlanır.

$$g_{t,i,j} = \frac{\partial E}{\partial w_{t,i,j}} \quad (3.32)$$

Adaptive Gradient Algoritmasında öğrenme katsayısı α , G katsayısı ile modifiye edilmiştir.

$$G = \sum_{t=1}^T g_{t,i,j} \quad (3.33)$$

$$w_{ij}^+ = w_{ij} - \frac{\alpha}{\sqrt{G}} g_{t,i,j} \quad (3.34)$$

G değişkeni t zaman adımlarında ağırlıklara bağlı olarak gradyanların karelerinin toplamına eşittir. Adaptif Gradyan Algoritmasının sağlamış olduğu temel katkı öğrenme oranının otomatik bir şekilde güncellenmesidir. Aynı zamanda bu algoritma ağırlıkların etkilerini dikkate alarak güncellemeyi büyük ya da küçük miktarda gerçekleştirir. Dezavantajı ise eğitim süresi boyunca karesel gradyanın giderek artmasıdır. Bu durum öğrenme oranının düşmesine neden olur.

Adaptif Gradyan algoritmasında kullanılan Kök Ortalama Karesel Hata Olasılığı (Root Mean Squared Error Probability – RMSProb) yaklaşımı ağırlıkların doğru bir şekilde güncellenmesinde çok etkili bir yöntemdir. Chen ve ark. tarafından öne sürülen bu yaklaşım uyarlamalı bir öğrenme oranı uygular (Chen ve ark., 2012). RMSProb yöntemi ile Adaptif Gradyan algoritmasında öğrenme oranının monoton bir şekilde azalmaması sağlanır. Yöntemdeki temel fikir, öğrenme oranını sabit ve üssel olarak azalan karesel gradyanlarının ortalamasına bölmektir.

$$M(t) = \vartheta M(t-1) + (1 - \vartheta)G \quad (3.35)$$

$$w_{ij}^+ = w_{ij} - \frac{\alpha}{\sqrt{M(t)}} g \quad (3.36)$$

Eşitlik 3.35’de kullanılan ϑ değişkeni bozulma oranını belirtir. Kingma ve ark. tarafından önerilen Adaptive Moment Estimation (Adam) adı verilen uyarlamalı öğrenme algoritması RMSProb ve momentum yaklaşımının birleşiminden oluşmaktadır (van der Walt ve ark., 2011).

$$m(t) = \beta_1 m(t-1) + (1 - \beta_1) \frac{\partial E}{\partial w_{ij}} \quad (3.37)$$

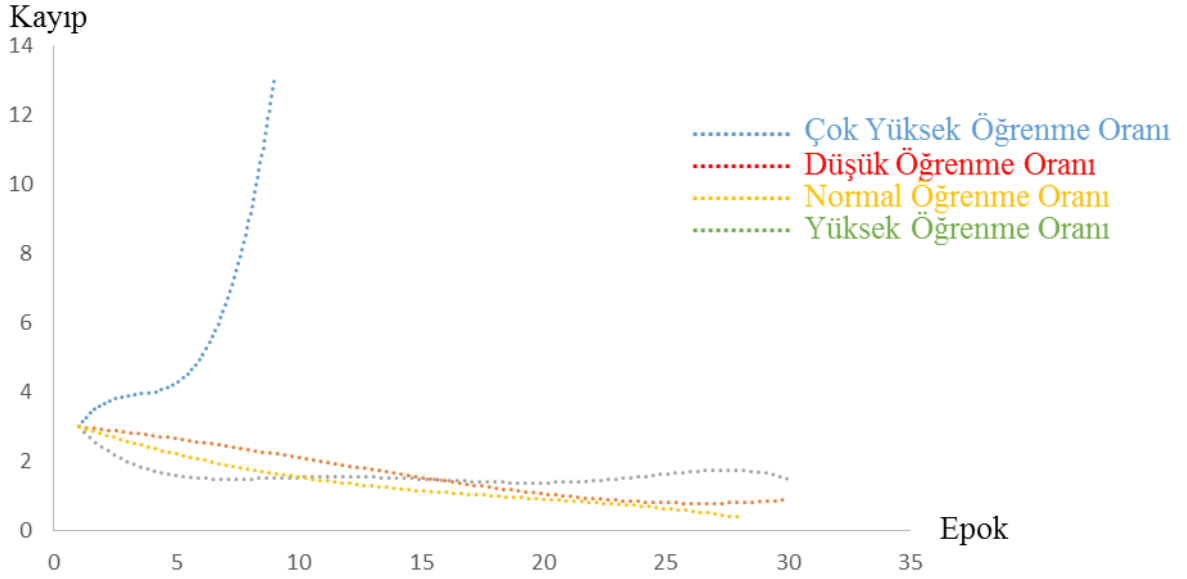
$$v(t) = \beta_2 v(t-1) + (1 - \beta_2) \left(\frac{\partial E}{\partial w_{ij}} \right)^2 \quad (3.38)$$

$$w_{ij}^+ = w_{ij} - \frac{\alpha}{\sqrt{v(t)}} m(t) \quad (3.39)$$

Eşitlik 3.37 ve 3.38'de bulunan β_1 ve β_2 öğrenme değişkenleridir. Literatürde önerilen değerleri sırasıyla 0.9 ve 0.999'dur. Günümüzde Adam yöntemi en popüler ve en çok kullanılan uyarlamalı öğrenme algoritmasıdır.

Yapay sinir ağları modeli eğitilirken, stokastik ve toplu öğrenme olmak üzere iki öğrenme yöntemi bulunmaktadır. Stokastik öğrenmede yalnızca bir örnek üretilir ve bunu geri yayılım izler. Bu nedenle, her işlemde içerisinde bir ağırlık güncellemesi yapılır. Toplu öğrenmede ise tüm veri kümeleri ve tüm veri kümelerinin kümülatif toplamına göre ağırlıklar güncellenir Stochastic Gradient Descent algoritması arama uzayında birçok yerel minimum ve maksimum bulunduğu ortamda daha iyi çalıştığı gözlemlenmiştir. Buna karşın, toplu öğrenme, yerel minimum noktalara daha hızlı yakınsama sağlamıştır. Algoritmaların kullanımları, eğitim setine bağlı olarak değişir. Genelde tüm veri kümelerinden rastgele olarak seçilen küçük örnek kümeleri şeklinde modern uygulamalarda kullanılır.

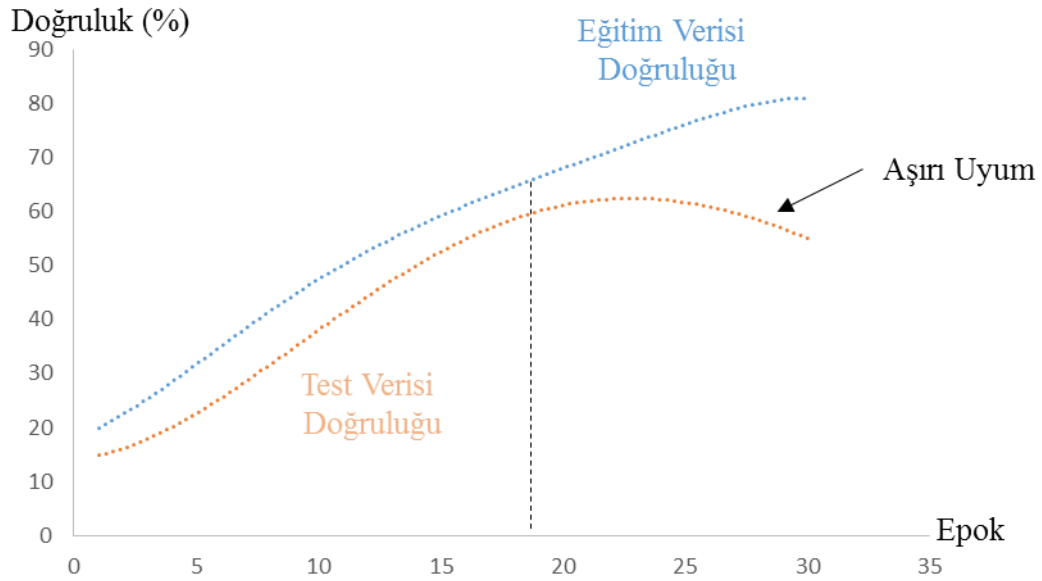
Öğrenme hızı sabitini seçmek bir diğer önemli tasarım problemidir. Düşük öğrenme oranları ile yapılan eğitimler doğrusal bir şekilde gerçekleşir. Yüksek öğrenme oranları kullanılması durumunda kayıp fonksiyonunu daha hızlı bir şekilde azaltacaktır. Fakat yerel minimumlara takılma ihtimali artacaktır. Eğitim sürecindeki kayıp grafiklerini analiz ederek optimum bir değere karar verilebilir. Yüksek bir öğrenme oranı genellikle hızla düşer ve bir süre sonra sabit kalır. Öte yandan, düşük öğrenme oranları yerel minimumlardan dolayı küresel minimuma ulaşamayabilir (Tasoulis ve ark., 2003). Çeşitli öğrenme oranları ile gerçekleştirilen eğitim grafikleri Şekil 3.25'de gösterilmektedir.



Şekil 3.25. Farklı öğrenme oranları performansları

Yapay sinir ağları eğitimine başlamadan önce eğitim verileri mini yığın adı verilen küçük veri kümelerine ayrılır. Eğitim verileri mini yığın yapılarına ayrılarak tüm eğitim verisi kapsanacak şekilde eğitim aşamasında kullanılır. Mini yığın yapıları ile bütün eğitim verisini temsil edecek şekilde bir kez eğitim aşamasında kullanılması süresince elde edilen iterasyon sayısına epok adı verilir. Sinir ağlarını eğitirken, eğer birkaç epok kullanılırsa, model uygun bir şekilde eğitilmemiş olabilir. Çok fazla epok kullanılması durumunda model aşırı eğitim işlemine maruz kalır ve eğitim örneklerini ezberler. Aşırı uyum problemi eğitimi tamamlanmış ağın eğitim verilerinde hassasiyetinin çok iyi olmasına rağmen test verilerinde düşük hassasiyete sahip olması durumudur (Song ve ark., 2019). Yapay sinir ağları bağlamında doğruluk, doğru sınıflandırılmış örneklerin sayısının tüm örneklere oranını ifade eder.

Yapay sinir ağlarının test verilerindeki düşük hassasiyetini gidermek amacıyla eğitim sürecinde belirli epok zamanlarında eğitim ve test verilerinin doğruluğu kontrol edilir. Bu analiz Şekil 3.26'da gösterildiği gibi kullanıcıya eğitim sürecini ne zaman durdurabileceğini gösterebilir. Model eğitim seti üzerinde eğitildiği için, eğitim seti doğruluğu ile test seti doğruluğu arasında her zaman küçük bir fark olacaktır. Bu fark, eğitim sürecinde artmaya başladığında eğitimin sonlandırılması gerekir.




Şekil 3.26. Eğitim sürecinde eğitim ve test verileri arasındaki ilişki

Veriler üzerinde ön işleme yapılması durumunda yapay sinir ağının daha hızlı öğrendiği ve daha iyi performans gösterdiği görülmüştür. Verilerden ortalamanın çıkarılması, en yaygın ön işleme yöntemlerinden biridir. Bu işlem sayesinde veriler belirli bir nokta etrafında toplanması sağlanır. Diğer ön işleme tekniklerinden biri olan yığın normalizasyon işlemi veri boyutunun aynı ölçekte kalmasını sağlar. Normalizasyonun bir diğer yolu her boyutu standart sapmaya bölmektir. Verileri normalize etmenin bir yolu ise verinin minimum ve maksimum değerlerini bulmak ve verileri -1 ile 1 arasında olacak şekilde yeniden ölçeklendirmektir.

Yapay sinir ağlarının eğitimi başlatılırken ağırlıkların değerlerine bazı başlangıç değerlerinin atanması gerekir. Tüm ağırlıkların sıfır olarak ayarlanması tüm yapay sinir çıkışlarının aynı değeri almasını sağlar. Bu işlem aynı zamanda geri yayılma sırasında aynı gradyan hesaplanmasına ve aynı parametre güncellemelerine neden olur. Bu nedenle ağırlık değerlerinde simetri olmamalıdır. Genellikle, ağırlık başlatılmasında sıfıra çok yakın ancak sıfır olmayan ağırlıklar tercih edilir. Ağırlıkları rasgele sıfır ortalama ve birim standart sapma ile Gaussian dağılımı şeklinde başlatılması tercih edilen başlangıç ağırlık atamalarından biridir. Ancak, küçük değerlerdeki ağırlıklar her sinir ağı için uygun olmayabilir. Bunun sebebi ise küçük ağırlık değerlerinde güncelleme çok küçük miktarlarda gerçekleşir. Çünkü elde edilen gradyan miktarı ağırlıklarla doğrudan ilişkilidir (Yang ve ark., 2018).

Eğitim süreci boyunca aşırı uyum probleminin önüne geçmek amacıyla kaçınma tekniği kullanılabilir. Srivastava ve ark. tarafından önerilen son derece etkili ve basit bir

tekniktir. Kaçınma rastgele seçilen yapay sinirlerin eğitim sırasında göz ardı edildiği bir tekniktir. Kaçınma işleminde bir p ($0 \leq p \leq 1$) değişkeni belirlenir. Her eğitim aşamasında, bireysel düğümler olasılıksal p oranı ile ağ bağlantısı kontrol edilir. Eğitim adımından sonra, göz ardı edilen düğümler ağa tekrar orijinal ağırlıkları p ile çarpılarak yeniden yerleştirilir. Şekil 3.27’de standart yapay sinir ağı yapısı ve kaçınma işlemi uygulanmış ağ yapısı bulunmaktadır.



Şekil 3.27. a) Standart ağ b) Kaçınma uygulanmış ağ

3.5. Konvolüsyonel Sinir Ağları

Konvolüsyonel sinir ağı (KSA) ileri beslemeli bir yapay sinir ağı örneğidir. KSA yapılarında normal sinir ağı modellerine kıyasla çok az ön işleme kullanılır. KSA'daki ağ modeli, makine öğrenmesindeki algoritmaların yansıra özellikleri kendisi öğrenir ve yapay sinirler arasındaki ilişkileri kurar. Çok katmanlı yapay sinir ağlarında görüntü sınıflandırılması yapılırken, her piksel ayrı ayrı alınarak bir vektör oluşturur. Bu işlem sonucunda bitişik pikseller arasındaki bilgiler dikkate alınmamış olur. Ayrıca pikseller arasındaki uzamsal ilişkide göz ardı edilmiş olur. Bu durumun üstesinden gelmek amacıyla verilere genellikle ön işleme adımı uygulanır.


KSA'da görüntü içerisinde uzamsal bilgi bir konvolüsyon operatörü ile işleme girer. Konvolüsyon filtreleri, eğitim sırasında değerlerini otomatik olarak öğrenir ve verilerdeki belirli desenleri ortaya çıkarır. KSA yapıları genel olarak konvolüsyon, havuzlama (pooling) ve tam bağlı katmanlardan oluşur. KSA yapılarında konvolüsyon filtreleri kullanılarak belirli desenler çıkarılır. Daha sonrasında havuzlama katmanları

ile model içerisindeki gereksiz verilerin görmezden gelinmesi sağlanır. Bu işlemler sonucunda görüntü verilerinde yaygın olarak bulunan belirli desenler elde edilmiş olur. Son adım olarak, elde edilen veriler vektöre dönüştürülür ve sınıflama işlemi yapılır. KSA yapısında ham veriler özellikleri çıkarılarak tek bir vektör olarak temsil edilir. Bu vektörel gösterim görüntünün gri veya renkli olmasına göre değişmektedir. Gri seviyeli görüntülerde tek bir vektör gösterimi bulunurken renkli görüntülerde ise renk kanallarından dolayı üç vektör gösterimi mevcuttur.

3.5.1. Konvolüsyon katmanı

Bir konvolüsyon katmanın temel işlevi, girdi verilerinden özellikler elde etmektir. Konvolüsyon, iki fonksiyonun matematiksel bir işleminden oluşur. KSA yapısında konvolüsyon işlemi, eleman bazında çarpım işlemi gerçekleştirilerek ana veriler üzerinde filtre denilen bir çekirdek fonksiyonunun basitçe kaydırılması ile gerçekleştirilir. Kaydırma işlemindeki her pencere için, ilgili elemanların çarpımı o pencerenin sonucunu verir. Tüm görüntü boyunca pencereler kaydırılarak, özellik haritası adı verilen konvolüsyon işleminin çıktısı üretilir.

Şekil 3.28'de, 5x5 boyutunda görüntü matrisi ile 3x3 boyutunda bir konvolüsyon filtresi kullanılarak işlem yapılmıştır. Sol üst köşeden başlayarak, filtre tüm görüntüyü taramaya başlar. Bu sayede görüntünün özellik haritası çıkarılmış olur. Filtre ve giriş görüntüsü arasında bir korelasyon olduğunda, sonuçta ortaya çıkan özellik haritasının bu alanlarda daha yüksek değerlere sahip olduğu görülmektedir. Benzerlik olmadığında ise ortaya çıkan özellik haritasının bu bölgelerde daha düşük değerleri vardır. Bu yüzden filtrelere özellik dedektörleri adı da verilir. Konvolüsyon katmanında, orijinal veriler üzerinde birçok filtre kullanılır. Bu filtrelerin her biri girdi verilerinin farklı desenlerini ve özelliklerini öğrenir. Özellikle kenarları, eğrileri, lekeleri ve pürüzsüz alanları algılamayı öğrenebilirler.



Şekil 3.28. Konvolüsyon işlemi

KSA yapılarında konvolüsyon işlemi göz önüne alındığında, düşünülmesi gereken üç tasarım sorunu bulunmaktadır. Bu sorunlar filtre boyutu, filtre sayısı ve kayma adıdır. Bu parametrelerin, çıktı verilerinin oluşumunda ve bellek kullanımı üzerinde etkisi mevcuttur.

Filtre boyutu, konvolüsyon katmanının çıktısını belirleyen bir değişkendir. Filtrenin değerleri modelin ağırlıklarını temsil eder. Örneğin, filtrenin boyutu 3x3 ise, çıktısının giriş katmanındaki 9 farklı düğümle bağlantısı vardır. Girişte tek kanallı gri tonlamalı bir görüntü var ise, filtre de tek kanallı olur. Giriş üç kanallı bir RGB görüntü ise, filtre üç boyutlu bir yapı olarak seçilir. Eğer filtre büyüklüğü çok küçükse, yeterli özellik elde edilmesi mümkün olmaz. Küçük boyuttaki filtreler büyük karmaşık görüntülerden yeterli özellik öğrenemez. Bununla birlikte, küçük boyuttaki filtreler ard

arda konvolüsyon işlemi için kullanılırsa, yeterli özellik öğrenilebilir. Filtre boyutunun daha büyük olduğu durumda ise hesaplama karmaşıklığı artmaktadır. Genel olarak, KSA yapısının eğitiminde 3×3 veya 5×5 gibi küçük filtre boyutları kullanılır. Bununla birlikte, son yayınlarda ağdaki boyutu azaltmak için bazı durumlarda 1×1 boyutunda filtrelerin yararlı olabileceği belirtilmektedir (Szegedy ve ark., 2015).

Konvolüsyon katmanında filtre sayısının belirlenmesi oldukça önemlidir. Çünkü belirlenen filtre sayısına göre öğrenilen özellik sayısı artmaktadır. Filtre sayısı yeterli olmazsa öğrenilmesi gereken bazı özellikler göz ardı edilebilir. Öte yandan, filtre sayısı fazla olması durumunda ise aynı özelliklerin öğrenilme olasılığı vardır. Aynı özellikleri öğrenen filtre sayısının çok olması bellek sorunları meydana getirir.

Her bir filtre giriş görüntüsü üzerinde kaydırıldığında, bir özellik haritası elde edilir. Bu çıktı görüntüleri tüm filtrelerden elde edilen çıktıların birleştirilmesinden oluşur. Giriş görüntüsü iki boyutlu olması durumunda çıktılar üç boyutlu olacaktır. Giriş görüntüsü üç boyutlu hacimsel veri ise, çıktıları dört boyutlu olacaktır. Fazladan boyutların elde edilmesi birçok filtre kullanmaktan kaynaklanır. Görüntünün derinliği ve filtrenin derinliği aynı olmalıdır. 30×30 boyutunda bir giriş görüntüsü ve 3×3 boyutunda bir filtre düşünüldüğünde elde edilen konvolüsyon katman sonucu 28×28 boyutunda olacaktır. Ancak, giriş görüntüsüne uygulanan birden fazla filtre vardır. Bu sebeple çıktı veri boyutu $K \times 28 \times 28$ olur. Bir sonraki konvolüsyon işlemi için filtre boyutu $K \times N \times M$ olur. KSA model temsillerinde, bu boyut genellikle $K @ N \times M$ olarak temsil edilir.

Kaydırma işlemi, filtrenin giriş hacminin etrafında nasıl hareket edeceği hakkında bilgi verir. Genellikle, filtre bir kerede giriş görüntüsünü belirli adım miktarına göre konvolüsyon işleminden geçirir. Bununla birlikte, çıktı matrisinin boyutunu kontrol etmek için adım miktarı değiştirilebilir. Adım miktarı 2 olarak atanırsa filtre 2 birim kayarak işlem yapar.

Konvolüsyon işleminde, çıkış verisinin boyutunu giriş hacmiyle aynı tutmak amacıyla giriş görüntüsüne dolgu eklenebilir. Dolgu boyutu genellikle filtrenin boyutuna göre belirlenir. Filtrenin boyutu 3×3 ise, görüntünün etrafında 1 piksellik dolgu yeterlidir. Filtrenin boyutu 5×5 ise, görüntünün etrafında 2 piksellik dolgu kullanılabilir. Şekil 3.29'da görüldüğü üzere dolgu değerleri genellikle sıfır veya kenar pikselleriyle aynı değer olarak seçilebilir.

Sıfır Dolgu

	←	←	←	←	←	←	←	→	
	0	0	0	0	0	0	0	0	
	0	0	0	0	0	0	0	0	
	0	0	1	0	0	1	0	0	
	0	0	1	0	1	0	0	0	
	0	0	1	0	1	1	0	0	
	0	0	0	0	0	0	0	0	
	0	0	0	0	0	0	0	0	
	←	←	←	←	←	←	←	→	

Sıfır Dolgu

Şekil 3.29. Sıfır dolgulu görüntü matrisi

Herhangi bir konvolüsyon katmanında çıktı boyutunu hesaplamak için Eşitlik 3.40 kullanılır.

$$O = \frac{(W - K + 2P)}{S} + 1 \quad (3.40)$$


Eşitlik 3.40'da O çıkış katmanının boyutunu belirtirken, W giriş katmanının boyutunu gösterir. Aynı zamanda K filtre boyutu, P dolgu boyutu ve S kayma adımındır.

3.5.2. Havuzlama katmanı


Alt örnekleme katmanı olarak da adlandırılan havuzlama katmanı, ağdaki parametre sayısını ve hesaplama sayısını azaltarak konvolüsyon katmanı çıktısı olarak elde edilen özellik haritalarından en önemli özellikleri seçer. Bunun yanı sıra havuzlama katmanı aşırı uyum probleminin önüne geçmek amacı da vardır. Havuzlama katmanı genellikle iki konvolüsyon katmanı veya konvolüsyon katmanı ile tam bağlı katmanlar arasına yerleştirilir.

Maksimum havuzlama ve ortalama havuzlama, en çok kullanılan havuzlama yöntemlerinden ikisidir. Belirli bir pencere için, maksimum havuzlama bu penceredeki maksimum değeri alır ve ortalama havuzlama penceredeki değerlerin ortalama değerini alır. Havuzlama işleminde, pencere boyutu ve adım değeri olmak üzere iki önemli parametre bulunur. Pencere boyutu, görüntüde taranacak alanın genişliğini belirler. Öte

yandan, adım değeri havuzlama penceresinin adım boyutunu belirler. Şekil 3.30'da maksimum ve ortalama havuzlama işlemleri gösterilmiştir.



a)



b)

Şekil 3.30. a) Maksimum havuzlama b) Ortalama havuzlama

3.5.3. Tam bağlı katman

Konvolüsyon ve havuzlama katmanı dikdörtgen biçimli çıktılar üretir. Bu çıktılar, vektör formatına dönüştürülerek ağırlık matrisi ile çarpılabilirler. Her biri $5 \times 5 \times 3$ matris boyutunda olan 64 özellik haritası katmanları varsa, tam bağlı katman için bu veriler $5 \times 5 \times 3 \times 64 = 4800 \times 1$ vektörüne dönüştürülür. Tam bağlı katmandan önceki katman, üst düzey özellikleri temsil eder. Tam bağlı bir katman yardımıyla, bu üst düzey özellikler, gizli katmanların ağırlıkları ile çarpılabilir. Sistemin geri kalan kısmı çok katmanlı yapay sinir ağı gibi çalışır.

3.5.4. SoftMax

SoftMax fonksiyonu, çoklu sınıflar için genel lojistik regresyon çeşididir. Regresyon işleminde gerçek sayıların bir giriş vektörü alınır ve N olasılıktan oluşan bir

olasılık dağılımı çıkarılır. Hesaplanan tüm olasılık değerleri (0,1) aralığındadır ve bu olasılık değerlerinin toplamı 1'e eşittir (Bishop, 2006). Daha yüksek girdi değerleri daha yüksek olasılık değerlerine neden olur. KSA yapılarında sınıflandırma amacıyla bir SoftMax katmanı kullanılır. Eşitlik 3.41'de Softmax fonksiyonu tanımlanmıştır.

$$sinf_j = \frac{\exp(sf_j)}{\sum_q \exp(sf_q)} \quad (3.41)$$

$sinf_j$ çıkış değerini, sf_j , softmax aktivasyon fonksiyonuna j . giriş değeridir. sf_q , SoftMax katmanındaki her bir yapay siniri gösterir.

3.5.5. Destek vektör makinesi

Softmax regresyonunun sınıflandırıcı olarak uygulanmasının yanı sıra, Destek Vektör Makineleri (DVM) sınıflandırma için kullanılabilir. Konvolüsyon katmanları özellik çıkarma işlemini gerçekleştirir. Sınıflandırma katmanında DVM algoritması yerleştirilir.

DVM, verileri girdi olarak almak ve istenen formata dönüştürmek için içerisindeki çekirdekleri kullanır. Çekirdekler girdi verilerini uygun bir özellik alanında iki nokta arasında döndürür. Böylece, çok yüksek boyutlu alanlarda bile hesaplama maliyeti düşük olur. DVM, Radyal Temel Fonksiyon (RTF), polinom veya sigmoid gibi farklı çekirdek fonksiyonlarına sahiptir. RTF çekirdeğinin formülü Eşitlik 3.42'de verilmiştir.

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (3.41)$$


Bazı giriş uzaylarındaki özellik vektörlerini temsil eden x ve x' örneğindeki RTF çekirdeği, iki özellik vektörü arasındaki karesel öklid mesafesi olarak tanımlanır. σ ise örnekler arasındaki varyansı gösterir.

DVM sınıflandırması için RTF çekirdeğini uygularken, g ve C olmak üzere iki parametre vardır. Sezgisel olarak, g parametresi, tek bir eğitim örneğinin etkisinin

“uzak” anlamına gelen düşük değerlere ve “yakın” anlamına gelen yüksek değerlere ne kadar ulaştığını tanımlar. C parametresi, karar fonksiyonunun büyüklüğünü maksimize etmeye karşı eğitim örneklerinin doğru bir şekilde sınıflandırılmasını sağlar. Doğruluk için en iyi parametreleri bulmak amacıyla, hem g hem de C parametrelerinde grid arama yöntemi uygulanır. g parametresi 0.01 ile 1 arasında, C parametresi ise 0.1 ve 10 arasında değer alabilir. Optimal değerler, sırasıyla 0.1 ve 1’dir (Cherkassky ve Ma, 2004).

3.5.6. Uzun kısa süreli bellek

Tekrarlayan Sinir Ağları (TSA) sıralı verileri işlemek için tasarlanmıştır. Ancak uzun boyutlara sahip dizileri öğrenmekte başarısız olmuşlardır. Bu sorunu önlemek için, Uzun Kısa Süreli Bellek (UKSB) Hochreiter ve ark. tarafından tanıtılmıştır (Hochreiter, 1997). Klasik TSA'ların yanı sıra, UKSB tekrarlanan bağlantıya sahip bir hafıza bloğunda kendinden gizli bir üniteye ve iki giriş ünitesine sahiptir. Bu birimler, önceki içeriğe göre bilgilerin bellek hücresine erişimini kontrol eder. Şekil 3.31 sıralı UKSB hafıza hücrelerini göstermektedir.



Şekil 3.31. Seri UKSB yapısı

Son yıllarda, UKSB ağları, çevrimdışı el yazısı tanıma ve konuşma tanıma gibi sıra etiketini içeren birçok soruna başarıyla uygulanmıştır.

Bir UKSB bellek bloğu, bir giriş kapısı i , bir unutmaya kapısı f ve o sırada bellek hücresindeki c hafızanın üzerine yazılan, saklayan veya alan bir çıkış kapısı o olmak üzere üç kapı içerir.

İlk olarak giriş kapısı i_t ve unutmaya kapıları f_t şu şekilde hesaplanır:

$$i_t = \text{sigm}(W_i x_t + H_i h_{t-1} + C_i c_{t-1} + b_i) \quad (3.42)$$

$$f_t = \text{sigm}(W_f x_t + H_f h_{t-1} + C_f c_{t-1} + b_f) \quad (3.43)$$

Daha sonra, mevcut bellek hücresi c_t unutmak için önceki içerikler c_{t-1} dahil olmak üzere yeni belleğin c^l bir miktarıyla güncellenir. Aşağıdaki eşitliklere göre hesaplamalar yapılabilir.

$$c_t^l = \text{tanh}(W_{c^l} x_t + H_{c^l} h_{t-1} + b_{c^l}) \quad (3.44)$$

$$c_t = f_t \square c_{t-1} + i_t \square c_t^l \quad (3.45)$$

Son olarak mevcut pozisyondaki h_t nihai aktivasyon, çıkacak bilgi miktarını düzenleyen çıkış kapısı o_t ile hesaplanır.

$$o_t = \text{sigm}(W_o x_t + H_o h_{t-1} + C_o c_t + b_o) \quad (3.46)$$

$$h_t = o_t \square \text{tanh}(c_t) \quad (3.47)$$

W , H ve C , giriş kapıları, tekrarlayan bağlantılar ve hücre kapıları için ağırlık matrisleridir.

3.5.7. K-En yakın komşu algoritması


K-En Yakın Komşu (K-EYK) Algoritması verilerin birbiri arasındaki komşulukları dikkate alarak kümeleme işlemini gerçekleştirir. Veri içerisindeki komşuluk miktarı tasarımcı tarafında belirlenir. Birbirine benzerlik gösteren verilerde komşuluk derecesi yüksek olup benzer olmayan verilerde komşuluk derecesi düşüktür. Veriler arasındaki uzaklık miktarına göre komşuluklar değişmektedir. Belirlenen komşuluk sayısına göre K-EYK algoritması sınıflama işlemini yapar.

K-EYK algoritması kümeleme işleminde özellikler üzerinde ağırlıklandırma gerçekleştirebilir. Eşitlik 3.48'de ağırlıkların tersi ya da tersinin karesinden yararlanılır.

Güncel ağırlık değerlerine göre sınıflama işlemi yapılır. x_i eğitim verilerini, x_q test verilerini gösterir. Eşitlik 3.48’de atanan ağırlık değerlerine göre veriler en yakın komşuluk formuna dönüştürülebilir.

$$W = \frac{1}{d(x_q, x_i)^2} \quad (3.48)$$

K-EYK kümeleme algoritmasında veri boyutu dikkate alınarak en yakın komşuluklar değerlendirilir. K ifadesi seçilmesi istenen komşuluk sayısını gösterir. $K=1$ olduğu durumda en yakın komşu veri değerlendirilerek kümeleme işlemi yapılır. Diğer bir ifadeyle K değeri kaç adet komşuluğun kümeleme işlemine dahil edileceğini temsil eder. Şekil 3.32’de $K=4$ için K-EYK algoritma sınıflandırması yer almaktadır.



Şekil 3.32. $K=4$ için K-EYK algoritma sınıflandırması

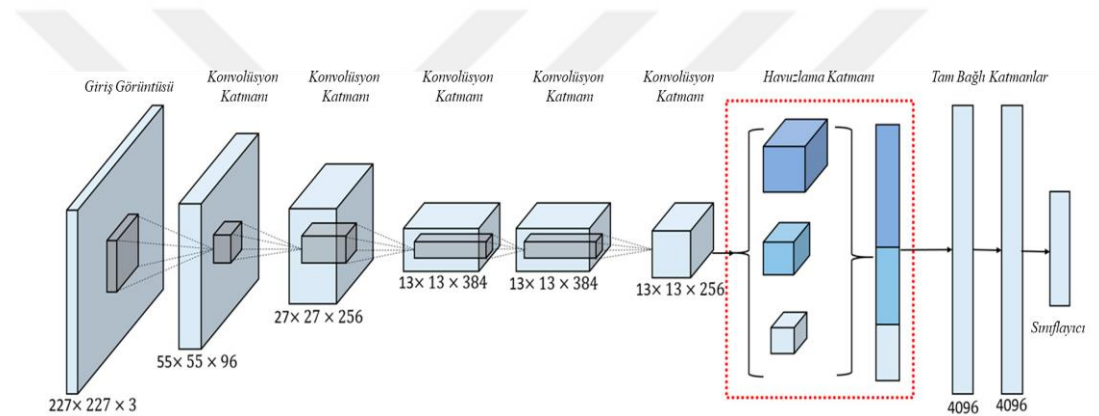
3.6. Ön Eğitimli KSA yapıları ve Transfer Öğrenmesi

Bu bölümde iyi bilinen derin sinir ağları ayrıntılı olarak açıklanmaktadır. Literatürde çok sayıda ön eğitimli konvolüsyonel sinir ağları mevcuttur. Bu tez çalışmasında AlexNet, VGGNet, GoogleNet, ResNet-50, InceptionNet ve SqueezeNet modelleri transfer öğrenimi için kullanılmıştır. Bu ağ yapıları birbirinden oldukça farklıdır ve ayrıca her biri belirli problemlerin çözümü için tasarlanmıştır.

3.6.1. Ön eğitimli ksa yapıları

3.6.1.1. AlexNet

AlexNet mimarisi, Krizhevsky ve ark. tarafından nesne tanıma için geliştirilen konvolüsyonel sinir ağı yapısıdır (Krizhevsky ve ark., 2017). Bu KSA yapısı, 1.2 milyon görüntü bulunan ILSVRC 2012 ImageNet adı verilen veri seti üzerinde eğitildi (Deng ve ark., 2009). AlexNet yapısı, basit tanıma görevlerinin küçük boyutlu veri kümeleriyle oldukça iyi çözülebileceğini gösterdi. Ancak, gerçek dünya koşullarında yüksek doğruluk oranları elde etmek için daha büyük eğitim setleri kullanmak gereklidir. AlexNet mimarisi Şekil 3.33'de gösterilmektedir.



Şekil 3.33. AlexNet Mimarisi (Krizhevsky ve ark., 2017)


AlexNet mimarisi toplamda sekiz katman içerir. Bu katmanların ilk beşi konvolüsyon katmanı olup sonrasında havuzlama katmanı ve iki adet tam bağlı katman bulunmaktadır. Son kısımda ise sınıflayıcı kullanılmıştır. 1000 sınıf etiketlerin üzerinde bir dağıtım üreten 1000 yollu softmax katmanı, son tam bağlı katmanın çıktısını besler. Şekil 3.33'de gösterildiği gibi konvolüsyon katmanları sadece önceki katmandaki filtre taramasından oluşan özellik haritalarına bağlanır. Konvolüsyona ve birbirine bağlı her katmandan sonra, REDB işlevi ağ boyunca uygulanır. Ayrıca, filtrelerin sayısı ve büyüklükleri Şekil 3.31'de gösterilmektedir. Birinci konvolüsyon katman filtreleri, 4 piksellik bir adımla $11 \times 11 \times 3$ ebadında 96 filtre sayısı ile $224 \times 224 \times 3$ giriş görüntüsünü girdi olarak alır. İkinci konvolüsyon katmanı, birinci konvolüsyon katmanından elde edilen çıktı verisini girdi olarak alır. Herhangi bir havuzlama veya normalizasyon katmanı olmadan, üçüncü, dördüncü ve beşinci konvolüsyon katmanları birbirlerine sırasıyla bağlanır. Bu tabakalar birbirlerinden farklı sayıda ve boyutta filtrelere sahiptir. Üçüncü konvolüsyon katmanı $3 \times 3 \times 256$ ebadında 384 adet filtreye sahiptir. Dördüncü

konvolüsyon katmanında $3 \times 3 \times 192$ boyutunda 384 adet filtre ve beşinci konvolüsyon katmanında $256 \times 3 \times 192$ boyutunda filtrelerle sahiptir. Son olarak, her bir tam bağlı katmanda 4096 yapay sınırlar bulunur (Krizhevsky ve ark., 2017).

AlexNet mimarisi yaklaşık 60 milyon parametreye sahiptir ve 650.000 yapay sinir içerir. Son katman 1000 farklı sınıf dağılım olasılığına sahiptir. Birçok parametre göz önüne alındığında, aşırı uyum çözülmesi gereken ciddi bir problem haline gelir. Aşırı uyum probleminin çözümü için iki temel yöntem mevcuttur. Önerilen yöntemlerden birincisi veri artırımı sağlamak diğeri ise kaçınma tekniği uygulamaktır. Bunun yanı sıra, konvolüsyonel sinir ağlarının derinliğinin artırılması sınıflandırma performansını etkileyen önemli faktörlerdendir.

3.6.1.2. VGGNet

Pfister ve ark.'nın önerdiği VGG mimarisi, görüntü tanıma problemi için çok derin konvolüsyonel sinir ağıdır (Pfister ve ark., 2015). Tasarımcıların bu mimarinin oluşturulmasında ana katkıları ağı derinliğini ve sınıflandırma doğruluğunu artırmaktır. Bunun için çok küçük boyutlara sahip (3×3) konvolüsyonel filtreler kullanmışlardır. VGG mimarisi, AlexNet mimarisi gibi ILSVRC 2012 ImageNet veri kümesi üzerinde eğitilmiştir. Elde edilen sınıflama sonuçları ile ImageNet ILSVRC-2014 sıralamasında ikinci sırada yer almaktadır. Ağı 16 ve 19 kat olmak üzere iki farklı modeli bulunmaktadır. VGG-16 modelinin mimarisi şekil 3.34'de gösterilmiştir.



Şekil 3.34. VGG-16 Mimarisi

VGG-16 mimarisinin girişinde $224 \times 224 \times 3$ RGB görüntüler için giriş katmanı bulunur. VGG modelinin 16 katmanlı versiyonunda 3×3 filtre boyutuna sahip 13 adet konvolüsyon katmanı bulunmaktadır. Konvolüsyon katmanlarının bir kısmından sonra maksimum havuzlama işlemi uygulanmıştır. Havuzlama işlemi 2×2 boyutunda olup 2

kayma adımına sahiptir. Farklı derinliğe sahip birkaç konvolüsyon katmanından sonra 3 adet tam bağlı katman bulunur. Tam bağlı katmanların ilk ikisinde 4096 düğüm var iken üçüncüsünde 1000 düğüm bulunur. Çünkü üçüncü tam bağlı katmanda 1000 yollu bir sınıflandırma işlemi yapılmaktadır. Son katmanda softmax sınıflandırıcısı bulunur. Ayrıca, tüm gizli katmanlarda REDB aktivasyon fonksiyonu uygulanmıştır.

3.6.1.3. GoogleNet

GoogleNet yapısı görüntü tanıma görevi için geliştirilmiş ve AlexNet'den 12 kat daha az parametre kullanılarak tasarlanmış bir konvolüsyonel sinir ağıdır (Szegedy ve ark., 2015). Derin sinir ağlarının performansını arttırmanın en basit yolu derinliği arttırmaktır. Ağın derinliği iki farklı yöntem ile artırılabilir. İlk olarak ağıdaki katman sayısı artırılarak derinliği artırılır. İkinci olarak ise filtre sayısı artırılarak ağın genişliği artırılır. Aslında bu işlemler, yüksek kaliteli modelleri eğitmenin kolay ve güvenli bir yoludur. Fakat bu gibi düzenlemeler bir takım dezavantajlar getirmektedir. Birincisi, daha büyük ağ yapılarını aşırı yüklenmeye daha yatkın hale getiren daha fazla sayıda parametre anlamına gelir. İkincisi, ağ boyutu arttığında hesaplama süresi ve kaynakların kullanımı da artar.

GoogleNet mimarisinin başlangıcı 224×224 RGB renkli görüntü alan giriş katmanı ile başlar. Boyut küçültme için, 1×1 filtrelerle sahip konvolüsyon katmanlarında REDB aktivasyon fonksiyonları kullanılmıştır. Ayrıca ağda birkaç kaçınma katmanı vardır ve bunların %70 oranında çıktı oranına sahiptir. Sınıflandırıcı olarak softmax yapısı kullanılmıştır. Sınıflandırıcıdan önce ortalama havuzlamanın kullanımı bu ağda da farklıdır, çünkü ekstra bir REDB katmanı kullanılır.

3.6.1.4. ResNet-50

Daha derin KSA modelinin tasarımı gerçekleşmeden önce eğitim sürecini çok zorlaştırdığı görülmüştür. Artık blok yapıları bu sorunun çözümü için kullanılır. Artık blok yapıları basitçe önceki katmanın çıktısını bir sonraki katmanın girişine bağlayan kısa bir yoldur. Bu sayede KSA modeli derinleştikçe düşük doğruluk oranlarının elde edilmesinin önüne geçilir. Artık blokları içeren uygulamalarından biri olan ResNet mimarisinde, kısayol bağlantıları konvolüsyon katmanlarını atlamak için kullanılır. Konvolüsyon katmanları, 2×2 adımına sahip olan ve her konvolüsyondan sonra

REDB'nun aktivasyonun kullanıldığı alt örnekleme işlemi olarak çalışır. Kısayol bağlantısı için giriş ve çıkış aynı boyutta olmalıdır. Boyut genişletme uygulandığında, projeksiyon eksenleri 1×1 boyutunda olması gerekir. Her iki durumda da, kısayollar iki boyutlu haritalara girdiğinde 2×2 adımla gerçekleştirilirler. Ağ sonunda 1000 tam bağlı bir katmanla Softmax sınıflandırıcısı bulunur. ResNet, 50, 101 ve 152 katmandan oluşan üç farklı versiyona sahiptir (He ve ark., 2016).

3.6.1.5. SqueezeNet

SqueezeNet, N. Forrester tarafından geliştirilen bir KSA yapısıdır. Daha küçük bir konvolüsyon filtreleri ile toplamda güncellenmesi gereken parametreyi azaltmak için kullanılabilir az sayıda kanal kullanımı ile SqueezeNet KSA yapısı tasarlanmıştır. SqueezeNet yapısı bağımsız bir konvolüsyon yapısı ile başlamış ve daha sonra 8 fire modülü kullanılmıştır. Bu modüller bir çeşit uyum yapısıdır. Fire modüllerinde, tasarlanan ağın son katmanlarına doğru filtre sayısı artırılmıştır. Bu işlemden sonra, ağ bir konvolüsyon katmanı ile sonlandırılır. Bu katmanın ardından, maksimum havuzlama ile özellik çıkarımı sağlanır. Ayrıca aktivasyon ve kaçınma katmanları, aşırı uyum problemini önlemek için kullanılmıştır (Verma ve ark., 2017).

3.6.1.5. InceptionNet

InceptionNet içerisindeki filtrelerin boyutları 1×1 , 3×3 ve 5×5 şeklinde ayarlanmıştır. Konvolüsyon işleminden sonra elde edilen özellik haritalarına 3×3 maksimum havuzlama işlemi uygulanır. KSA yapılarındaki temel sorunlar arasında yapı içerisindeki işlemlerin oldukça karmaşık olması ve hesaplanması gereken parametre sayısının fazla olması gösterilebilir. Bu problemler konvolüsyon katmanı öncesine paralel olarak konvolüsyon katmanları eklenerek çözülmüştür. Son katmanlara bağlı olan tam bağlı katmanlar öncesinde ortalama havuzlama işlemi yapılır. Bu işlem ile parametre sayısının azalması sağlanır.

InceptionNet yapısında 9 adet inception katmanı olup toplam katman sayısı 100'den fazladır. Nesne tanıma problemleri için kullanılan Bölgesel tabanlı Konvolüsyonel Sinir Ağları içerisinde Inception v1 modelini kullanmaktadır.


3.6.1.6. DenseNet

DenseNet mimarisinde üç farklı ölçekte yoğun bloklar mevcuttur. Model için giriş görüntü boyutları $224 \times 224 \times 3$ olmalıdır. Model yapısı belirtilen görüntü boyutlarına uygun bir şekilde filtre özellikleri atanmıştır. Yoğun bloklardan önce görüntüye ilk olarak 3×3 ve 1×1 filtre boyutlarına sahip bir dizi konvolüsyon işlemleri uygulanır. Konvolüsyon işlemleri ile birlikte özellik indirilmesi için 2×2 boyutunda pencerelere sahip havuzlama işlemi kullanılır. En son olarak ise ortalama havuzlama işlemi gerçekleştirilir. Sonrasında yoğun bloklardan elde edilen özellik haritaları 32×32 , 16×16 ve 8×8 boyutlarına sahiptir. DenseNet-121, DenseNet-169, DenseNet-201 ve DenseNet-264 modelleri DenseNet yapısında yaygın olarak kullanılmaktadır (Huang, 2017).

3.6.2. Transfer öğrenmesi

Transfer öğrenmesi, bir görev için daha önceden öğrenilmiş bir bilgiyi kullanarak elde edilen bilgilerin yeni bir görev için başlangıç parametreleri olarak kullanılmasıdır (Torrey ve ark., 2008). Genel olarak, bu teknik makine öğrenme algoritmalarında belirli problemler için tasarlanmıştır. Transfer öğrenmesindeki temel amaç farklı alanlardan veya dağıtımlardan gelen eğitim ve test verileri üzerindeki sınıflama başarısını artırmaktır. Birçok gerçek uygulamada gerekli eğitim verilerinin elde edilmesi ve modellerin oluşturulması oldukça zordur. Transfer öğrenmesi başarılı bir şekilde yapılırsa, pahalı veri etiketleme çalışmalarına gerek kalmayabilir ve öğrenme performansı da artabilir.

Şekil 3.35'de geleneksel ve transfer öğrenme teknikleri arasındaki farklar görülmektedir. İlk modelde her görev için model sıfırdan öğrenmeye çalışır. İkinci modelde ise önceki görevlerde öğrenilmiş bilgiler hedef göreve aktarılmaya çalışılır. İkinci modelde, sahip olunan eğitim veri sayısı birincisinden daha az olabilir. Bu nedenle, bilgi olarak eğitim verileri yerine önceki görevlerden elde edilen bilgiler kullanılır.



Şekil 3.35. a) Klasik makine öğrenmesi b) Transfer öğrenmesi

Transfer öğrenmesinde kullanılan çeşitli ayarlar mevcuttur. Bu ayarlar endüktif, transdüktif ve denetimsiz transfer ayarlar olmak üzere üç gruba ayrılır. Bu ayarlar arasındaki farklar görev alanı ve eğitim verilerinin etiketlenip etiketlenmediğinden kaynaklanır (Pan ve Yang, 2010). Endüktif transfer ayarlarında, hedef ve kaynak görevleri birbirinden farklıdır. Aynı yapı içerisinde kullanılan verilerin aynı veya farklı alanlardan gelmeleri önemli değildir. Transdüktif transfer öğrenmesinde, kaynak ve hedef görevler aynıdır fakat veri alanları farklıdır. Son olarak, denetimsiz transfer öğrenme ortamında, hedef ve kaynak görevleri birbirinden farklıdır. Yalnız gerçekleştirilen görevler birbirleri ile ilişkilidir.

Bu tez kapsamında endüktif transfer öğrenme ayarı kullanılmıştır. Bu ayar kapsamında konvolüsyonel sinir ağı, önce farklı bir görüntü tanıma görevi için eğitilmiştir. Eğitilen bu ağı kullanmak amacıyla elde edilen bilgileri kullanıcının

kendi modeline aktarması gerekir. Bu noktada, kişinin yeniden tanımlaması gereken hedef görev, kaynak görevden farklı olabilir. KSA yapılarında transfer öğrenmesi sadece konvolüsyonel sinir ağının yeni eğitim verileriyle tekrar eğitilmesi değil, aynı zamanda geri yayılma süreci devam ederken önceden belirlenmiş ağın ağırlıklarının ince ayarlanması anlamında gelir.

Birçok sorunun çözümü için, yeterli miktarda eğitim verisi bulmak oldukça zordur. Konvolüsyonel sinir ağlarında aşırı uyum problemini ortadan kaldırmak için büyük miktarda eğitim verisine ihtiyaç vardır. Bu nedenle, bir ağın tamamını sıfırdan eğitmek yerine, önceden eğitilmiş ağlara yeni eğitim setleriyle ince ayar yapılabilir. Bu teknik, konvolüsyonel sinir ağlarının küçük eğitim setleri ile ilgili problemlere başarıyla uygulanmasını sağlar.

İnce ayar, konvolüsyonel sinir ağlarında kullanılan transfer öğrenme stratejilerinden biridir. Tüm katmanlara ince ayar yapılabilir veya yalnızca ağın bazı katmanlarına ince ayar gerçekleştirilebilir. Genellikle aşırı uyum probleminden kaçınmak için önceki katmanların aynı tutulduğu, sadece bazı yüksek katmanların ince ayarlandığı kabul edilir. Modeldeki ilk katmanlar daha çok kenar ve kabarcık özelliklerini barındırır. Sonraki katmanlar ise problem alanıyla ilgili daha spesifik özellikler içerir. Diğer önemli konu ise probleme ince ayar işleminin nasıl kullanılacağına karar vermektir. Temel olarak iki önemli parametre vardır. Bunlar, kullanılması planlanan veri setinin büyüklüğü ve orijinal veri setine benzerliğidir.

3.6.3. Kütüphaneler

Derin öğrenme algoritmalarının çalıştırılabilmesi ve geliştirilebilmesi birtakım yazılımsal ve donanımsal maliyetler gerektirir. Eğitim aşamasında sistem kaynakları oluşturulan modelin performansını etkiler. Eğitim sürecinin daha hızlı bir şekilde gerçekleştirilebilmesi için Merkezi İşlem Birimi (MİB) yerine Grafıksel İşlem Biriminin (GİB) kullanılması gerekir. Bu donanımsal yapıların kullanılması kullanıcı bilgisi ve belirli bir zaman gerektirir. Derin öğrenme kütüphaneleri birçok farklı donanımsal yapıları kullanmaya imkân sağlamakta ve modellerin geliştirilmesinin önünü açmaktadır. Literatürde birçok derin öğrenme kütüphanesi bulunmaktadır.

3.6.3.1. TensorFlow

TensorFlow matematiksel hesaplamaları kolayca gerçekleştirebilen ve açık kaynak yazılımına sahip bir kütüphanedir. Google tarafından desteklenen araştırmacılar tarafından oluşturulmuş bir kütüphanedir. Kütüphane tarafından otomatik bir şekilde oluşturulan çizelgeler ile hesaplama sistemi görselleştirilmektedir. Python başta olmak üzere birçok programlama dillerinde kullanıcıların yararlanabileceği arayüzü bulunur. Mevcut arayüzler arasında kullanımı en kolay olan python tabanlı versiyonudur (Li ve ark., 2017).

TensorFlow kütüphanesi MİB ve GİB desteği sağlayan tüm cihazlarda çalışabilecek şekilde tasarlanmıştır. Kütüphanenin sağladığı esneklik ile derin öğrenme modelleri üzerinde çok az değişiklik yapılarak veya değişiklik yapılmadan çalıştırılabilmektedir. Görüntü işleme ve görüntü tanıma problemleri başta olmak üzere birçok alanda etkin biçimde kullanılmaktadır. Gerçekleştirilecek hesaplamalar tek bir MİB ile yapılabileceği gibi birden fazla GİB üzerinde de yapılabilmektedir (Mo ve ark., 2017). Paralel hesaplama yapılabilmesi için CUDA platformunun desteği gerekmektedir.

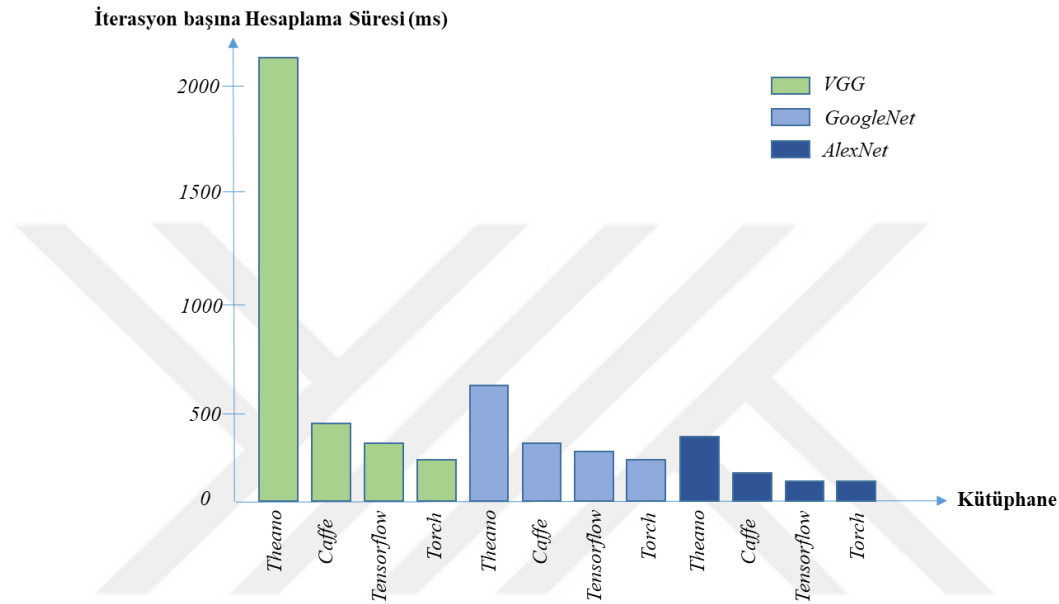
3.6.3.2. Theano

Theano kütüphanesi Montreal Üniversite tarafından desteklenen bir grup araştırmacı tarafından geliştirilmiştir. Python tabanlı açık kaynak koduna sahip kütüphanedir. Matematiksel hesaplamaları etkin ve hızlı bir şekilde gerçekleştirebilen Numpy kütüphanesi ile bütünleşik olarak çalışabilmektedir.

Numpy kütüphanesi veri işlemlerini diziler üzerinden gerçekleştirerek boyutlandırma ve indeksleme gibi fonksiyonlara sahiptir. C programlama dilinde bu fonksiyonlar hazırlanarak python programı içerisinde kullanımı sağlanmıştır. Kütüphane içerisinde MİB ve GİB kullanımı için CUDA desteği sağlanmıştır. GİB üzerinde paralel işlem yapılacağı zaman Theano matematiksel denklemleri CUDA koduna çevirir. Python kütüphanesinde bulunan modüller sayesinde derleme işlemi gerçekleştirilir (Boufenar ve Batouche, 2017). Aynı zamanda optimizasyon tekniklerini kullanarak gereksiz hesaplamaların yapılmasına izin vermez.

Theano içerisinde makine öğrenmesi ve derin öğrenme modellerinin geliştirilebileceği birçok kütüphane bulunmaktadır. Ön eğitilmiş modellerin

kullanılabilmesi ve yeni ağların oluşturulabilmesi için Pylearn2 ve Keras kütüphaneleri bulunmaktadır. Hazır ön eğitilmiş modelleri için birçok kütüphane içerisinde eğitim sırasındaki hesaplamalar gerçekleştirilmiş ve hesaplama süresi açısından performansları karşılaştırılmıştır. Şekil 3.36'da Theano kütüphanesinin diğer kütüphanelere göre hesaplama süresi performansları karşılaştırılmıştır. Performans karşılaştırılması Tesla P100 donanımı üzerinde gerçekleştirilmiştir.



Şekil 3.36. Kütüphanelerin performans karşılaştırılması

3.6.3.3. Torch

Torch kütüphanesi derin öğrenme modellerinde ileri geri matematiksel işlemleri hızlı bir şekilde gerçekleştiren açık kaynaklı bir kütüphanedir. Derin öğrenme uygulamalarında sıklıkla tercih edilmektedir. Torch kütüphanesi hem MİB hem de GİB üzerinden işlemler gerçekleştirebilmektedir. Diğer kütüphanelerden farklı olarak Torch kütüphanesinde Lua dili ile geliştirilme yapılmaktadır. Torch kütüphanesi kullanıcılara esneklik ve hızlı eğitim kolaylığı sağlamaktadır.

Lua dili C dili ile kolayca entegre bir şekilde çalışabilmektedir. İşlemler C dilinde gerçekleştirilerek kullanıcıya C dili tabanlı arayüz sunar. Lua dili içerisindeki veriler tablolar halinde işlem görür. Tablolar içerisinde sayı değerlerinin yanı sıra metin değerleri de yer almaktadır. Veriler üzerinde tekrardan boyutlandırma işlemi yapılabilmektedir. Lua dili derin öğrenmeden daha fazla oyun tasarımlarında kullanılır. Python diline göre daha az kütüphaneye sahip olan Lua dili, C ve C++ dillerinin

kütüphanelerini kullanabilmektedir. LuaJIT derleyicisi sayesinde yüksek hızda çalışabilmektedir. Diğer bir avantajı ise Lua dilinin gerçek zamanlı sistemler üzerine kolayca uygulanabilmesidir (Shen ve ark., 2013).

3.6.3.4. Caffe

Berkeley Görü ve Öğrenme Merkezi tarafından geliştirilen Caffe, C++ tabanlı açık kaynaklı bir kütüphanedir. Bu sayede tasarımcılar için değişiklik yapmaya ve algoritma geliştirmeye yönelik ortam sunmaktadır. Arayüzü sayesinde Python ve Matlab programları ile uyumlu çalışabilmektedir. GİB donanımını kullanarak paralel bir şekilde hesaplamaları gerçekleştirebilir. Caffe kütüphanelerini kullanarak konvolüsyonel sinir ağları modelleri oluşturulabilmekte ve eğitimleri gerçekleştirilebilmektedir. Ayrıca, görüntü sınıflandırma ve örüntü tanıma üzerine birçok örnekler sunarak tasarımcıların kendi problemleri için eğitim ve test işlemlerini gerçekleştirmesine katkı sağlar. Caffe kütüphaneleri kullanılması ile modellerin geliştirilmesi ve iyileştirilmesi için fazla kod yazımına ihtiyaç duyulmaz

3.6.3.5. Keras

François Chollet ve ark. tarafından geliştirilen Keras, Python tabanlı olup yüksek seviyeli yapay sinir ağları ve derin öğrenme algoritmalarının eğitimi için kullanılmaktadır. TensorFlow, Torch ve Theano kütüphanelerinin üzerinde çalışma kabiliyeti mevcuttur. Keras sayesinde derin öğrenme yapılarında kolayca tanımlama yapılabilmektedir. Aynı zamanda MİB ve GİB üzerinde işlemler gerçekleştirebilmektedir. Eğitim aşamasında doğruluk grafiklerini ve regularizasyon şemalarını bağımsız olarak çizdirebilmektedir. Bununla birlikte kullanım için hazırlanmış olan belgeler ve Python paket desteği ile tasarımcılara kolayca geliştirme yapmalarına imkân vermektedir.

3.6.3.6. Jupyter Notebook

Jupyter Notebook, Python tabanlı olup TensorFlow, Torch, Theano ve Keras kütüphanelerini eş zamanlı olarak çalıştırabilme kabiliyetine sahiptir. Alt kütüphanelerin en üstün özellikli yapılarını kullanarak işlemleri hızlı bir şekilde

gerçekleştirebilmektedir. Aynı zamanda MİB ve GİB donanımlarını etkin bir şekilde kullanabilir. Web tabanlı kullanıcı arayüzüne sahip Jupyter Notebook, karmaşık yapıda ve ağır hesaplama gerektiren modeller için kullanıcılara önemli avantajlar sağlamaktadır. Jupyter Notebook uygulamalarını Colab adı verilen uzaktan hizmet sağlayan platformda çalıştırmak mümkündür. Colab, Google tarafında hazırlanmış bir uzaktan erişim platformu olup 15 GB Google Drive hafızası ile kullanıcılara hizmet sunmaktadır. Bunun yanı sıra Google laboratuvarlarında bulunan yüksek hızlı bilgisayarlara erişerek işlemlerinizi online olarak yapıp sonuçları alabilme fırsatı sağlar. Jupyter Notebook sağlamış olduğu bu hizmetle tasarımcıların yüksek maliyetli GİB donanımları satın almasına gerek kalmamıştır. Bu tez kapsamında oluşturulan bazı derin öğrenme modellerinin eğitiminde Jupyter Notebook kullanılmıştır.

3.7. Konvolüsyonel Destek Vektör Makineleri

Destek Vektör Makineleri (DVM), literatürde bulunan en popüler denetimli sınıflandırıcılar arasındadır. Aşırı uyum problemini maksimum mesafe prensibini kullanarak çözümlen bir yöntemdir. DVM algoritması, çeşitli tanıma problemlerini çözmek amacıyla tasarımcılar tarafından belirlenen özelliklerle birlikte yoğun bir şekilde kullanılmaktadır. Konvolüsyonel Destek Vektör Makineleri (KDVM), sınıflandırma görevini yerine getirmek için genellikle bir KSA özellik çıkarıcısı ile beraber çalışmaktadır (Bazi ve Melgani, 2018). Bu algorithmada, denetimli özellik haritalarını oluşturmak için konvolüsyonel filtrelerden yararlanılmıştır. Standart KSA yapılarına kıyasla, KDVM algoritması DVM yöntemine dayanan derin öğrenme tekniğidir. Eğitim aşamasında geri yayılım algoritmasını kullanmamaktadır.

KDVM ağı, bir sınıflandırma katmanı tarafından takip edilen çeşitli alternatif konvolüsyonel ve havuzlama katmanlarına dayanmaktadır. Her bir konvolüsyon katmanı, yeni bir özellik haritası üretmek için önceki katman tarafından üretilen özellik haritalarını işlemek amacıyla bir dizi doğrusal DVM filtre bankları kullanır. İlk konvolüsyonel katman için, DVM filtreleri orijinal giriş görüntüleri üzerinde işlem yapar. Her bir konvolüsyon tabakasının DVM ağırlıkları, ilgilenilen nesnelere temsil eden görüntüler üzerinde çalışılarak doğrudan denetimli bir şekilde hesaplanır. Konvolüsyonel katmanlar tarafından üretilen özellik haritaları daha sonra REDB gibi doğrusal olmayan bir aktivasyon fonksiyonunda işlenir. KDVM'de havuzlama katmanı, KSA yapılarındaki havuzlama katmanına benzer şekilde çalışır. Konvolüsyonel

katmandan küçük dikdörtgen yamalar alır ve her yamadan tek bir çıktı üretir. Son olarak, ağ tarafından elde edilen üst düzey temsil vektörleri, sınıflandırma görevini yerine getirmek için tekrar doğrusal bir DVM sınıflandırıcısına girdi olarak verilir.

3.7.1. Konvolüsyonel DVM katmanı

Konvolüsyonel DVM katmanı, KDVM ağının ana yapısıdır. Bu katman, özellik haritaları oluşturmak için konvolüsyonel filtreler olarak doğrusal yapıdaki DVM ağırlıklarını kullanır. Bu filtre ağırlıkları, geri yayılım yoluyla hesaplanan geleneksel KSA'ların ağırlıklarından farklı olarak ileri denetimli bir öğrenme yöntemi kullanarak öğrenir.

Veri setinde pozitif görüntüler ilgilenilen nesneyi içerirken, negatif görüntüler arka planı temsil eder. İlk olarak her görüntüden I_i , $h \times h \times 3$ üç kanallı bir görüntü yama küme çıkartılır. Bütün görüntüler işlendikten sonra $Tr^{(1)}$ olarak tanımlanan veri seti oluşturulur. Tahsis edilen farklı alt eğitim kümelerinden rastgele olarak seçilen eğitim verilerinde bir dizi DVM filtresi öğrenilir. Her bir DVM filtresinin ağırlık vektörü $w \in \mathbb{R}^d$ ve bias değerleri $b \in \mathbb{R}$ aşağıdaki sınırlandırılmamış optimizasyon problemi optimize edilerek belirlenir.

$$\min_{w,b} w^T w + C \sum_{i=1}^l \xi(w, b; x_i, y_i) \quad (3.49)$$

C , ceza değişkeni olarak atanmıştır. L1-DVM ve L2-DVM referans alınarak karesel hinge maliyet fonksiyonu $\max(1 - y_i(w^T x^i + b), 0)^2$ kullanılmıştır. Daha basit bir şekilde ifade etmek amacıyla bias değerleri formülden atılmış ve DVM filtreleri formülün bu haliyle eğitilebilmektedir. Daha sonra, konvolüsyon tabakasının tüm ağırlıkları, dört boyutlu filtre kümesinde gruplandırılabilir. Konvolüsyon özellik haritasının oluşturulmasında her eğitim görüntüsü DVM filtreleri ile konvolüsyon işlemine girer. Görüntü üzerindeki konvolüsyon işlemi matematiksel olarak Eşitlik 3.50'de gösterilmiştir.

$$h_{ki}^{(1)} = f(I_i * w_k^{(1)}), \quad k = 1, \dots, n^{(1)} \quad (3.50)$$

Eşitlik 3.50’de bulunan h_{ki} elde edilen k . özellik haritasını gösterir. * operatörü konvolüsyon işlemini belirtir. f ise REDB aktivasyon fonksiyonudur. Şekil 3.37’de konvolüsyonel DVM katmanının algoritması yer almaktadır.



Şekil 3.37. Konvolüsyonel DVM katmanının algoritması

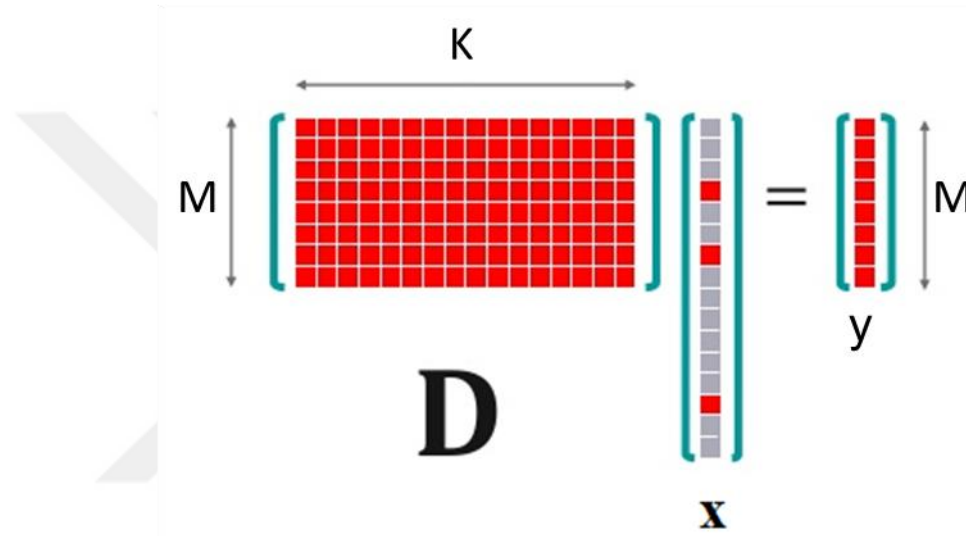
3.7.2. Havuzlama katmanı ve sınıflandırma

KDVM algoritmasında indirgeme katmanı, KSA yapılarındaki uzaysal havuzlama katmanına benzer yapılar kullanır. Genellikle, sonraki katmanlar için en faydalı özellikleri seçerek gösterimin uzaysal boyutunu küçültmek üzere iki ard arda gelen konvolüsyonel katmanlar arasına yerleştirilir. Temel olarak, konvolüsyonel özellik haritalarından küçük dikdörtgen bloklar alır ve her bloktan tek bir çıktı üretmek için bunları alt örneklemesini gerçekleştirir. Uzamsal indirgemeyi gerçekleştirmenin, ortalama ya da maksimum alma, ya da bloktaki değerlerin öğrenilmiş doğrusal bir kombinasyonu gibi birçok yol mevcuttur. Birkaç konvolüsyonel DVM ve havuzlama katmanından sonra, ağın son katmandan çıkarılan yüksek seviyeli özellikler üzerine ikili bir DVM sınıflandırıcısı eğitimi gerçekleştirilir.

3.8. Derin Sözlük Öğrenme

3.8.1. Seyrek gösterim

Seyrek gösterim modelinde elde edilmesi gereken y matrisi $M \times I$ boyutunda olup, öğrenilmesi gereken D sözlüğü $M \times K$ boyutundadır. D sözlük matrisine göre öğrenilmesi gereken x seyrek katsayı vektörü $K \times I$ boyutundadır. Seyreklik sentez modeli Şekil 3.38’de gösterilmektedir.



Şekil 3.38. Seyreklik sentez modeli

Modelde gösterildiği gibi D sözlüğü içerisinde K adet $M \times I$ boyutunda sözlük atomu bulunur. y matrisinin elde edilmesi için gereken gösterim $y=Dx$ veya $\|y-Dx\|_p \leq \epsilon$ koşulu dikkate alınmak üzere $y \approx Dx$ şeklinde güncellenebilir. Formül içerisindeki $\|\cdot\|_p$ işareti x seyrek gösteriminin l_p normu olarak isimlendirilir.

Seyreklik sentez modelinde seyrek katsayı vektörü ve sözlük matris çözümlenmesinin yapılması gerekir. Bu problem sözlük öğrenme problemi olarak bilinir ve problemin çözümü için iki aşama önerilir. Bu aşamalara başlamadan önce seyrek gösterim probleminin matematiksel olarak ifadesi Eşitlik 3.51’de gösterilmektedir.

$$\min_x \|x\|_0, \quad y = Dx \quad (3.51)$$

Formül içerisindeki $\|x\|_0$ ifadesi seyrek katsayı vektörü olan x vektörünün sıfır normunu ifade eder. Başka bir ifadeyle x vektöründeki 0'dan farklı elemanların sayısını vermektedir. Seyrek gösteriminin elde edilmesi için $\|x\|_0$ ifadesinin K değerinden çok küçük olması gerekir. Sözlükte 0'dan farklı değerlerin elde edilmesi amaçlanır. Optimize edilmesi gereken sözlük öğrenme problemi Eşitlik 3.52'deki gibi ifade edilir.

$$\min_{D,x} \|y - Dx\|_F^2, \quad \|x_i\|_0 = s \quad \forall i \quad (3.52)$$

Eşitlik 3.52'deki $\|\cdot\|_F$ Frobenius normunu ifade eder. Bu eşitliğin çözümünün ilk aşamasında seyrek gösterim matrisinin bulunması gerekir.

$$\min_{D,x} \|y_i - Dx_i\|_F^2, \quad \|x_i\|_0 = s \quad \forall i \quad (3.53)$$

Eşitlik 3.53'de seyreklik vektörünün güncellenmesi gerekir. s tasarımcı tarafından belirlenen seyreklik seviyesidir. Seyreklik katsayı vektörlerinin sözlük matrisi ile çarpımından elde edilen gösterim (Dx_i) ile hedeflenen veri olan (Chavushyan ve ark.) arasındaki karesel hatanın minimize edilmesi gerekir. Seyrek gösterim kodlamasında kullanılan algoritmalara Eşleşme Takip Algoritması, Dik Eşleşme Takip Algoritması, Temel Takip Algoritması ve Odaksal Düşük Tanımlı Sistem Çözümü yöntemi örnek verilebilir.

İkinci aşama olarak sözlük güncellemesi yer almaktadır. Bu aşamada birinci aşamada hesaplanan x seyrek gösterim matrisi kullanılarak D sözlük matrisinin güncellenmesi gerçekleştirilir.

$$\min_D \|y - Dx\|_F^2 \quad (3.54)$$

3.8.2. Sözlük öğrenme

Sözlük öğrenme algoritmasında bir işaret, sözlük ve seyrek katsayı vektörü ile seyreklik model sentezi gerçekleştirilir. Sentez kapsamında elde edilen sözlük

matrisinde atom adı verilen sütun vektörler bulunur. Seyrek gösterimin ana unsurlarından olan atomların birleşiminden seyrek katsayı vektörü ile yaklaşık işaret elde edilmeye çalışılır.

Hesaplanması gereken $M \times I$ boyutunda y işaretini elde etmek için $M \times K$ boyutundaki D sözlük matrisi ile $K \times I$ boyutunda olan x seyrek katsayı vektörüne göre $y=Dx$ veya $\|y-Dx\|_p \leq \epsilon$ koşulu kullanılır. Sözlük atomlarının gösterimini oluşturmak üzere seyrek gösterim ifadesi Eşitlik 3.55’de gösterilmektedir.

$$y' = \sum_{k=1}^K x(k)d_k = Dx \quad (3.55)$$

Eşitlik 3.55’de $x(k)$ ifadesi k . atomdaki seyrek katsayı değerlerini gösterir. Seyrek katsayı vektöründe temsillerin az sayıda eleman ile gösterilebilmesi için sıfırdan farklı elemanlarının sayısı oldukça az olmalıdır. Elde edilmesi gereken y işareti ile seyrek gösterim sonucunda elde edilen y' işareti arasındaki fark gösterim hatası olarak ifade edilir ve formülü Eşitlik 3.56’deki gibidir.

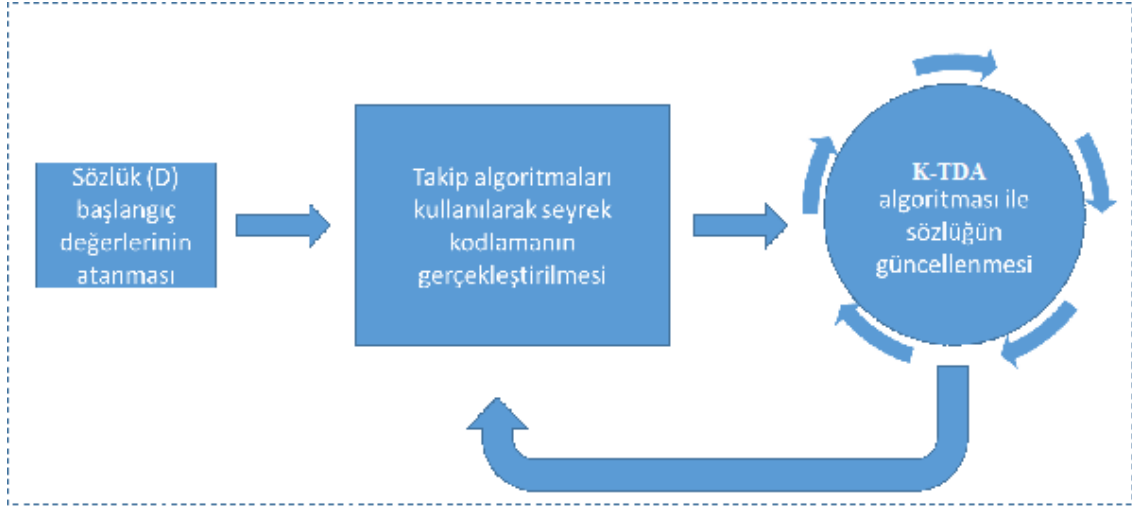
$$r = y - y' = y - Dx \quad (3.56)$$

Seyrek sentez modelin çerçevesinde uygun bir şekilde sözlük ve seyrek gösterim matrisinin elde edilmesi literatürde önerilen farklı algoritmalar ile iki aşamada gerçekleştirilir. Bu aşamalar seyrek kodlama ve sözlük güncellemesidir. Bu işlem derin sözlük öğrenme kapsamında kullanılan K-Tekil Değer Ayırıştırması (K-TDA) yöntemi ile gerçekleştirilmiştir.

3.8.3. K-TDA algoritması

K-TDA algoritması hedeflenen işaretin seyrek temsillerinin ve sözlük matrisinin elde edilebilmesi için kullanılan bir algoritmadır. Temelde K-ortalama metodunu kullanarak işlem yapmaktadır. Sözlük öğrenmede optimizasyon eşitliği olarak Eşitlik 3.52’nin çözümü gerçekleştirilir. Problemin çözümü sonucunda en iyi sözlük matrisi ve en iyi seyrek gösterim matrisinin elde edilmesi amaçlanır. K-TDA algoritmasında

optimizasyon fonksiyonundaki hatayı en aza indirmek için döngüsel bir işlem uygulanır. K-TDA algoritmasının şematik gösterimi Şekil 3.39’de gösterilmektedir.



Şekil 3.39. K-TDA algoritmasının basit şeması

Sözlük öğrenmede optimum değerlere sahip seyrek katsayı matrisinin elde edilmesi söz konusu olmadığından yaklaşık çözümler elde edilir. K-TDA algoritmasında ilk olarak seyrek kodlama işlemi yapılır ve sonrasında seyrek kodlama matrisi x sabit tutularak sözlük D güncellemesi gerekir. Sözlük matrisinde bulunan atomlar güncellenerek hata oranı en aza indirilmeye çalışılır. Seyreklik katsayılarında K-TDA algoritması kullanarak gerçekleştirilen güncelleştirme işlemi ile K-ortalamlar algoritmasıyla yapılan güncelleştirme tekniği arasında büyük farklılıklar bulunur. Sözlük öğrenmede kullanılan K-ortalamlar algoritması uygulanırken seyrek katsayı matrisi değiştirilmeden sözlük güncelleştirilmesi gerçekleştirilir. K-TDA algoritmasında ise her adımda sıralı bir şekilde hem sözlük hem de seyrek katsayı matrisi güncelleştirilir. Bu sıralı güncelleme ile beraber elde edilen seyrek katsayılar ve sözlükler işareti daha çok yakınsar. K-TDA algoritmasında kullanılan fark ifadesi Eşitlik 3.57’de verilmiştir.

$$\|y - Dx\|_F^2 = \sum_{i=1}^N \|y_i - Dx\|_2^2 \quad (3.57)$$

Fark denklemini ayrık bir optimizasyon problemine dönüştürmek için kullanılacak formül Eşitlik 3.58’de verilmiştir.

$$\min_{x_i} \{ (\| y_i - Dx_i \|_2^2) \} , \quad \| x_i \|_0 \leq T_0, \quad i = 1, 2, \dots, N. \quad (3.58)$$

Eşitlik 3.58'in çözümü için takip algoritması kullanılması gerekir. Optimum bir çözümün elde edilebilmesi için eşik değeri olan T_0 değerinin olabildiğince küçük seçilmesi gerekmektedir.

Sözlük matrisindeki değerlerin güncellenmesinde sıfırdan farklı katsayıların yeniden hesaplanması gerekir. Bu işlemde ilk olarak D sözlük matrisi sabit tutulur ve x katsayı matrisi güncellenir. Sonrasında x katsayı matrisi sabit tutulup D sözlük matrisi güncellenir. Eşitlik 3.57'de gösterilen fark ifadesinin modifiye edilmiş hali Eşitlik 3.59'da gösterilmiştir.

$$\| y - Dx \|_F^2 = \| y - \sum_{i=1}^K d_j x_T^j \|_F^2 = \| E_k - d_k x_T^k \|_F^2 \quad (3.59)$$

Eşitlik 3.59'da E_k , k . atomu dikkate almadan N adet örnekten elde edilen hatayı temsil eder. d_k ve x_T^k vektörleri K-TDA algoritması ile hesaplanmıştır. Bu vektörlerin elde edilmesinde E_k hatasının en aza indirilmesi gerekir. k . atomun güncellenmesi esnasında x_T^k vektörü rastgele bir şekilde bulunur. Bu aşamada bazı problemler ile karşılaşmaktadır. Problemin çözümü için sezgisel bir yöntem önerilir. Eşitlik 3.60'da kullanılan w_k vektörü x_T^k vektörünün sıfır olmayan indis bilgilerini barındırır.

$$w_k = \{i \mid 1 \leq i \leq K, \quad x_T^k(i) \neq 0\} \quad (3.60)$$

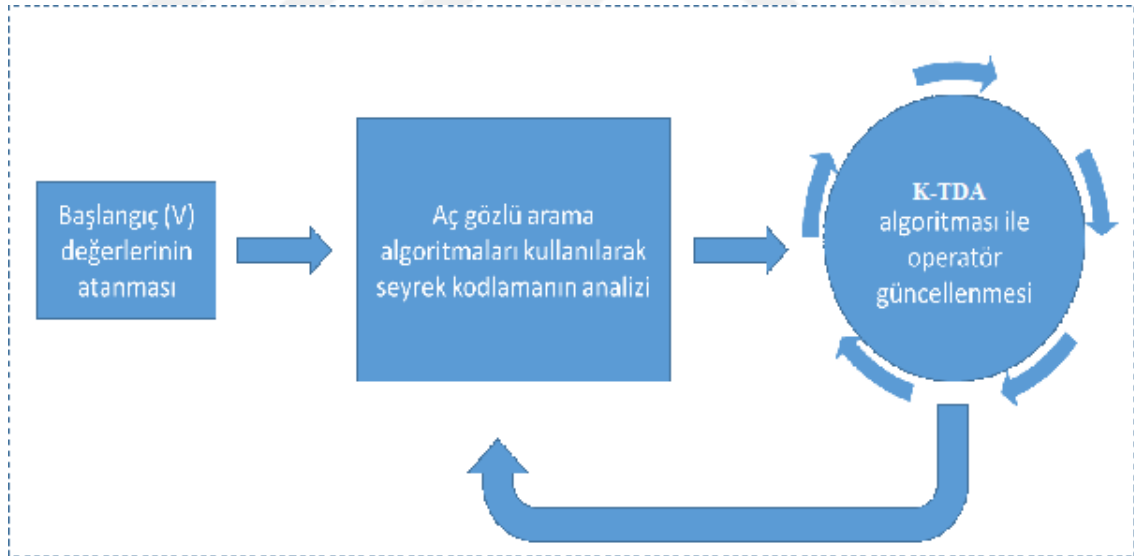
Eşitlik 3.60'da bulunan w_k vektörü sıfırdan farklı değerleri içerirken, V_k matrisinin sıfır değerlerini bulunduran vektör olarak da tanımlanır. V_k ile x_T^k matrislerinin çarpımından x_T^k 'den daha küçük bir boyutta x_{R^k} vektörü elde edilir. V_k matrisinin örnek kümesi ile çarpımlarından ise alt örnek kümeleri oluşturulur ve Y_{R^k} ile temsil edilir. Benzer bir şekilde V_k matrisi E_k matrisi ile çarpıldığında her örneğe karşılık gelen hata değeri E_{R^k} elde edilir. Eşitlik 3.59 x_{R^k} çözümüne göre tekrar düzenlendiğinde Eşitlik 3.61 elde edilir.

$$\|E_k V_k - d_k x_T^k V_k\|_F^2 = \|E_k^R - d_k x_R^k\|_F^2 \quad (3.61)$$

Eşitlik 3.61 üzerine doğrudan TDA algoritması uygulanabilir. TDA algoritması ile $E_k^R = U \Delta V_T$ dönüşümü elde edilir. Bu ayrıştırma işlemi sonucunda U matrisinin ilk sütunu güncellenmiş d_k atomunu ifade eder. V matrisinin ilk sütunu ile $\Delta(1,1)$ ifadesinin çarpımı ise güncel seyrek katsayı vektörünü x_R^k verir. d_k vektörünün elde edilmesi için kullanılan ifade Eşitlik 3.62’de verilmiştir.

$$d_k = \frac{E_k^R x_R^{kT}}{x_R^k x_R^{kT}} x_R^k = \frac{d_k^T E_k^R}{d_k^T d_k} \quad (3.62)$$

Analiz K- TDA algoritması, K- TDA algoritmasına benzer bir şekilde çalışan ve analiz sentezlik modelindeki operatörün belirlenmesi için kullanılan bir döngüsel algoritmadır. Analiz K-TDA algoritmasının çalışma prensibi Şekil 3.40’da gösterilmiştir.




Şekil 3.40. Analiz K-TDA algoritmasının basit şeması

3.8.4. Kısıtlı boltzman makinesi


Kısıtlı Boltzman Makinesi (KBM) denetimsiz olasılıksal sinir ağları modellerinden biridir. KBM’nin kullanımı, derin ağların başarısı kanıtlandıktan sonra daha da artmıştır. Derin yapılarda gizli nöron ağları ile özellik çıkarımı gerçekleştirilir.

KBM, Sınırsız Boltzman Makinelerinde türetilmiş bir yapıdır. Şekil 3.41’de Sınırsız Boltzman Makinesinin şematik gösterimi verilmiştir.



Şekil 3.41. Dört görünür katmanı ve iki gizli katmanı bulunan sınırsız boltzman makinesi

İkili sınıflandırmalarda daha çok kullanılan KBM yapısında Sınırsız Boltzman makinelerinden farklı olarak görünür katmalardaki nöronlar arasında herhangi bir bağlantı bulunmamaktadır. Aynı zamanda gizli nöronlar arasında da herhangi bir bağlantı bulunmamaktadır. Şekil 3.42’de görünür ve gizli katmanlardan oluşan KBM yapısı gösterilmiştir.



Şekil 3.42. Dört görünür katmanı ve dört gizli katmanı bulunan kısıtlı boltzman makinesi

$$E(v, h) = -\sum_i a_i v_i - \sum_j b_j h_j - \sum_i \sum_j v_i w_{ij} h_j \quad (3.63)$$

Bu eşitlikte a_i görünür katmandaki i . nöronun bias değerini gösterir. Gizli katmandaki j . nörondaki bias değeri b_j olarak ifade edilir. w_{ij} aralarındaki ağırlıkları gösterir. Görünür nöronların olasılıksal hesabı Eşitlik 3.64’deki gibi gerçekleştirilir.

$$p(v) = \frac{1}{z} \sum_h e^{-E(v,h)} \quad (3.64)$$

z ifadesi, görünür ve gizli birimlerin olası tüm konfigürasyonlarının toplanmasıyla hesaplanan normalleştirme faktörüdür. Gözlenen değişkenler girdi olarak görünür birimlere beslendikten sonra, KBM'deki stokastik birim 1 değerine sahip olma olasılığına sahiptir.

$$p(h_j = 1 | v) = \sigma(b_j + \sum_i v_i w_{ij}) \quad (3.65)$$

Gizli birimlerin ikili halleri kullanılarak, görünür birimlerin yeniden yapılandırılmış ikili halleri $\sigma(x) = 1/(1+e^{-x})$ ifadesinden yararlanılarak Eşitlik 3.66'ye göre hesaplanır.

$$p(v_i = 1 | h) = \sigma(a_i + \sum_j h_j w_{ji}) \quad (3.66)$$

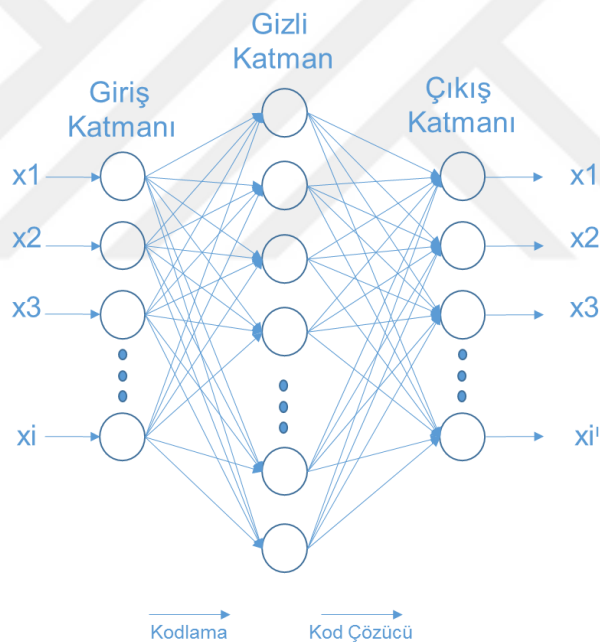
Bir KBM'nin her bir eğitim aşaması, bir kodlama-kod çözme işlemi olarak da adlandırılabilen iki faza sahiptir. İlk aşamada, gizli değerler bir kodlama işlemi olarak Eşitlik 3.65'e göre hesaplanmaktadır. Sonra görünür birimlerin, gizli değerleri kullanarak gözlemlenen girdi değerlerinin yeniden yapılandırılması ile kod çözme aşaması yapılır. Gözlenen değişkenler ve yeniden yapılandırılmış değerler arasındaki fark, ağırlıkların güncelleme hesabını belirler. Eğitim süresince yapılan bu işleme tek adımlı zıt yakınsama algoritması (Single Step Contrastive Divergence-CD-1) denir. CD-1 algoritması ile KBM, giriş verilerinden bir dizi özellik çıkarır. CD-1 algoritmasında, bir sonraki girişe önceden belirlenmiş eşik değerinin bir hanesine ulaşana kadar tekrar tekrar verilir ve böylece ağırlık vektörü optimize edilir. CD-1 algoritması ile ağırlık güncellemesi Eşitlik 3.67'ye göre yapılır.

$$\Delta w = \varepsilon (\langle v_i h_i \rangle^0 - \langle v_i h_i \rangle^1) \quad (3.67)$$

ε ifadesi öğrenme oranıdır. Öğrenme oranının seçimi oldukça önemlidir. Öğrenme oranının küçük bir değer olarak seçilmesi yavaş bir yakınsama ile sonuçlanırken, büyük bir değer seçilirse yakınsamayı geçebilir. $\langle v_i h_j \rangle^0$ giriş stokastik değerlerinin dış ürünü ve üretilen gizli değerlerdir. $\langle v_i h_j \rangle^1$ yeniden yapılandırılmış görünür birimlere karşılık gelen ve üretilmiş gizli değerlerin dış ürünüdür.

3.8.5. Yığın otomatik kodlayıcı

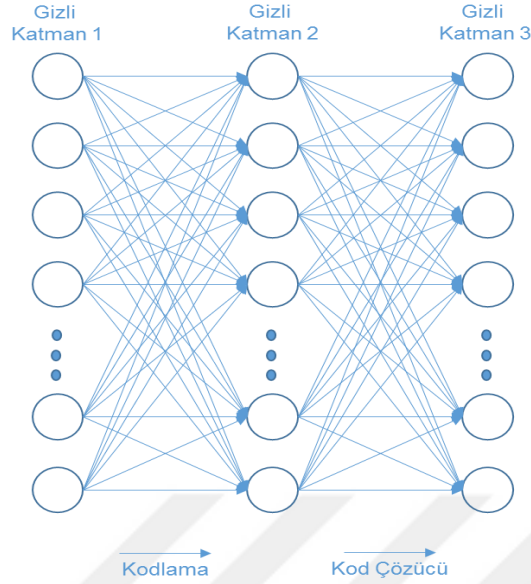
Bir otomatik kodlayıcı, kendi girdilerini yeniden yapılandırmayı amaçlayan yapay bir sinir ağı türüdür. Bu nedenle, girişin etkin bir şekilde kodlanması mümkündür veya gizli birimlerin sayısı giriş birimlerinin sayısından daha az olduğunda boyut azaltımı için kullanılabilir.



Şekil 3.43. Otomatik kodlayıcı modeli

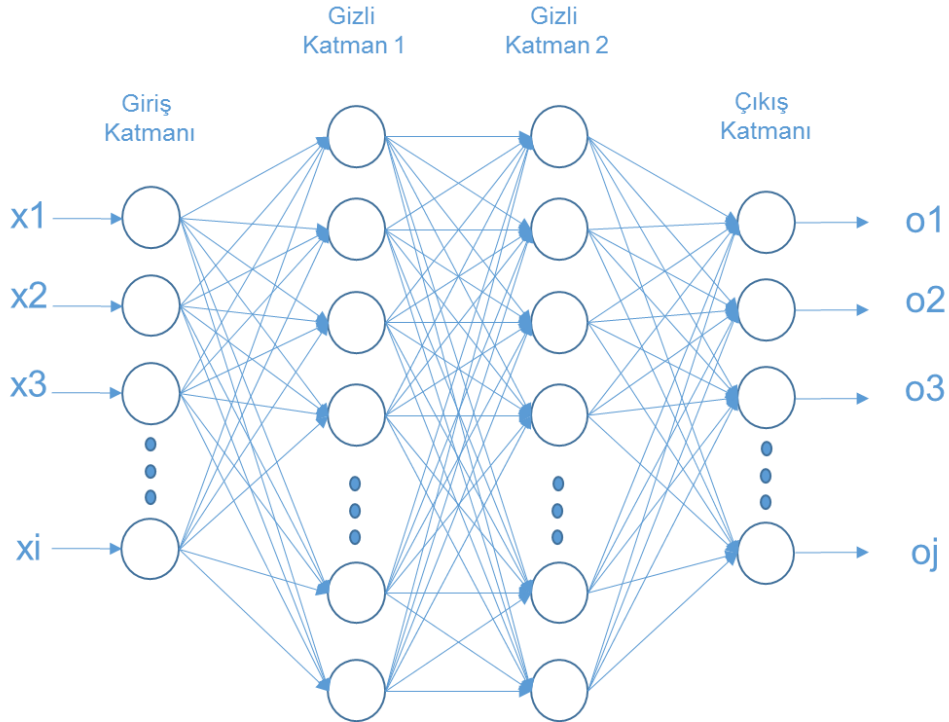
Oto kod çözücü modelinde Şekil 3.43'de çıkış hedef değerlerini elde etmek için girdi değerlerine göre eğitim yapılır. Ağırlıklar, giriş değerleri ile üretilen değerler arasındaki farka göre güncelleme işlemi yapılır. Yığın otomatik kodlayıcıların elde edilmesi için, model eğitildikten ve ağırlık değerleri belirlendikten sonra çıktı katmanı çıkarılır ve ek olarak gizli katmanlar eklenir. Bu durumda gizli katmandaki çıktı ağırlıkları yeni gizli katmanın girdisi olur. Oluşturulan modelde yeni girdi değerlerini

tekrar oluşturmak için modelin eğitilmesi gerekir. Bu işlem açgözlü arama algoritması tarafından yığın otomatik kodlayıcının değişkenlerini elde etmek için kullanılır.



Şekil 3.44. Otomatik kodlayıcı modelinde gizli katman yapıları

Model eğitiminde Gizli Katman 1 eğitimi tamamlandıktan sonra Gizli Katman 2 ağırlık değerlerinin belirlenmesi işlemine geçilir. Bu şekilde, gerekli gizli katmanlar sayısı açgözlü arama algoritması kapsamında birbiri ardına eklenebilir. İki katmanlı otomatik yığın otomatik kodlayıcı Şekil 3.45’de gösterilmiştir.

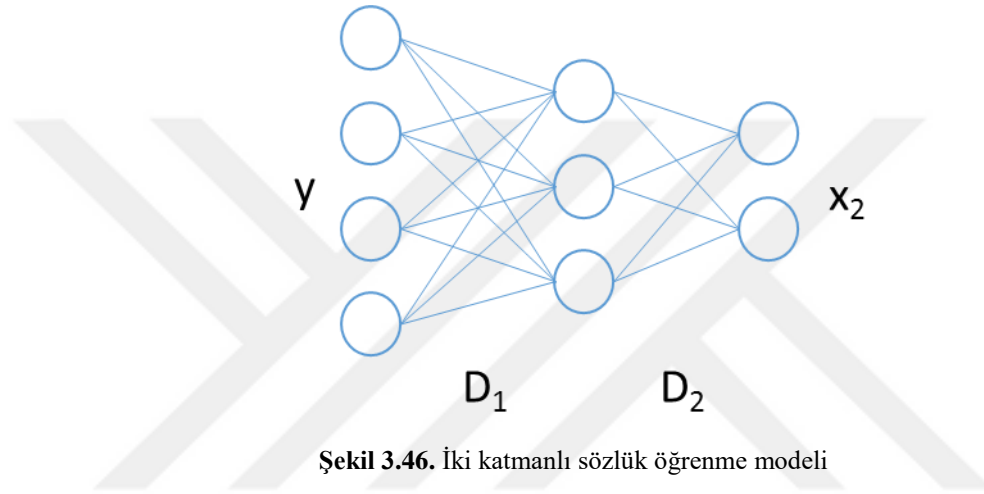


Şekil 3.45. İki katmanlı yığın otomatik kodlayıcı modeli

Şekil 3.45 dikkate alınarak istenilen gizli katman sayısı belirlenip son gizli katmana çıkış katmanı eklenir. Modeldeki değişkenleri belirlemek için denetimli bir öğrenmenin kullanılması gerekir.

3.8.6. Derin sözlük öğrenme algoritması

Derin sözlük öğrenme fikri derin öğrenme algoritmalarının başarısından esinlenerek ortaya çıkmıştır. Eşitlik 3.52'deki tek katmanlı sözlük öğrenme formülü esas alınarak iki katmanlı sözlük öğrenme modeli Şekil 3.46'da verilmiştir.




Şekil 3.46. İki katmanlı sözlük öğrenme modeli

İki katmanlı sözlük öğrenme yapısını matematiksel olarak modellemek gerekirse Eşitlik 3.68 elde edilir.

$$y = D_1 D_2 x_2 \quad (3.68)$$

İki seviyeli sözlük öğrenme yapısında öğrenilen seyrek katsayılar ile tek seviyeli sözlük öğrenme ile elde edilen seyrek katsayılar birbirinden farklıdır. Eşitlik 3.52'deki problem (tek seviyeli) iki-doğrusal bir problemdir. Eşitlik 3.68'deki problem ise (iki seviyeli) üç-doğrusal bir problemdir. Bu nedenle, tek seviyeli sözlük öğrenmesinden ve daraltılmış iki seviyeli bir sözlük öğrenmesinden aynı özelliklerin elde edilmesi beklenemez. Birden fazla sözlük seviyesinin tek seferde öğrenilmesinde bir takım zorluklar bulunmaktadır. Çok katmanlı sözlük öğrenme yapılarında bu yakınsama daha zordur. Aynı zamanda birden fazla sözlük katmanı eş zamanlı olarak öğrenildiğinde çözülmesi gereken parametrelerin sayısı artar. Derin sözlük öğrenme yapılarında

yakınsamayı garantilemek amacıyla açgözlü arama algoritmaları kullanılmaktadır. Ayrıca, katmanlı öğrenmede her katmanda kullanılan açgözlü arama algoritması ile yakınsama sağlanacaktır. Katmanlı öğrenmeyi gösteren model Şekil 3.47'de gösterilmiştir.



Şekil 3.47. Katmanlı sözlük öğrenme

Önerilen yapıyı genişleterek, doğrusal olmayan aktivasyon fonksiyonu (φ) ile çok seviyeli bir sözlük öğrenme problemi Eşitlik 3.69 ile tanımlanabilir.

$$y = D_1 \varphi(D_2 \varphi(\dots \varphi(D_N x_N))) \quad (3.69)$$

Eşitlik 3.69'un çözümü için optimizasyon formülünü elde etmek gerekirse Eşitlik 3.70 kullanılır.

$$\min_{D_1, \dots, D_N, x} \| y - D_1 \varphi(D_2 \varphi(\dots \varphi(D_N x))) \|_F^2 + \mu \| x \|_1 \quad (3.70)$$

Konveks olmayan optimizasyon probleminde hesaplanması gereken bazı parametreler vardır. Bu nedenle, derin öğrenme yapısında her katman için ayrı bir öğrenme gereklidir. Optimizasyon fonksiyonu $x_1 = \varphi(D_2 \varphi(\dots (D_N x_N))$ olarak değiştirilmiştir. Optimum çözüm, tek katmanlı bir sözlük öğrenmesinde alternatif küçültme yaklaşımı ile gerçekleştirilir. Bu nedenle, D ve x değişkenleri şu şekilde öğrenilir:

$$x_1 \leftarrow \min_x \| y - D_1 x_1 \|_F^2 \quad (3.71)$$

$$D_1 \leftarrow \min_D \| y - D_1 x_1 \|_F^2 \quad (3.72)$$

İkinci gizli katmandaki seyrek katsayı gösterimi $x_2 = \varphi(\dots(D_N \cdot x_N))$ ile ifade edilir. Eğer birinci katmana göre belirtilen ifade tekrardan düzenlenirse $x_1 = \varphi(D_2 x_2)$ veya $\varphi^{-1}(x_1) = (D_2 x_2)$ denklemleri elde edilir. Denklemlerdeki değişkenleri hesaplamak için Eşitlik 3.73'de bulunan minimizasyon probleminin çözümü gerekmektedir.

$$\min_{D_2, x_2} \| \varphi^{-1}(x_1) - D_2 Z_2 \|_F^2 \quad (3.73)$$

Derin sözlük öğrenme yapısında doğrusal yapıdaki öğrenmeyi engellemek amacıyla aktivasyon fonksiyonları kullanılır. Seyrek katsayıların doğru bir şekilde öğrenilebilmesi için bu işlem önemlidir. Aynı zamanda derin sözlük öğrenmedeki sözlük matrisi boyutları da öğrenilen sözlük sayısını etkiler. Derin sözlük öğrenmenin eğitim ve test aşamalarının pseudo kodu Şekil 3.48'de verilmiştir.

Eğitim Algoritması
Sözlüklerin başlangıç değerlerinin atanması $D_i, i=1, 2, \dots, N$
İlk katmanda sözlük öğrenmenin gerçekleştirilmesi
$x_1 \leftarrow \min_x \ y - D_1 x_1 \ _F^2$
$D_1 \leftarrow \min_D \ y - D_1 x_1 \ _F^2$
Gizli katmanlarda sözlük öğrenmenin gerçekleştirilmesi
$x_i \leftarrow \min_{x_i} \ \varphi^{-1}(x_{i-1}) - D_i x_i \ _F^2$
$D_i \leftarrow \min_{D_i} \ \varphi^{-1}(x_{i-1}) - D_i x_i \ _F^2$
Son katmandaki sözlük öğrenmenin gerçekleştirilmesi
$x_N \leftarrow \min_{x_N} \ \varphi^{-1}(x_{N-1}) - D_N x_N \ _F^2 + \lambda \ x_N \ _1$
$D_N \leftarrow \min_{D_N} \ \varphi^{-1}(x_{N-1}) - D_N x_N \ _F^2$
Test Algoritması
$D = D_1, D_2 \dots D_N$
y_{test} test örneklerinin seyrek gösterimlerinin hesaplanması
$x_{test} \leftarrow \min_{x_{test}} \ x_{test} - D x_{test} \ _2^2 + \lambda \ x_{test} \ _1$

Şekil 3.48. Derin sözlük öğrenmenin eğitim ve test aşamalarının pseudo kodu


3.9. Nesne tanıma tabanlı konvolüsyonel sinir ağları

3.9.1. You only look once (YOLO)

J. Redmon ve ark. tarafından önerilen YOLO mimarisi bir görüntüdeki nesnelere ve konumlarını tespit etmek için tasarlanmıştır (Redmon J., 2016). YOLO, Algılanan nesnelere etrafına sınırlayıcı çerçeveler çizer ve aynı anda birden fazla nesneyi algılayabilir. Diğer algoritmalar ise nesnelere sınıflandırabilmek ve algılayabilmek için görüntü üzerinde çok katmanlı görevleri yerine getirir. Ancak YOLO'yu çok hızlı ve performanslı yapan unsur tek bir ağ geçişinde algılama yapmasıdır.

Darknet yapısı KSA'larının eğitim çerçevesini sunar. Aynı zamanda YOLO'nun eğitimi için temel bir yapı görevi görür. Darknet mimarisi açık kaynak kodlu, C / CUDA ile yazılmış olup hem MIB hem de GIB hesaplamalarını destekler.

YOLO, nesnelere sınıf olasılıklarını tahmin edebilir ve tek bir değerlendirme ile sınırlayıcı çerçeveleri çizebilir. YOLO modelinin sadeliği, tahminleri gerçek zamanlı olarak gerçekleştirmesini sağlar. YOLO ağı 24 adet konvolüsyon katmanı ve bunu takiben 2 tam bağlantılı katmandan oluşur. Şekil 3.49'da gösterildiği gibi YOLO algoritması görüntüyü girdi olarak alır ve $S \times S$ boyutlarda ızgaralara böler. Izgaranın her hücresi bir güven değeri ile N sınırlayıcı çerçevelerini tahmin eder.




Şekil 3.49. YOLO algoritması

3.9.2. Hızlı bölgesel tabanlı konvolüsyonel sinir ağları

Ross Girshick tarafından Bölgesel tabanlı Konvolüsyonel Sinir Ağları (B-KSA) mimarisini baz alarak nesne tespiti problemlerinin çözümü için Hızlı B-KSA adlı daha hızlı bir algoritma geliştirmiştir (Girshick R., 2014). Hızlı B-KSA, havuzlama bölgelerinin çakışması dışında, mimari içerisindeki parametreleri güncellemek için geri yayılım algoritması kullanmaktadır. Bu sayede bir hücre birden fazla bağlantıdan beslenen gradyan değerlerine sahip olabilir. Ayrıca, Hızlı B-KSA sınırlayıcı çerçeveyi eğitmek için regresyon analizi, nesnenin ait olduğu sınıfı belirleyebilmek için de softmax kullanılır.

Hızlı B-KSA mimarisinin, B-KSA mimarisinden daha hızlı olmasının nedeni KSA yapısına nesnenin bulunabileceği bölge önerilerinin fazla sayıda girdi olarak verilmemesidir. Bunun yerine konvolüsyon işlemi her görüntüye ayrıca uygulanır ve özellik haritaları oluşturulur. Hızlı B-KSA mimarisi Şekil 3.50’de gösterilmektedir.

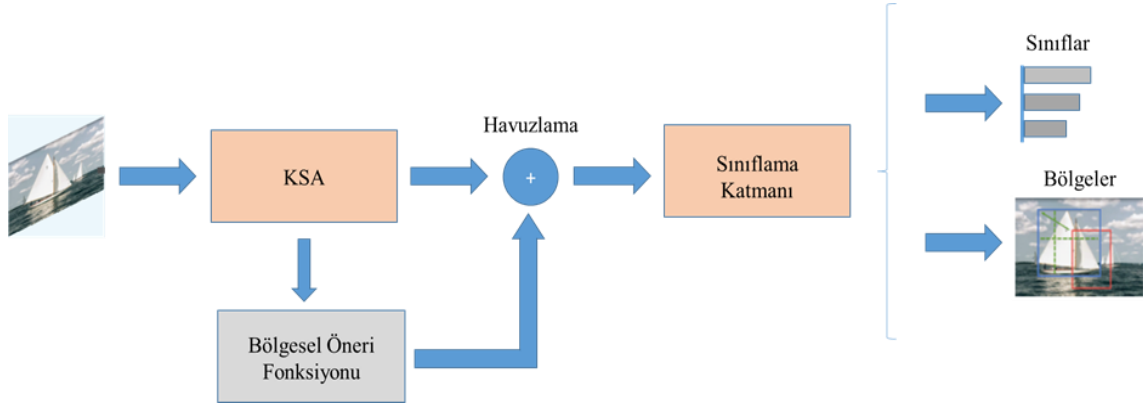


Şekil 3.50. Hızlı B-KSA mimarisi

3.9.3. Daha hızlı-bölgesel tabanlı konvolüsyonel sinir ağları

Bölge önerilerini tespit etmek için B-KSA ve Hızlı B-KSA tarafından kullanılan seçici arama algoritması, ağın performansını etkileyen yavaş ve zaman alıcı bir süreçtir. Bu nedenle, Gandhi tarafından önerilen seçici arama algoritmasını ortadan kaldıran ve ağı bölge tekliflerini öğrenmesini sağlayan Daha Hızlı B-KSA adı ile bir nesne algılama algoritması geliştirilmiştir. Hızlı B-KSA'ya benzer şekilde, giriş görüntüsünden özellik haritası sağlayan konvolüsyonel bir ağ olarak tasarlanmıştır. Bölge önerilerini belirlemek için özellik haritasında seçici arama algoritması kullanmak yerine, bunun için ayrı bir ağ kullanılır. Öngörülen bölge teklifleri daha sonra önerilen

bölge içindeki görüntüyü sınıflandırmak ve bölge kutuları için başlangıç değerlerini tahmin etmek için bir havuzlama katmanı kullanılarak yeniden şekillendirilir (Ren, 2015). Daha Hızlı B-KSA mimarisi Şekil 3.51’de gösterilmektedir.



Şekil 3.51. Daha Hızlı B-KSA mimarisi

3.10. Nvidia Jetson TX2 Modülü

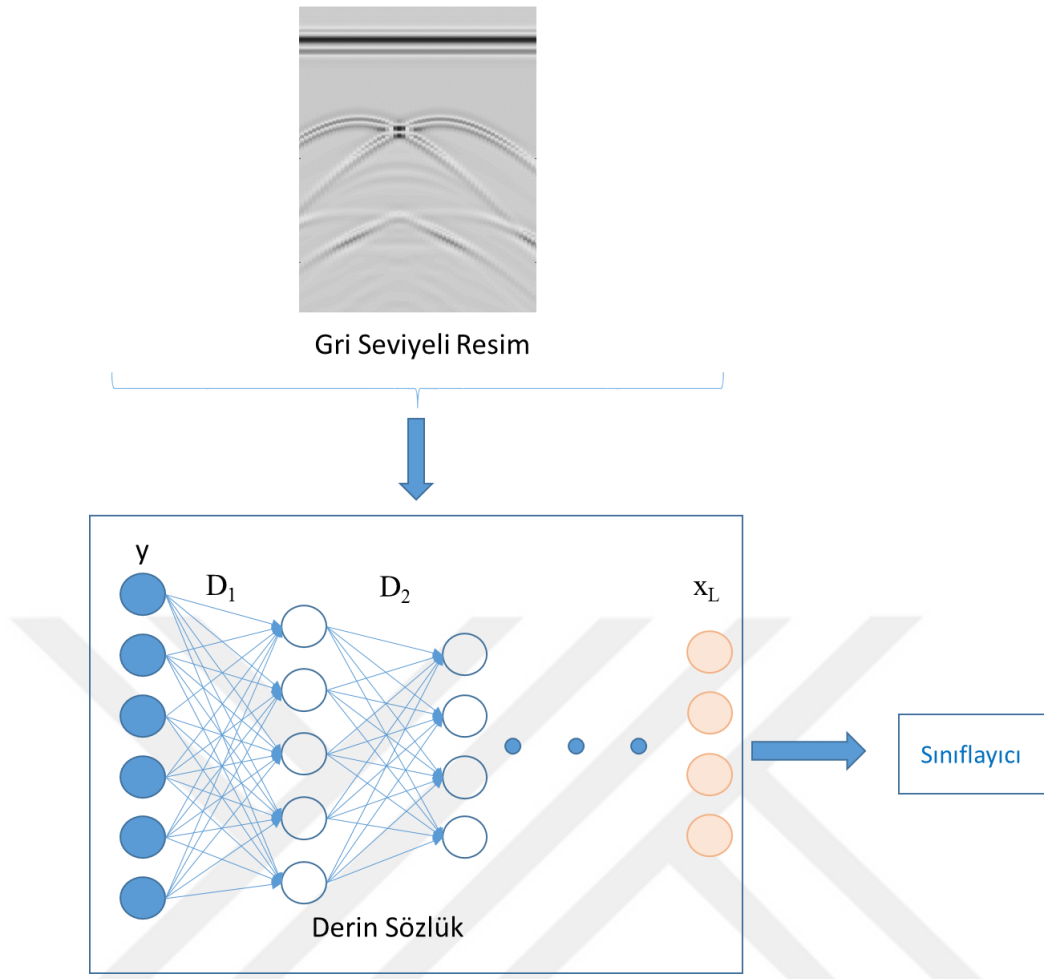
Tez çalışmasında tasarlanan modelin test işlemleri Nvidia Jetson TX2 modülü üzerinde NVIDIA Pascal, 256 CUDA çekirdekli GİB üzerinde gerçekleştirilecektir. Kit üzerinde 8 GB RAM bulunmaktadır. Geliştirme için Python programlama dili mevcuttur. Derin öğrenme kütüphanesi olarak arka planında TensorFlow kütüphanesi ile birlikte çalışan Keras kullanılır. 32 GB dahili hafızası bulunmaktadır. Ayrıca altı kamera girişi bulunan kart üzerinde USB bağlantı girişleri mevcuttur. Şekil 3.52’de gösterilen Jetson TX2 modülü tez kapsamında uygulama platformu olarak kullanılmıştır.



Şekil 3.52. Nvidia Jetson TX2 modülü

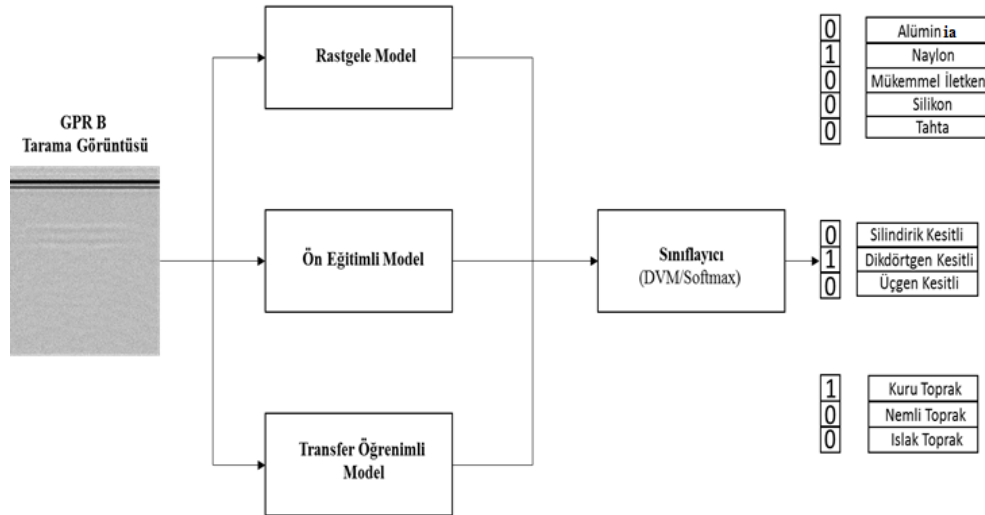
3.11. Önerilen Yöntemler

Tez kapsamında birbirinden farklı özelliklere sahip dört adet veri seti bulunmaktadır. İlk veri seti toplamda 180 adet GPR B Tarama görüntüsüne sahip olup konvolüsyonel sinir ağlarının eğitimi için yeterli veriye sahip değildir. Konvolüsyon sinir ağları veri sayısı arttıkça genelleme yeteneği artan bir yöntemdir. Bu sebeple ilk veri seti için daha iyi performans gösteren derin sözlük öğrenme yapısı kullanıldı. Derin sözlük öğrenme yapısında her bir katman kendi içerisinde güncelleme yaptığı için diğer derin öğrenme yapılarına göre daha hızlı bir şekilde çözümlere yakınsayabilir. Ayrıca, görüntü, sözlük ve seyrek temsil boyutu, hesaplama zamanı üzerinde doğrudan bir etkiye sahiptir. Bunun yanı sıra, derin sözlük yapısındaki gizli katmanların sayısı, ağ performansını etkileyen başka bir faktördür. Giriş katmanından gizli katmana doğru sözlük ve seyrek gösterim matrisinin boyutu giderek azaldığından son katmanlardaki güncelleme daha hızlı yapılır. Gizli katmanlar, farklı sınıflara göre sözlükler oluşturur ve eğitim sırasında her bir sınıf için ayrı bir sözlük öğrenir. Bununla birlikte, her katmanda farklı atomlar öğrendiği için sınıflama aşamasında gereken seyrek gösterim matrisi daha uygun şekilde oluşturulur. Ağ yapısındaki doğrusallaşma problemini engellemek amacıyla her katmanın çıkışına aktivasyon fonksiyonu ile işlem yapılır. Bu çalışmada, GprMax programı ile elde edilen GPR B-tarama görüntülerinin analizi için derin bir sözlük öğrenme yapısı önerilmiştir. Önerilen yöntem modeli Şekil 3.53'de gösterilmiştir. Önerilen derin sözlük öğrenme yapısı farklı katman sayıları ve sınıflandırıcılar kullanılarak karşılaştırmalı performans analizi gerçekleştirilmiştir.



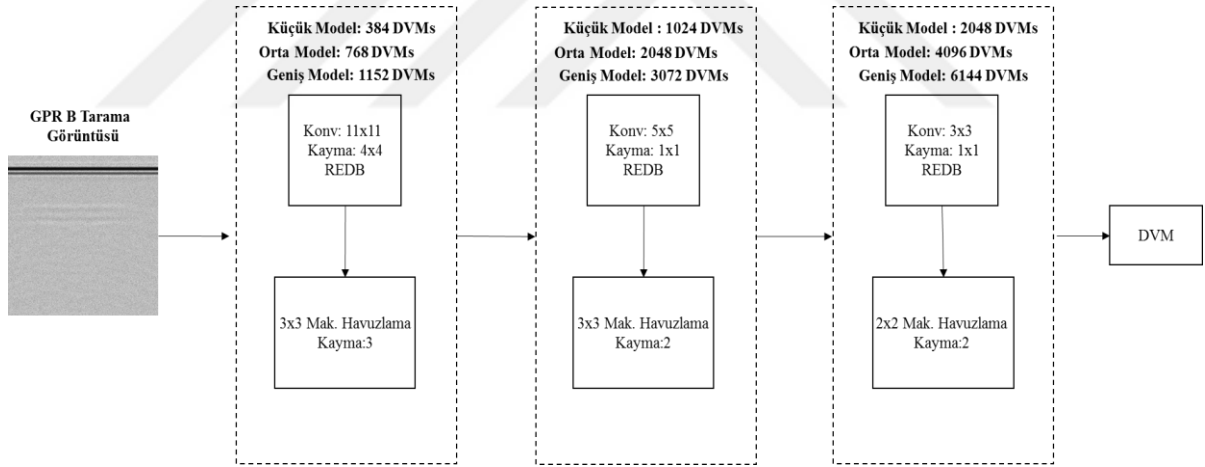
Şekil 3.53. Önerilen derin sözlük öğrenme yapısı

İkinci veri setinde toplamda 4280 adet GPR B tarama görüntüsü bulunmaktadır. Bu veri konvolüsyonel sinir ağlarının eğitimi için oldukça uygun yapıdadır. Bu verilerin 2140 adet görüntüsü eğitim için geri kalan 2140 adet görüntü de test için kullanılmıştır. Eğitim verilerinin modeller üzerindeki hassasiyeti test etmek amacıyla eğitim verileri 267, 535, 1070, 1605 ve 2140 adet şeklinde ayrılmış ve bu veri sayıları ile eğitimler gerçekleştirildi. Aynı zamanda konvolüsyonel sinir ağları rastgele, ön eğitilmiş ve transfer öğrenimli yapıları kullanılarak üç farklı model yapıları ile eğitimler gerçekleştirildi. Konvolüsyonel sinir ağ yapıları olarak AlexNet, VGG-16, GoogleNet, ResNet50 ve SqueezeNet kullanılmıştır. Bunun yanı sıra modeller üzerinde sınıflandırıcıların etkisini görmek amacıyla softmax ve DVM kullanılmıştır. Şekil 3.54’de önerilen konvolüsyonel sinir ağları yapısı gösterilmiştir.



Şekil 3.54. Önerilen konvolüsyonel sinir ağı yapısı

Bununla birlikte KDVM yapıları kullanarak da eğitimler yapılmıştır. KDVM'ler küçük, orta ve geniş ölçekli yapılar tasarlanarak eğitimler yapılmıştır. Şekil 3.55'de önerilen KDVM yapıları sunulmuştur.




Şekil 3.55. Önerilen konvolüsyonel destek vektör makineleri yapıları

Şekil 3.55'de gösterilen küçük, orta ve geniş KDVM model incelendiğinde kullanılan DVM filtre ağırlık sayıları farklılık göstermektedir. Küçük modellerin ilk konvolüsyonel DVM katmanına bakıldığında 384 adet DVM filtre ağırlığı (DVMs) bulunmaktadır. İkinci konvolüsyonel DVM katmanında 1024 adet ve üçüncü katmanda ise 2048 adet DVMs bulunmaktadır. Orta KDVM modelinde katman sırasına göre 768, 2048 ve 4096 adet DVMs filtre ağırlığı bulunmaktadır. Geniş KDVM modelinde sırasıyla 1152, 3072 ve 6144 adet DVMs filtresi bulunmaktadır. İlk konvolüsyonel

DVM katmanında filtreler 11×11 boyutundadır. Kayma adımı 4×4 olarak belirlenmiştir. Sonrasında ise REDB aktivasyon fonksiyonu bulunmaktadır. İlk konvolüsyon DVM katmanının çıkışında 3×3 boyunda ve 3 kayma adımına sahip maksimum havuzlama katmanı bulunmaktadır. İkinci konvolüsyonel DVM katmanında filtreler 5×5 boyutunda olup kayma adımı 1×1 olarak belirlenmiştir. Ayrıca, elde edilen özellik haritaları REDB aktivasyon işleminde geçirilmektedir. İkinci konvolüsyonel DVM katmanının çıkışına 3×3 boyutunda 2 kayma adımına sahip maksimum havuzlama işlemi uygulanmaktadır. Son katman olan üçüncü konvolüsyonel DVM katmanında 3×3 boyutunda filtreler bulunmaktadır. Kayma adımları 1×1 boyutunda olup REDB aktivasyon işlemi uygulanmaktadır. Çıkışlarında 2×2 boyutunda kayma adımı 2 olan maksimum havuzlama işlemi yapılmaktadır. Elde edilen özellik vektörleri doğrusal DVM ile sınıflandırılmaktadır.


Karşılaştırmalı analiz kapsamında makine öğrenmesi yöntemlerinde kullanılan Gray Level Co-Occurrence Matrix (GLCM), Gray Level Run Length Matrix (GLRLM), Autocorrelation Function (ACF) ve seyrek temsil özellikleri görüntülerden çıkarılarak bu özellikler Gaussian Destek Vektör Makinesi ile sınıflandırma işlemi yapılmıştır. Şekil 3.56’da önerilen makine öğrenmesi yöntemi gösterilmiştir.



Şekil 3.56. Önerilen makine öğrenmesi yöntemi

Tez kapsamında kullanılan üçüncü veri setinde toplam 8505 adet gerçek GPR B Tarama görüntüsü bulunmaktadır. Bu veri setindeki görüntülerin %75 eğitim ve geri kalan %25’lik miktarı ise test işlemi için kullanılmıştır. Karşılaştırmalı analiz kapsamında transfer öğrenmesi tekniği ile ön eğitilmiş ağların üzerinde işlemler yapılmıştır. Kullanılan ön eğitilmiş KSA yapıları ise AlexNet, VGG-19, GoogleNet, InceptionNet, ResNet 50 ve DenseNet’tir. Bu veri seti için iki farklı önerilen yöntem bulunmaktadır. Önerilen yöntemlerden birincisi içerisinde blok yapısı ve sınıflandırıcı

olarak K-EYK algoritması kullanan bir KSA modelidir. Blok yapısını içerisinde farklı özelliklere sahip konvolüsyon katmanı, yığın normalizasyonu, REDB ve havuzlama katmanı bulunmaktadır. Önerilen KSA mimarisinde 5 adet blok yapısı mevcuttur. Blok yapılarından sonra bir adet kaçınma katmanı, bir adet tam bağlı katman ve sınıflama için K-EYK katmanı bulunur. Önerilen yöntem Şekil 3.57’de şematize edilmiştir.



Şekil 3.57. Önerilen KSA+K-EYK mimarisi


Önerilen KSA mimarisindeki Blok 1’de bulunan konvolüsyon katmanında 12 adet 3×3 boyutlarında görüntü filtreleri mevcuttur. Havuzlama katmanında 3×3 pencere boyutunda maksimum havuzlama uygulanmaktadır. Blok 2, Blok 3, Blok 4 ve Blok 5’de yer alan konvolüsyon filtrelerinin boyutları Blok 1’deki filtre boyutu ile benzer bir şekildedir. Yalnızca filtre sayılarında değişiklik mevcuttur. Sırasıyla Blok 2’de 24 adet, Blok 3’de 36 adet, Blok 4’de 48 adet ve Blok 5’de 48 adet konvolüsyon filtresi bulunmaktadır. Blok 5’de yer alan maksimum havuzlama penceresi 1×13 boyutlarındadır. Önerilen KSA yapısı değerlendirildiğinde ön eğitilmiş KSA modellerine göre parametre sayısının oldukça az olduğu görülmektedir.

Bu veri seti için kullanılan diğer bir yöntem ise geri bağlantılar ve paralel UKSB yapıları barındıran KSA modelidir. Önerilen yöntemin giriş görüntüsü boyutları $224 \times 224 \times 3$ şeklindedir. Bu yöntemde de diğer yöntemde olduğu gibi farklı özelliklerde blok yapısı mevcuttur. Önerilen yöntemdeki blok yapısında sırasıyla konvolüsyon katmanı, yığın normalizasyonu ve REDB katmanı bulunur. Konvolüsyon katmanlarında 3×3 boyutlarında 20 adet görüntü filtreleri bulunur. Blok yapıları ile beraber havuzlama katmanları kullanılarak geri bağlantıları yapılmıştır. Önerilen yöntem içerisindeki geri bağlantıların kullanılmasının ana nedeni gradyan yok olması probleminin önüne

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Tez kapsamında kullanılan dört farklı özelliklerdeki veri seti kullanılmış ve analizi için farklı yöntemler önerilmiştir. Birinci veri seti için önerilen derin sözlük öğrenme algoritmasından elde edilen sonuçlar bu bölümde karşılaştırmalı olarak açıklanmıştır. GPR B tarama görüntülerini oluşturmak için GprMax programı kullanılmıştır. Bu program, ortamdaki elektromanyetik dalga yayılımını FDTD yöntemi ile çözümlenmektedir. GprMax programında senaryo oluşturmaya başlamadan önce, tarama için gerekli olan anten parametreleri ayarlanmalıdır. Oluşturulan senaryolar için merkez frekans 400 MHz olan bir dipol anten kullanılmıştır. 3×4 m boyutlarındaki yer altı modelinde, GPR B tarama görüntüleri 180 farklı GPR senaryosundan elde edilmiştir.

Önerilen çok katmanlı derin sözlük öğrenme yapısında, her katmanda farklı boyut ve atomlara sahip sözlükler vardır. Bunun nedeni, her katmandaki seyrek kodlama matrisinin boyutunun, giriş matrisinin boyutundan daha küçük olmasıdır. Her katmandaki öğrenilen sözlükler, Şekil 4.1'de gösterilmiştir.



Şekil 4.1. a) İlk katmanda öğrenilen sözlük b) İkinci katmanda öğrenilen sözlük c) Üçüncü katmanda öğrenilen sözlük

İlk katmanda bulunan sözlük, diğer katmanlardaki öğrenilen sözlüklerden boyut ve atom sayısı olarak daha büyüktür. İlk katmanda öğrenilen sözlükte 400 adet atom vardır. Bu atomların her biri 11×23 boyuttadır. Ayrıca, bu atomlar 20×20 birimden oluşan bir sözlük oluşturur. İkinci katmandaki sözlük yapısı 11×23 boyutunda 36 adet atom içerir. Bu atomlar sözlük içerisine 6×6 olarak yerleştirilmiştir. Son katmanda öğrenilen sözlük en küçüktür. Bunun nedeni, öğrenilecek olan giriş matrisinin, birinci

tabakadaki giriş matrisinden daha küçük olmasıdır. Bu katmandaki sözlük 7×15 boyutunda 16 atom içermektedir. Bu atomlar 4×4 kare matris biçiminde sözlük içerisine yerleştirilmiştir.

Çizelge 4.1. Birinci ve seti için yöntemlerin karşılaştırmalı sonuçları

Sınıflayıcılar	Tek gizli Katmana sahip Sözlük Öğrenme	İki gizli Katmana sahip Sözlük Öğrenme	Üç gizli Katmana sahip Sözlük Öğrenme
Complex Tree	%72.2	%63.9	%69.4
Medium Tree	%72.2	%63.9	%69.4
Simple Tree	%72.2	%63.9	%66.7
LDA	%63.9	%61.1	%94.4
Linear DVM	%69.4	%77.8	%72.2
Quadratic DVM	%66.7	%72.2	%80.6
Cubic DVM	%66.7	%63.9	%75.0
Fine Gaussian DVM	%58.3	%55.6	%58.3
Medium Gaussian DVM	%75.0	%72.2	%69.4
Coarse Gaussian DVM	%66.7	%77.8	%44.4
Fine K-EYK	%66.7	%55.6	%72.2
Medium K-EYK	%77.8	%72.2	%52.8
Coarse K-EYK	%27.8	%27.8	%27.8
Cosine K-EYK	%66.7	%69.4	%61.1
Cubic K-EYK	%72.2	%72.2	%55.6
Weighted K-EYK	%72.2	%77.8	%61.1
Boosted Trees	%27.8	%27.8	%27.8
Bagged Trees	%69.4	%77.8	%77.8
Subspace Discriminant	%38.9	%55.6	%83.3
Subspace K-EYK	%63.9	%58.4	%80.6
RUS Boosted Trees	%66.7	%38.9	%30.6

Çizelge 4.1'de gösterildiği gibi, önerilen algoritma GPR B-tarama görüntüleri üzerinde % 94.4 oranında en yüksek sınıflama doğruluğu elde etmiştir. Farklı malzeme ve şekillerden oluşan gömülü nesnelere oldukça yüksek bir performans ile sınıflandırılmıştır. Ayrıca, nesne pozisyonu 10 cm'lik bir tolerans dahilinde değerlendirilmiştir. GPR B tarama görüntülerinde beş farklı malzemeden yapılmış farklı geometrilerden oluşan gömülü nesnelere kullanılmıştır. GPR B-tarama görüntülerinde yansımaların ve çakışmaların neden olduğu yanlış alarm durumu, önerilen derin sözlük öğrenmesi sayesinde azaltılmıştır.

Çizelge 4.1 dikkate alındığında en düşük sınıflandırma performansı % 27.8'lik bir başarı oranına sahiptir. En yüksek sınıflandırma başarısı, LDA ile üç gizli katmanlı derin sözlük öğrenme yapısının sınıflandırılmasıyla elde edilmiştir. Bu yapının sınıflandırma performansı Çizelge 4.1'de en yüksek olan % 94.4'dür. Tek gizli katmana sahip derin sözlük öğrenme yapısında, %75.0 oranında sınıflandırma başarısına ulaşılmıştır. Bu performans Medium Gaussian DVM sınıflandırıcı ile elde edilmiştir. İki gizli katman yapısı ile birlikte derin sözlük öğrenmesinin sınıflandırma başarısı % 77.8 oranına çıkmıştır. Bu performans, Linear DVM, Coarse Gaussian DVM ve Bagged

Trees ile elde edilmiştir. Çizelge 4.1 incelendiğinde, gizli katman sayılarına göre ortalama sınıflandırma sonuçlarının birbirine yakın olduğu gözlemlenmiştir. Katmanların ortalama performansı sırasıyla % 63.13, % 62.18 ve % 63.33'tür.

İkinci veri setinde oluşturulan senaryolar için yalnızca bir gömülü nesne düşünülmüştür. GPR B tarama görüntüleri GprMax simülasyonu ile oluşturulmuştur. Toplam 1070 adet GPR B tarama görüntüsü üretilmiştir. KSA ağları için bu miktardaki görüntü sayısı çok azdır. Bu nedenle, görüntü veri seti artırılmalıdır. Veri artırımı için renk uzay dönüşümü ve speckle gürültüsü ekleme işlemi yapılmıştır. Toplamda 4280 adet GPR B tarama görüntüsü elde edilmiştir. Elde edilen GPR B Tarama görüntülerinin tümü gri seviyededir. Buna ek olarak, eğitilen modelleri gerçek veriler ile test etmek amacıyla 54 adet gerçek GPR B tarama görüntüsü kullanılmıştır.

Doğruluk, karşılaştırmalı analizde ana ölçüt olarak seçilmiştir. KSA yapılarında rastgele, ön eğitilmiş ve transfer öğrenimli modeller kullanılmıştır. Karşılaştırmalı analizi daha da genişletmek için Softmax ve DVM sınıflandırıcılarının performansı değerlendirilmiştir. Ayrıca, GLCM, GLRLM, ACF ve seyrek temsil özellikleri Gaussian DVM algoritması ile sınıflandırılmıştır. Tüm bu deneyler, Matlab programında 16 GB RAM ile Intel Core i7-7700 HQ 2.8 GHz'lik işlemci ve Nvidia GTX 1080 ekran kartı üzerinde gerçekleştirildi.

Malzeme çeşidinin belirlenmesi için rastgele modellerde AlexNet + DVM yapısı % 86.17 sınıflandırma doğruluğu elde etmiştir. VGG-16 ve SqueezeNet yapılarının doğruluğu % 20.11 ile birbiriyle aynıdır. Düşük doğruluk oranlarının temel nedeni ağ parametrelerinin başlangıçta rastgele olarak atanmasından dolayı optimum değerlere ulaşması için daha fazla eğitim verisi gerektirmesidir. GoogleNet ve ResNet yapılarının hesaplanma sürelerinin oldukça fazla olması nedeniyle rastgele bir model eğitimi yapılmamıştır. KDVM, tüm derin öğrenme modelleri içerisinde sadece rastgele model olarak eğitilmiştir. Çizelge 4.2'de görüldüğü üzere, gömülü nesnelerin malzeme çeşidinin belirlenmesinde en yüksek sınıflandırma doğruluğu 2140 adet eğitim görüntüsüyle ve % 95.46 oran ile geniş KDVM modeli tarafından sağlanmaktadır. Ön eğitilmiş modellerde, 2140 adet eğitim görüntüsü ile ResNet + Softmax yapısı %56.78 oran ile en yüksek sınıflandırma başarısına sahiptir. Bu modeller içerisinde en düşük doğruluk oranı % 28.05 ile GoogleNet + DVM'nindir. Transfer öğrenimli modellerde, ResNet + Softmax yapısı % 43.68 oran ile en düşük doğruluğa sahiptir. Diğer yandan, 2140 adet eğitim görüntüsü ile geniş KDVM modeli, diğerlerine göre % 95.46 ile daha iyi sonuç vermiştir.

Çizelge 4.2. İkinci veri seti için yöntemlerin karşılaştırılmalı sonuçları

KSA Modelleri	Eğitim Görüntüleri	Malzeme Çeşidi Sınıflama Doğruluğu (%)						Şekil Çeşidi Sınıflama Doğruluğu (%)						Toprak Çeşidi Sınıflama Doğruluğu (%)						Gerçek Veriler İçin Şekil Çeşidi Sınıflama Doğruluğu (%)		Hesaplama Zamanı (Dakika)
		Rastgele		Ön Eğitimli		Transfer Öğrenimli		Rastgele		Ön Eğitimli		Transfer Öğrenimli		Rastgele		Ön Eğitimli		Transfer Öğrenimli		Softmax	DVM	
		Softmax	DVM	Softmax	DVM	Softmax	DVM	Softmax	DVM	Softmax	DVM	Softmax	DVM	Softmax	DVM	Softmax	DVM	Softmax	DVM	Softmax	DVM	
AlexNet	267	48.23	42.41	41.18	32.93	48.35	50.3	81.43	85.84	80.42	77.23	93.48	94.53	98.58	98.19	91.11	77.54	96.41	96.86	40.74	70.37	154
	535	55.39	52.46	46.49	38.05	57.97	59.01	96.28	95.77	85.77	81.49	95.18	96.42	99.28	99.52	91.49	80.26	98.62	98.93			
	1070	70.45	73.24	50.34	40.59	71.45	78.16	97.7	97.88	90.51	81.27	96.74	97.69	99.5	99.42	96.1	91.2	99.53	99.53			
	1605	79.18	82.28	51.33	40.22	80.67	86.28	98.29	98.43	92.06	87.6	97.77	98.84	99.44	99.48	96.22	92.21	99.22	99.59			
VGG-16	267	19.12	20	39.67	35.41	58.94	60.09	33.52	33.33	81.35	80.17	96.23	96.16	33.33	33.33	92.22	83.31	99.25	99.25	66.67	66.67	741
	535	19.93	20	42.86	36.21	70.55	73.48	33.15	33.33	85.29	85.55	98.16	97.94	33.52	33.33	91.57	91.51	99.57	99.57			
	1070	20.11	20	49.97	40.16	80.35	84.98	33.52	33.33	89.23	86.49	97.8	98.35	33.52	33.33	95.35	94.73	99.26	99.59			
	1605	20.11	20	51.78	47.63	86.45	90.36	33.52	30.07	90.56	86.33	98.96	98.61	33.52	33.37	96.1	94.19	99.44	99.55			
GoogleNet	267	x	x	36.57	28.05	53.52	55.11	x	x	78.97	76.58	94.48	95.23	x	x	88.45	72.24	97.03	96.84	66.67	62.96	297
	535	x	x	42.86	36.01	61.93	64.91	x	x	83.47	84.43	96.41	97	x	x	90.85	80.74	98.91	99.38			
	1070	x	x	49	42.59	75.64	81.28	x	x	86.64	86.93	97.95	98.6	x	x	94.85	85.29	99.19	99.31			
	1605	x	x	50.58	40.93	80.15	84.86	x	x	89.7	85.99	98.14	98.43	x	x	95.51	91.2	99.26	99.59			
ResNet	267	x	x	50.61	40.37	85.89	91.03	x	x	90.17	88.01	98.88	98.5	x	x	96.11	90.96	99.21	99.58	57.40	57.40	397
	535	x	x	44.36	38.2	44.51	43.68	x	x	86.8	90.26	89.57	91.27	x	x	95.36	86.22	94.93	95.81			
	1070	x	x	48.87	37.6	53.34	55.38	x	x	86.89	87.11	94.95	95.43	x	x	95.59	92.22	98.14	98.61			
	1605	x	x	51.06	44.86	59.22	63.83	x	x	92.79	90.45	96.4	96.91	x	x	96.57	96.38	98.44	99.19			
SqueezeNet	267	x	x	54.92	50.28	64.96	68	x	x	93.9	92.4	96.57	97.34	x	x	98.05	97.94	99.55	99.51	38.88	51.85	130
	535	19.92	20	41.05	33.06	48.1	48.82	33.33	33.33	84.21	68.27	94.18	94.83	33.52	33.33	94.23	53.94	98.7	98.57			
	1070	20.11	20	46.84	30.92	52.67	53.27	33.52	33.33	87.69	67.34	96.89	97.03	33.15	33.33	96.01	87	98.78	99.22			
	1605	20.11	20	47.32	35.11	68.06	73.8	33.52	33.33	89.45	79.53	97.8	98	33.52	33.33	96.47	79.59	95.05	98.47			
Küçük KDVM Modeli	267	x	86.2	x	x	x	x	x	78.68	x	x	x	x	x	98.62	x	x	x	x	x	70.37	120
	535	x	88.08	x	x	x	x	x	82.86	x	x	x	x	x	99.62	x	x	x	x			
	1070	x	90.68	x	x	x	x	x	86.21	x	x	x	x	x	99.44	x	x	x	x			
	1605	x	93.29	x	x	x	x	x	93.82	x	x	x	x	x	99.66	x	x	x	x			
Orta KDVM Modeli	267	x	94.44	x	x	x	x	x	97.19	x	x	x	x	x	99.58	x	x	x	x	x	70.37	258
	535	x	83.44	x	x	x	x	x	91.52	x	x	x	x	x	98.27	x	x	x	x			
	1070	x	88.26	x	x	x	x	x	93.45	x	x	x	x	x	99.44	x	x	x	x			
	1605	x	90.88	x	x	x	x	x	94.01	x	x	x	x	x	99.58	x	x	x	x			
Geniş KDVM Modeli	267	x	93.73	x	x	x	x	x	96.58	x	x	x	x	x	99.58	x	x	x	x	x	74.07	381
	535	x	94.76	x	x	x	x	x	97.24	x	x	x	x	x	99.66	x	x	x	x			
	1070	x	86.2	x	x	x	x	x	92.28	x	x	x	x	x	98.62	x	x	x	x			
	1605	x	88.08	x	x	x	x	x	94.29	x	x	x	x	x	99.44	x	x	x	x			
Geniş KDVM Modeli	267	x	91.16	x	x	x	x	x	95.93	x	x	x	x	x	99.58	x	x	x	x	x	74.07	381
	535	x	94.29	x	x	x	x	x	97.52	x	x	x	x	x	99.66	x	x	x	x			
	1070	x	94.29	x	x	x	x	x	97.52	x	x	x	x	x	99.66	x	x	x	x			
	1605	x	95.46	x	x	x	x	x	98.64	x	x	x	x	x	99.76	x	x	x	x			

Şekil türü sınıflandırması için rastgele modellerde 2140 adet eğitim görüntüsü kullanılarak AlexNet + DVM yapısı % 98.74 oran ile en iyi sonucu verirken, 1605 adet eğitim görüntüsü ile VGG + DVM yapısı % 90.84 oran ile en düşük sınıflandırma doğruluğunu elde etmiştir. Ön eğitilmiş modellerde, % 95.32 doğruluk oranı ile 2140 adet eğitim görüntüsü kullanılarak ResNet + Softmax yapısı en yüksek doğruluk oranına sahiptir. Bununla beraber SqueezeNet + DVM yapısı % 67.34 doğruluk oranı ile en düşük sınıflandırma doğruluğuna sahiptir. Transfer öğrenimli modellerde VGG-16 + Softmax yapısı 1605 adet eğitim görüntüsü kullanılarak % 98.96 oranı ile en yüksek sınıflandırma başarısını elde etmiştir. Bununla beraber, ResNet + Softmax yapısı 267 adet eğitim görüntüsü kullanarak % 89.57 oranı ile en düşük sınıflandırma sonucuna sahiptir. Gerçek GPR B tarama görüntülerinde, geniş KDVM modeli, şekil türü tespiti için % 74.07 oran ile en yüksek doğruluğu elde etmiştir.

Toprak çeşidi sınıflandırmasında, tüm modeller arasında 2140 adet eğitim görüntüsü kullanarak geniş KDVM yapısı % 99.76 oran ile en yüksek doğruluğa sahiptir. Genel olarak, rastgele modellerde VGG-16 + SqueezeNet yapısı % 33.33 oran ile en düşük doğruluğa sahiptir. Ön eğitilmiş modeller için, 2140 adet eğitim görüntüsü kullanılarak ResNet + Softmax yapısı % 98.27 oran ile en yüksek sınıflandırma doğruluğuna sahiptir. SqueezeNet + DVM yapısı 267 adet eğitim görüntüsündeki doğruluğu % 53.94 oran ile en düşük doğruluktur. Transfer öğrenimli modellerde % 99.59 oran ile en yüksek doğruluğa sahip dört yapı bulunmaktadır. En düşük doğruluk oranı ise ResNet + Softmax yapısı ile % 94.93 oran ile elde edilmiştir.

Hesaplama zamanı açısından, küçük KDVM yapısı, diğer KSA algoritmalarına göre en kısa sürede yaklaşık iki saat içerisinde eğitim işlemi tamamlamıştır. VGG-16, en uzun hesaplama süresine sahip olup eğitim süreci 741 dakika sürmüştür. Eğitim aşamasında 200 epok kullanılmış ve 2140 adet görüntü kullanılarak hesaplama zamanı belirlenmiştir

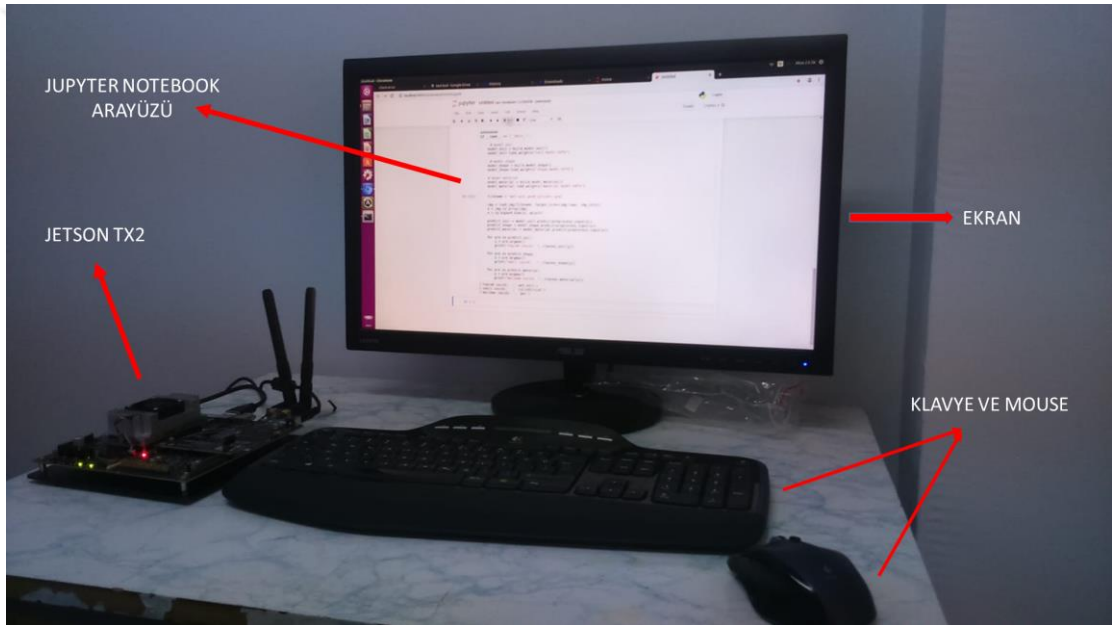
Çizelge 4.3. İkinci veri seti için makine öğrenmesi yöntemlerinin karşılaştırmalı sonuçları

Özellikler	Sınıflayıcı	Sınıflama Doğruluğu (%)		
		Malzeme Çeşidi	Şekil Çeşidi	Toprak Çeşidi
GLCM	GDVM	15.32	27.64	28.69
GLRLM	GDVM	19.71	33.19	32.06
ACF	GDVM	16.44	24.9	25.32
Seyrek Temsil	GDVM	15.65	27.66	27.36

Son olarak makine öğrenmesi yöntemleri kapsamında, GLCM, GLRLM, ACF ve seyrek temsil özellikleri Gaussian Destek Vektör Makinesi (GDVM) sınıflayıcısı

tarafından sınıflandırılmıştır. Sınıflandırma sonuçlarıyla ilgili olarak, en iyi performanslar, malzeme, şekil, toprak tipi sınıflandırması için sırasıyla % 19.71, % 33.19 ve % 32.06 oranlar ile GLRLM + GDVM modelinde elde edilmiştir.

Transfer öğrenimli KSA yapılarının uygulaması Jetson TX2 Kartı üzerinde gerçekleştirilmiştir. Jetson TX2 kartı, Ubuntu tabanlı Jet Pack işletim sistemini kullanmaktadır. Ayrıca bu kart derin öğrenme yapılarını çalıştırabilmek için gerekli Python tabanlı kütüphaneleri desteklemektedir. Bilgisayardan bağımsız olarak çalışan Jetson TX2 kartının tez için uygulaması Şekil 4.2’de yer almaktadır. Jetson TX2 kartı gerekli programların tasarlanabilmesi için harici ekran ve klavye-mouse setine ihtiyaç duyar. Gerçekleştirilen uygulama Jupyter notebook arayüzü tarafından kullanılmaktadır.



Şekil 4.2. Jetson TX2 kart uygulaması

Jetson TX2 kartında eğitimden ziyade test işlemleri yapılmıştır. Test işleminde görüntüler sırayla seçilip sonuç etiketleri Jupyter notebook arayüzünde gösterilmektedir. Jet Pack işletim sistemi İngilizce tabanlı olduğundan bazı Türkçe karakterlerin gösterilmesi sorunlara neden olmaktadır bu sebeple arayüz İngilizce tasarlanmıştır. Jupyter Notebook kodu eklerde verilmektedir. Kod içerisinde eğitimi yapılmış KSA yapısı kod ile kart içerisine yüklenmekte ve sonuçlar test görüntüleri için ekranda yazılmaktadır.

Tez çalışmasında kullanılan üçüncü veri setinde toplamda 8505 adet gerçek GPR B tarama görüntülerinin %75’i KSA yapılarının eğitimi ve %25’i ise KSA yapılarının

test edilmesi için kullanılmıştır. Çizelge 4.4'de önerilen yöntem ve ön eğitilmiş KSA yapıları için elde edilen doğruluk, keskinlik, duyarlılık ve F1 Skoru verilmiştir. GPR çeşidinin belirlenmesinde önerilen KSA yapısı % 97.16 doğruluk, % 97.31 keskinlik, % 97.04 duyarlılık ve % 97.18 F1 skoru ile en yüksek performansı göstermiştir. Çalışmada önerilen diğer ön eğitilmiş KSA yapılarına göre önerilen yöntemin gösterdiği performans daha yüksektir. Ön eğitilmiş KSA yapıları içerisinde VGG-16 modeli % 96.84 doğruluk, % 96.97 keskinlik, % 96.71 duyarlılık ve % 96.84 F1 skoru ile metrik değerleri ile en iyi performansa sahiptir. En düşük performans ise % 95.89 doğruluk, % 96.12 keskinlik, % 95.79 duyarlılık ve % 95.95 F1 skoru metrik değerleri ile AlexNet modeline aittir. GPR çeşidi tespitinde olduğu gibi önerilen KSA yapısı tarama frekansının tespitinde de en yüksek performansı elde etmiştir. Önerilen KSA yapısı ile elde edilen metrik değerleri % 94.88 doğruluk, % 95.02 keskinlik, % 95.49 duyarlılık ve % 95.24 F1 skoru şeklindedir. Tarama frekansı tespitinde VGG-16 modeli önerilen KSA modelinden sonra % 94.54 doğruluk, % 94.73 keskinlik, % 95.07 duyarlılık ve % 94.90 F1 skoru metrik değerleri ile en yüksek performansı göstermiştir. En düşük performans AlexNet modeline ait olup % 90.88 doğruluk, % 90.89 keskinlik, % 91.92 duyarlılık ve % 91.40 F1 skoru metrik değerlerine sahiptir. Toprak çeşidinin tespitinde önerilen KSA yapısı VGG-16 ve DenseNet-121 modellerinden sonra en yüksek performansı elde etmiştir. Önerilen KSA yapısı ile elde edilen metrik değerleri % 90.63 doğruluk, % 90.50 keskinlik, % 90.83 duyarlılık ve % 90.66 F1 skoru şeklindedir. En yüksek performans gösteren VGG-16 modeli ise % 93.00 doğruluk, % 92.49 keskinlik, % 93.26 duyarlılık ve % 92.87 F1 skoru metrik değerlerine sahiptir. En düşük performans diğer görevlerde olduğu gibi % 84.39 doğruluk, % 84.20 keskinlik, % 84.57 duyarlılık ve % 84.39 F1 skoru metrik değerleri ile AlexNet modeline aittir.

Çizelge 4.4. Üçüncü veri seti için önerilen KSA+K-EYK ve ön eğitilmiş ksa yöntemlerinin karşılaştırmalı sonuçları

KSA Modelleri	Metrikler (%)	GPR Çeşidi Tespiti	Tarama Frekansı Tespiti	Toprak Çeşidi Tespiti
AlexNet	Doğruluk	95.89	90.88	84.39
	Keskinlik	96.12	90.89	84.20
	Duyarlılık	95.79	91.92	84.57
	F1 Skoru	95.95	91.40	84.39
VGG-16	Doğruluk	96.84	94.54	93.00
	Keskinlik	96.97	94.73	92.49
	Duyarlılık	96.71	95.07	93.26
	F1 Skoru	96.84	94.90	92.87
GoogleNet	Doğruluk	96.36	94.08	90.54
	Keskinlik	96.61	94.29	89.14
	Duyarlılık	96.21	94.83	92.81
	F1 Skoru	94.41	94.56	90.94
InceptionNet V2	Doğruluk	94.94	90.92	86.28
	Keskinlik	94.76	91.04	85.27
	Duyarlılık	94.61	91.90	88.46
	F1 Skoru	94.68	91.47	86.84
ResNet-50	Doğruluk	96.21	92.58	81.46
	Keskinlik	96.07	92.70	80.36
	Duyarlılık	96.62	93.29	80.61
	F1 Skoru	96.35	92.99	80.48
DenseNet-121	Doğruluk	95.26	94.5	91.36
	Keskinlik	95.05	94.52	90.46
	Duyarlılık	95.45	95.22	91.11
	F1 Skoru	95.25	94.87	90.78
Önerilen KSA+K-EYK	Doğruluk	97.16	94.88	90.63
	Keskinlik	97.31	95.02	90.50
	Duyarlılık	97.04	95.49	90.83
	F1 Skoru	97.18	95.24	90.66

Tez kapsamında analiz edilen üçüncü veri seti için önerilen diğer bir yöntemde Çift Yönlü UKSB+KSA yapısıdır. Karşılaştırmalı analiz kapsamında AlexNet, VGG-16, GoogleNet, Inception V2, ResNet-50 ve DenseNet-121 önceden eğitilmiş modeller olarak seçilmiştir. GPR verileri rastgele olarak eğitim setine (% 75) ve teste (% 25) ayrılmıştır. Tüm metrikler yüzde olarak hesaplanmıştır. Karşılaştırmalı analiz sonuçları Çizelge 4.5'de verilmiştir.

Çizelge 4.5. Üçüncü veri seti için önerilen Çift Yönlü UKSB+KSA ve ön eğitilmiş KSA yöntemlerinin karşılaştırmalı sonuçları

KSA Modelleri	Metrikler (%)	GPR Çeşidi Tespiti	Tarama Frekansı Tespiti	Toprak Çeşidi Tespiti
AlexNet	Doğruluk	95.89	90.88	84.39
	Keskinlik	96.12	90.89	84.20
	Duyarlılık	95.79	91.92	84.57
	F1 Skoru	95.95	91.40	84.39
VGG-16	Doğruluk	96.84	94.54	93.00
	Keskinlik	96.97	94.73	92.49
	Duyarlılık	96.71	95.07	93.26
	F1 Skoru	96.84	94.90	92.87
GoogleNet	Doğruluk	96.36	94.08	90.54
	Keskinlik	96.61	94.29	89.14
	Duyarlılık	96.21	94.83	92.81
	F1 Skoru	94.41	94.56	90.94
InceptionNet V2	Doğruluk	94.94	90.92	86.28
	Keskinlik	94.76	91.04	85.27
	Duyarlılık	94.61	91.90	88.46
	F1 Skoru	94.68	91.47	86.84
ResNet-50	Doğruluk	96.21	92.58	81.46
	Keskinlik	96.07	92.70	80.36
	Duyarlılık	96.62	93.29	80.61
	F1 Skoru	96.35	92.99	80.48
DenseNet-121	Doğruluk	95.26	94.5	91.36
	Keskinlik	95.05	94.52	90.46
	Duyarlılık	95.45	95.22	91.11
	F1 Skoru	95.25	94.87	90.78
Önerilen Çift Yönlü UKSB+KSA	Doğruluk	97.31	95.54	93.15
	Keskinlik	97.08	95.71	92.93
	Duyarlılık	97.75	96.28	94.46
	F1 Skoru	97.42	96.00	93.70


GPR çeşidi sınıflandırma sonuçlarının diğer sınıflandırma sonuçlarının performansına göre daha başarılı olduğu görülmektedir. Önerilen Çift Yönlü UKSB+KSA yöntemi % 97.31 doğruluk, % 97.08 keskinlik, % 97.75 duyarlılık ve % 97.42 F1 skoru ile en iyi performansa sahiptir. VGG-16 modeli, % 96.84 doğruluk, % 96.97 keskinlik, % 96.71 duyarlılık ve % 96.84 F1 skoru metrik sonuçları ile ikinci sırada yer almaktadır. InceptionNet V2 modeli, GPR çeşidi tespitinde % 94.94 doğruluk, 94.76 keskinlik, % 94.61 duyarlılık ve % 94.68 F1 skoru metrik değerleriyle en kötü performansa sahiptir.

Tarama frekansında 200 MHz ile 900 MHz arasında toplam dokuz sınıf vardır. Önerilen Çift Yönlü UKSB+KSA modeli % 95.54 doğruluk, % 95.71 keskinlik, % 96.28 duyarlılık ve % 96.00 F1 skoru ile en iyi performansa sahiptir. VGG-16, GPR tipinin sınıflandırılmasında olduğu gibi doğruluk ile en iyi ikinci performansa sahiptir.

VGG 16 modeli ile elde edilen metrik performansları % 94.54 doğruluk, % 94.73 keskinlik, % 95.07 duyarlılık ve % 94.90 F1 skoru şeklindedir. AlexNet mimarisinin doğrusal özelliği ve mimari derinliğinin az olması nedeniyle tarama frekansının sınıflandırılması için en kötü performansa sahiptir. AlexNet modeli % 90.88 doğruluk, % 90.89 keskinlik, % 91.92 duyarlılık ve % 91.40 F1 skoru sınıflandırma metriklerine sahiptir.

Son olarak, toprak çeşidinin sınıflandırılması oldukça zor bir problem olarak karşımıza çıkmaktadır. Diğer sınıflandırma sonuçlarında olduğu gibi, önerilen Çift Yönlü UKSB+KSA daha iyi performansa sahiptir. Metrik performansı % 93.15 doğruluk, % 92.93 keskinlik, % 94.46 duyarlılık ve % 93.70 F1 skoru şeklindedir. VGG-16 sonuçları önerilen Çift Yönlü UKSB+KSA yöntemine göre performansı daha yüksektir. Toprak çeşidinin sınıflandırılmasında en yüksek metrik performansı % 93.00 doğruluk, % 92.49 keskinlik, % 93.26 duyarlılık ve % 92.87 F1 skoru olduğu görülmektedir. Öte yandan, ResNet-50 en kötü performansa sahip olup bütün metrik değerleri % 80 civarındadır.

Tez çalışmasında kullanılan dördüncü veri setinde GPR B tarama görüntülerinde nesne tespiti için kullanılan derin öğrenme modelleri YOLO, Hızlı B-KSA ve Daha Hızlı B-KSA'dır. Bu modellerin eğitimi tamamlandıktan sonra test görüntü örnekleri üzerindeki performansı Şekil 4.4'de verilmektedir.



Şekil 4.4. a) Test görüntüleri b) YOLO algoritması sonuçları c) Hızlı B-KSA sonuçları d) Daha Hızlı B-KSA sonuçları

Elde edilen test sonuçları değerlendirildiğinde YOLO algoritmasının oldukça başarısız olduğu görülmektedir. Hızlı B-KSA ile elde edilen sonuçlar test görüntü sonuçlarına daha yakındır. Daha Hızlı B-KSA Sonuçları ise performans açısından ikinci sırada bulunmaktadır. Nesne tespit algoritmalarının performansının düşük olmasının temel nedeni eğitim için kullanılan veri sayısının yetersiz olmasıdır.

Elde edilen araştırma bulguları değerlendirildiğinde GPR B tarama görüntüleri farklı problemler ve zorluklar içermektedir. Bu problemlerden başlıcaları gürültü ve yanlış alarm durumudur. Bunun yanı sıra tarama sahasındaki nemlilik değişimleri iletkenliği etkileyeceğinden dolayı GPR görüntülemesinde farklı problemler ortaya çıkmaktadır. Gömülü nesnenin yanlış olarak algılanması veya algılanması bu problemlerden bir kaçıdır. Derin öğrenme teknikleri ile kontrollü ortam koşulları bu problemler belli bir oranda çözüme kavuşturulmuştur.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

GPR, uzaktan algılama sistemlerinde en çok tercih edilen yöntemlerdendir. Diğer yöntemlere kıyasla GPR gerçekleştirmiş olduğu taramalarda yüksek çözünürlük elde ederek metalik veya metalik olmayan nesnelere kolay bir şekilde tespit edebilmektedir. GPR yapısında alıcı-verici antenleri, veri kayıt, veri kontrol ve görüntüleme birimlerini içerir. GPR, toprak düzlemine çok kısa dalga boyuna sahip radyo frekans (Athey ve ark.) dalgaları gönderir (Athey ve ark.). Gönderilen RF dalgaların bir kısmı ortamın elektriksel özellik değişiminden etkilenerek yansır. Bu yansıyan dalgalar alıcı anten tarafından toplanarak veri belleğinde kaydedilir. Bu kayıtlar daha sonra birleştirilerek GPR Tarama görüntüleri elde edilir.

GPR Tarama ile elde edilen B Tarama görüntülerinin analizinde bir takım zorluklar ile karşılaşılabilir. Bu zorluklardan biri tarama görüntüsündeki gürültü etkisidir. Gürültüler, GPR B tarama görüntülerinin bozulmasına neden olarak analizi güçleştirmektedir. Analizi zorlaştıran diğer bir durum ise yanlış alarm durumudur. Yani ortamda aranan hedef bulunmamasına rağmen varmış gibi algılanmasıdır. Tarama yapılan ortamda gömülü nesnelere birbirlerine yakın olması görüntülerde çakışmalar ve harici yansımalar neden olur. Bu durum malzeme kalınlığının fazla olmasında da gerçekleşebilir. Gerçekleşen bu problemler yanlış alarm oranını artırmaktadır. Ayrıca toprak çeşitlerinin ve gömülü nesnelere çok farklı elektriksel özelliklere sahip olması diğer bir zorluk olarak karşımıza çıkmaktadır. Bu zorluğun diğer bir aşaması da gömülü nesnelere farklı derinlik seviyelerinde bulunması durumunda görülmektedir.

Bu tez çalışmasında, belirtilen zorlukların üstesinden gelmek amacıyla GPR B Tarama görüntülerinin analizinde derin öğrenme yöntemleri kullanılmıştır. Araştırma sonuçları incelendiğinde derin öğrenme algoritmaları yanlış alarm durumunu azaltarak gömülü nesnelere şekil ve malzeme özelliklerini otomatik bir şekilde elde edebilmektedir. Bunun yanı sıra tarama yapılan toprak sahası özelliklerini hakkında da bilgi verebilmektedir. Önerilen yöntemlerin çalıştırılmasında daha çok Matlab ve Jupyter Notebook programları kullanılmıştır. Derin öğrenme algoritmalarının uygulanması için dört ayrı veri seti kullanılmıştır. Bunlardan ilk ikisi GprMax programı ile elde edilen simülasyon verilerinden son iki veri seti ise gerçek GPR verilerinden oluşmaktadır. GprMax programı zamanda sonlu farklar (FDTD) tekniğini kullanan açık

erişim bir simülasyon yazılımıdır. Bu aşamada GprMax ile elde edilen GPR B tarama görüntüleri hem eğitim hem de test işlemlerinde kullanılmıştır. Simülasyon verilerine uygulanan derin öğrenme tekniklerinin elde etmiş olduğu performansın gerçek GPR verilerinde de elde edilebileceğini ortaya koymak amacıyla iki ayrı gerçek veri setine de derin öğrenme teknikleri kayda değer performans göstermektedir.

Önerilen derin öğrenme yöntemlerinin denenmesi sürecinde elde edilen sonuçlar göz önüne alındığında toprak ve gömülü nesnelerin elektriksel özelliklerinin görüntülerin analizini zorlaştırdığı gözlemlenmiştir. Derin öğrenme algoritmalarının eğitim aşamasında görüntülerden özellikleri otomatik ve hassas bir şekilde öğrenmesinden ötürü karşılaşılan bu zorluklar büyük oranda aşılmıştır. Eğitimi tamamlanmış derin öğrenme algoritmaları gerçek GPR B tarama görüntüleri üzerinde test edilerek gerçek dünyadaki başarıları ortaya konmuştur. Böylece herhangi bir müdahaleye ihtiyaç kalmadan otomatik bir şekilde toprak ortamı ve gömülü nesnelerin özelliklerini tahmin etmeye yönelik önemli bir adım gerçekleştirilmiştir.

Önerilen derin öğrenme algoritmaları ile toprak ortamı, gömülü nesnelerin özelliklerinin tespiti ve yanlış alarm oranının azaltılması sağlanmıştır. Tasarlanan derin öğrenme yapıları donanımsal olarak da çalıştırılmıştır. Eğitimi tamamlanmış derin öğrenme algoritmalarının yüklendiği Jetson TX2 kartına uygulanan GPR verileri ile gerçek zamanlı test denemesi yapılmıştır. Böylece GPR cihazından alınacak bir B tarama görüntüsünün anlık olarak Jetson TX2 kartına aktarımı gerçekleştirildiğinde gerçek zamanlı otomatik tespit yeteneğinin mümkün olabileceği gösterilmiştir. İlerleyen çalışmalarda daha büyük bir bütçe ile gerçek bir GPR cihazının geliştirilen donanıma adaptasyonu ile tam anlamıyla sahada gerçek zamanlı otomatik tespit yeteneğine sahip uygulama ortaya konabilecektir. Kullanılması planlanan alanlar arkeolojik uygulamalar, metalik ve metalik olmayan mayınların tespiti ve asfalt yollardaki kırık ve çatlakların tespiti olarak sıralanabilir.

5.2 Öneriler

Tez çalışması kapsamında önerilen derin öğrenme algoritmalarının doğruluk oranları yeterli görülmemeli ve farklı derin öğrenme yöntemleri geliştirilmelidir. Böylece daha yüksek doğruluk oranlarının elde edilmesi gerekmektedir. Ayrıca derin öğrenme algoritmalarının eğitim ve test aşamasında daha fazla gerçek GPR B tarama görüntüsü kullanılarak sistemin uygulanabilirliğe yatkınlığı sağlanmalıdır. Bunun yanı

sıra, literatürdeki U-Net yapıları kullanılarak çoklu gömülü nesnelerin bulunduğu tarama görüntüleri üzerinde semantik bölütleme işlemi yapılabilir.

Ayrıca, tez çalışması kapsamında gerçekleştirilen benzetim ve uygulama sonuçları, bu konu üzerinde çalışmayı planlayan araştırmacılara kılavuz olması ümit edilmektedir.



KAYNAKLAR

- Al-Nuaimy, W., Huang, Y., Nakhkash, M., Fang, M. T. C., Nguyen, V. T. ve Eriksen, A., 2000, Automatic detection of buried utilities and solid objects with GPR using neural networks and pattern recognition, *Journal of Applied Geophysics*, 43 (2-4), 157-165.
- Athey, J., Alexaki, A., Osipova, E., Rostovtsev, A., Santana-Quintero, L. V., Katneni, U., Simonyan, V. ve Kimchi-Sarfaty, C., 2017, A new and updated resource for codon usage tables, *BMC Bioinformatics*, 18.
- Bazi, Y. ve Melgani, F., 2018, Convolutional SVM Networks for Object Detection in UAV Imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 56 (6), 3107-3118.
- Belli, K., Wadia-Fascetti, S. ve Rappaport, C., 2011, Integrated Sensor and Media Modeling Environment Developed and Applied to Ground-Penetrating Radar Investigation of Bridge Decks, *Journal of Computing in Civil Engineering*, 25 (1), 10-20.
- Benedetto, A., Benedetto, F., De Blasiis, M. ve Giunta, G., 2005, Reliability of signal processing technique for pavement damages detection and classification using ground penetrating radar, *IEEE Sensors Journal*, 5 (3), 471-480.
- Benedetto, A. ve Benedetto, F., 2011, Remote Sensing of Soil Moisture Content by GPR Signal Processing in the Frequency Domain, *IEEE Sensors Journal*, 11 (10), 2432-2441.
- Bestagini, P., Lombardi, F., Lualdi, M., Picetti, F., & Tubaro, S. , 2020, Landmine Detection Using Autoencoders on Multipolarization GPR Volumetric Data, *IEEE Transactions on Geoscience and Remote Sensing*.
- Bishop, C. M., 2006, Pattern Recognition and Machine Learning, *Springer, New York*.
- Boufenar, C. ve Batouche, M., 2017, Investigation on Deep Learning for Off-line Handwritten Arabic Character Recognition Using Theano Research Platform, *2017 Intelligent Systems and Computer Vision (ISCV)*.
- C. G. Windsor, L. C., and P. Falorni, 2005, The Estimation of Buried Pipe Diameters by Generalized Hough Transform of Radar Data, *Progress In Electromagnetics Research Symposium*, 345-349.
- Caner Özdemir , Ş. D., Enes Yiğit, Betül Yılmaz, 2014 A Review on Migration Methods in B-Scan Ground Penetrating Radar Imaging, *Mathematical Problems in Engineering*, 2014/6.
- Caorsi, S. ve Cevini, G., 2005, An electromagnetic approach based on neural networks for the GPR investigation of buried cylinders, *IEEE Geoscience and Remote Sensing Letters*, 2 (1), 3-7.
- Chavushyan, V. A., Simonyan, K. V., Simonyan, R. M., Isoyan, A. S., Simonyan, G. M., Babakhanyan, M. A., Hovhannisyian, L. E., Nahapetyan, K. H., Avetisyan, L. G. ve Simonyan, M. A., 2017, Effects of stevia on synaptic plasticity and NADPH oxidase level of CNS in conditions of metabolic disorders caused by fructose, *Bmc Complementary and Alternative Medicine*, 17.
- Chen, T. S., Lin, Y. Y., Chen, J., Huang, C. C. ve Chang, H. W., 2012, A Study Using Genetic Algorithm and Support Vector Machine to Find Out How the Attitude of Training Personnel Affects the Performance of the Introduction of Taiwan TrainQuali System in an Enterprise, *Information and Business Intelligence, Pt Ii*, 268, 142-149.

- Cherkassky, V. ve Ma, Y. Q., 2004, Practical selection of SVM parameters and noise estimation for SVM regression, *Neural Networks*, 17 (1), 113-126.
- Daniels, D. J., 2004, Ground Penetrating Radar, *The Institution of Electrical Engineers*.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K. ve Li, F. F., 2009, ImageNet: A Large-Scale Hierarchical Image Database, *Cvpr: 2009 IEEE Conference on Computer Vision and Pattern Recognition, Vols 1-4*, 248-255.
- Derobert, X. ve Pajewski, L., 2018, TU1208 Open Database of Radargrams: The Dataset of the IFSTTAR Geophysical Test Site, *Remote Sensing*, 10 (4).
- Edoardo Pasolli, F. M., Massimo Donelli, ve Redha Attoui, a. M. D. V., 2008, Automatic Detection And Classification Of Buried Objects In Gpr Images Using Genetic Algorithms And Support Vector Machines, 525.
- El-Mahallawy, M. S. ve Hashim, M., 2013, Material Classification of Underground Utilities From GPR Images Using DCT-Based SVM Approach, *IEEE Geoscience and Remote Sensing Letters*, 10 (6), 1542-1546.
- Feng, X., Yu, Y., Liu, C. ve Fehler, M., 2015, Combination of H-Alpha Decomposition and Migration for Enhancing Subsurface Target Classification of GPR, *IEEE Transactions on Geoscience and Remote Sensing*, 53 (9), 4852-4861.
- Frigui, H., Ho, K. C. ve Gader, P., 2005, Real-time landmine detection with ground-penetrating radar using discriminative and adaptive hidden Markov models, *Eurasip Journal on Applied Signal Processing*, 2005 (12), 1867-1885.
- Gader, P., Lee, W. H. ve Wilson, J. N., 2004, Detecting landmines with ground-penetrating radar using feature-based rules, order statistics, and adaptive whitening, *IEEE Transactions on Geoscience and Remote Sensing*, 42 (11), 2522-2534.
- Gader, P. D., Mystkowski, M. ve Zhao, Y. X., 2001, Landmine detection with ground penetrating radar using hidden Markov models, *IEEE Transactions on Geoscience and Remote Sensing*, 39 (6), 1231-1244.
- Giannakis, I., Giannopoulos, A. ve Warren, C., 2016, A Realistic FDTD Numerical Modeling Framework of Ground Penetrating Radar for Landmine Detection, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9 (1), 37-51.
- Girshick R., D. j., Darel T., Malik J., 2014, Rich feature hierarchies for accurate object detection and semantic segmentation Tech report (v5).
- Gonzalez-Huici, M. A., Catapano, I. ve Soldovieri, F., 2014, A Comparative Study of GPR Reconstruction Approaches for Landmine Detection, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7 (12), 4869-4878.
- Grandjean, G., Gourry, J. C. ve Bitri, A., 2000, Evaluation of GPR techniques for civil-engineering applications: study on a test site, *Journal of Applied Geophysics*, 45 (3), 141-156.
- Groenenboom, J., 2002, Data Processing and Imaging in GPR System Dedicated for Landmine Detection, *Subsurface Sensing Technologies and Applications*, 3 (4), 387-402.
- He, K. M., Zhang, X. Y., Ren, S. Q. ve Sun, J., 2016, Deep Residual Learning for Image Recognition, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
- Hochreiter, S. v. S., J. , 1997, Long Short-Term Memory, *Neural Computing*, 9 (8), 1735-1780.
- Hofmann, T., Scholkopf, B. ve Smola, A. J., 2008, Kernel methods in machine learning, *Annals of Statistics*, 36 (3), 1171-1220.

- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. , 2017, Densely connected convolutional networks, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708.
- Jiao, L. B., Ye, Q. L., Cao, X. H., Huston, D. ve Xia, T., 2020, Identifying concrete structure defects in GPR image, *Measurement*, 160.
- Kaur, P., Dana, K. J., Romero, F. A. ve Gucunski, N., 2016, Automated GPR Rebar Analysis for Robotic Bridge Deck Evaluation, *IEEE Transactions on Cybernetics*, 46 (10), 2265-2276.
- Kim, N., Kim, S., An, Y. K. ve Lee, J. J., 2019, Triplanar Imaging of 3-D GPR Data for Deep-Learning-Based Underground Object Detection, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12 (11), 4446-4456.
- Kovalenko, V., Yarovoy, A. G. ve Lighthart, L. P., 2007, A novel clutter suppression algorithm for landmine detection with GPR, *IEEE Transactions on Geoscience and Remote Sensing*, 45 (11), 3740-3751.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2017, ImageNet Classification with Deep Convolutional Neural Networks, *Communications of the Acm*, 60 (6), 84-90.
- Krueger, K. R., McClellan, J. H. ve Scott, W. R., 2015, Efficient Algorithm Design for GPR Imaging of Landmines, *IEEE Transactions on Geoscience and Remote Sensing*, 53 (7), 4010-4021.
- Lambot, S., Weihermuller, L., Huisman, J. A., Vereecken, H., Vanclooster, M. ve Slob, E. C., 2006, Analysis of air-launched ground-penetrating radar techniques to measure the soil surface water content, *Water Resources Research*, 42 (11).
- Lei, W. T., Hou, F. F., Xi, J. C., Tan, Q. Y., Xu, M. D., Jiang, X. Y., Liu, G. Y. ve Gu, Q. Y., 2019, Automatic hyperbola detection and fitting in GPR B-scan image, *Automation in Construction*, 106.
- Li, A., Li, Y. X. ve Li, X. H., 2017, TensorFlow and Keras-based Convolutional Neural Network in CAT Image Recognition, *2017 2nd International Conference on Computational Modeling, Simulation and Applied Mathematics (CMSAM)*, 529-533.
- Liu, H., Zhao, J. G. ve Sato, M., 2015, A Hybrid Dual-Polarization GPR System for Detection of Linear Objects, *IEEE Antennas and Wireless Propagation Letters*, 14, 317-320.
- Ma, X., Liu, H., Wang, M. L. ve Birken, R. A., 2018, Automatic detection of steel rebar in bridge decks from ground penetrating radar data, *Journal of Applied Geophysics*, 158, 93-102.
- Manandhar, A., Torrione, P. A., Collins, L. M. ve Morton, K. D., 2015, Multiple-Instance Hidden Markov Model for GPR-Based Landmine Detection, *IEEE Transactions on Geoscience and Remote Sensing*, 53 (4), 1737-1745.
- Mesecan, I., Cico, B. ve Bucak, I. O., 2020, Feature vector for underground object detection using B-scan images from GprMax, *Microprocessors and Microsystems*, 76.
- Mo, Y. J., Kim, J., Kim, J. K., Mohaisen, A. ve Lee, W., 2017, Performance of Deep Learning Computation with TensorFlow Software Library in GPU-Capable Multi-Core Computing Platforms, *2017 Ninth International Conference on Ubiquitous and Future Networks (ICUFN 2017)*, 240-242.
- Muvhiwa, R. F., Sempuga, B., Hildebrandt, D. ve Van der Walt, J., 2018, Study of the effects of temperature on syngas composition from pyrolysis of wood pellets using a nitrogen plasma torch reactor, *Journal of Analytical and Applied Pyrolysis*, 130, 159-168.

- Pan, S. J. ve Yang, Q. A., 2010, A Survey on Transfer Learning, *IEEE Transactions on Knowledge and Data Engineering*, 22 (10), 1345-1359.
- Pantic, M. ve Rothkrantz, L. J. M., 2004, Facial action recognition for facial expression analysis from static face images, *IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics*, 34 (3), 1449-1461.
- Pasolli, E., Melgani, F. ve Donelli, M., 2009, Automatic Analysis of GPR Images: A Pattern-Recognition Approach, *IEEE Transactions on Geoscience and Remote Sensing*, 47 (7), 2206-2217.
- Pfister, T., Simonyan, K., Charles, J. ve Zisserman, A., 2015, Deep Convolutional Neural Networks for Efficient Pose Estimation in Gesture Videos, *Computer Vision - ACCV 2014, Pt I*, 9003, 538-552.
- Porsani, J. L., Slob, E., Lima, R. S. ve Leite, D. N., 2010, Comparing detection and location performance of perpendicular and parallel broadside GPR antenna orientations, *Journal of Applied Geophysics*, 70 (1), 1-8.
- Redmon J., D. S., Girshick R., Farhadi A., 2016, You Only Look Once: Unified, Real-Time Object Detection.
- Ren, S., Kaiming He, Ross Girshick, and Jian Sun, 2015, Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, *Advances in Neural Information Processing Systems*, 28.
- Rodes, J. P., Reguero, A. M. ve Perez-Gracia, V., 2020, GPR Spectra for Monitoring Asphalt Pavements, *Remote Sensing*, 12 (11).
- Roth, F., van Genderen, P. ve Verhaegen, M., 2005, Convolutional models for buried target characterization with ground penetrating radar, *IEEE Transactions on Antennas and Propagation*, 53 (11), 3799-3810.
- Salon, S. J. ve Dangelo, J., 1988, Applications of the Hybrid Finite-Element - Boundary Element Method in Electromagnetics, *IEEE Transactions on Magnetics*, 24 (1), 80-85.
- Schroedl, G. F., 2006, Ground-penetrating radar for archaeology., *Geoarchaeology-an International Journal*, 21 (6), 641-642.
- Shen, Y. C., Wang, L. V. ve Shen, J. T., 2013, Deep subwavelength optical imaging using correlated nano-torches, *Applied Physics Letters*, 103 (20).
- Shihab, S., Al-Nuaimy, W. ve Eriksen, A., 2004, Radius estimation for subsurface cylindrical objects detected by ground penetrating radar, *Proceedings of the Tenth International Conference on Ground Penetrating Radar, Vols 1 and 2*, 319-322.
- Singh, N. P. ve Nene, M. J., 2013, Buried Object Detection and Analysis of GPR Images: Using Neural Network and Curve Fitting, *2013 Annual International Conference on Emerging Research Areas & 2013 International Conference on Microelectronics, Communications & Renewable Energy (AICERA/ICMICR)*.
- Song, S. L., Huang, H. T. ve Ruan, T. X., 2019, Abstractive text summarization using LSTM-CNN based deep learning, *Multimedia Tools and Applications*, 78 (1), 857-875.
- Sun, Z. Y., Sha, A. M., Zhang, J. ve Gao, H. G., 2003, Principles and application of ground penetrating radar in non-destructive testing of highways, *ICEMI'2003: Proceedings of the Sixth International Conference on Electronic Measurement & Instruments, vol. 1-3*, 1044-1048.
- Szegedy, C., Liu, W., Jia, Y. Q., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going Deeper with Convolutions, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9.

- Tasoulis, D. K., Spyridonos, P., Pavlidis, N. G., Cavouras, D., Ravazoula, P., Nikiforidis, G. ve Vrahatis, M. N., 2003, Urinary bladder tumor grade diagnosis using on-line trained neural networks, *Knowledge-Based Intelligent Information and Engineering Systems, Pt 1, Proceedings*, 2773, 199-206.
- Torrey, L., Shavlik, J., Walker, T. ve Maclin, R., 2008, Relational macros for transfer in reinforcement learning, *Inductive Logic Programming*, 4894, 254-257.
- Unal, M., Caliskan, A. ve Turk, A. S., 2013, Impacts on Signal Processing Techniques for Ground Penetrating Radar, *2013 Signal Processing Symposium (SPS)*.
- Uzbaş, M., 2016, Doğaltaş blokları içindeki bozuklukların yer radarı ile belirlenmesi *Selçuk Üniversitesi Yüksek Lisans Tezi*.
- van der Walt, S., Colbert, S. C. ve Varoquaux, G., 2011, The NumPy Array: A Structure for Efficient Numerical Computation, *Computing in Science & Engineering*, 13 (2), 22-30.
- Verma, A., Qassim, H. ve Feinzimer, D., 2017, Residual Squeeze CNDS Deep Learning CNN Model for Very Large Scale Places Image Recognition, *2017 IEEE 8th Annual Ubiquitous Computing, Electronics and Mobile Communication Conference (UEMCON)*, 463-470.
- Wang, Y. H., Cui, G. Y. ve Xu, J., 2020, Semi-automatic detection of buried rebar in GPR data using a genetic algorithm, *Automation in Construction*, 114.
- Wang, Y. W., Li, X., Sun, Y. J. ve Stoica, P., 2005, Adaptive imaging for forward-looking ground penetrating radar, *IEEE Transactions on Aerospace and Electronic Systems*, 41 (3), 922-936.
- Warren, C., Giannopoulos, A. ve Giannakis, I., 2016, GprMax: Open source software to simulate electromagnetic wave propagation for Ground Penetrating Radar, *Computer Physics Communications*, 209, 163-170.
- Williams, R. M., Ray, L. E., Lever, J. H. ve Burzynski, A. M., 2014, Crevasse Detection in Ice Sheets Using Ground Penetrating Radar and Machine Learning, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7 (12), 4836-4848.
- Wong, D., Ton, T. ve Soumekh, M., 2010, Alaric Forward-Looking Ground Penetrating Radar System with Standoff Capability, *2010 IEEE National Conference on Wireless Information Technology and Systems*.
- Xu, X. Y., Miller, E. L., Rappaport, C. M. ve Sower, G. D., 2002, Statistical method to detect subsurface objects using array ground-penetrating radar data, *IEEE Transactions on Geoscience and Remote Sensing*, 40 (4), 963-976.
- Yang, X. F., Ye, Y. M., Li, X. T., Lau, R. Y. K., Zhang, X. F. ve Huang, X. H., 2018, Hyperspectral Image Classification With Deep Learning Models, *IEEE Transactions on Geoscience and Remote Sensing*, 56 (9), 5408-5423.
- Yayu Liu, M. W., Qiurong Cai, 2010, The Target Detection for GPR Images Based on Curve Fitting, 2876-2879.
- Youn, H., Kobashigawa, J., Evans, M. ve Çelik, N., 2010, Feasibility Study for IED Detection Using Forward-Looking Ground Penetrating Radar Integrated with Target Features Classification, *2010 IEEE Antennas and Propagation Society International Symposium*.
- Yu, T. Y., Cheng, T. K., Zhou, A. ve Lau, D., 2016, Remote defect detection of FRP-bonded concrete system using acoustic-laser and imaging radar techniques, *Construction and Building Materials*, 109, 146-155.
- Yu, Y., Chen, C. C., Feng, X. ve Liu, C., 2017, Modified Entropy-Based Fully Polarimetric Target Classification Method for Ground Penetrating Radars

- (GPR), *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10 (10), 4304-4312.
- Zhang, X. B., Feng, X., Zhang, Z. J., Kang, Z. L., Chai, Y., You, Q. ve Ding, L., 2019, Dip Filter and Random Noise Suppression for GPR B-Scan Data Based on a Hybrid Method in f - x Domain, *Remote Sensing*, 11 (18).
- Zhou, X. R., Chen, H. H. ve Li, J. L., 2018, An Automatic GPR B-Scan Image Interpreting Model, *IEEE Transactions on Geoscience and Remote Sensing*, 56 (6), 3398-3412.
- Zhou, X. R., Chen, H. H. ve Hao, T., 2019, Efficient Detection of Buried Plastic Pipes by Combining GPR and Electric Field Methods, *IEEE Transactions on Geoscience and Remote Sensing*, 57 (6), 3967-3979.



EKLER

EK 1: Jupyter Notebook Test Kodu

```

# import pandas as pd
import random, math
import numpy as np
from keras.preprocessing.image import load_img, img_to_array
from keras.applications.vgg16 import VGG16, preprocess_input
from keras.models import Sequential, Model
from keras.layers import Input, Dense, Dropout, Activation, Flatten
from keras.optimizers import SGD

# model material definition
classes_material = ['alimunia', 'nylon', 'pec', 'silicon', 'wood']
nb_classes_material = len(classes_material)
current_dir = "/notebooks"
img_rows, img_cols = 224, 224
def build_model_material() :
    input_tensor = Input(shape=(img_rows, img_cols, 3))
    vgg16 = VGG16(include_top=False, weights='imagenet',
input_tensor=input_tensor)
    _model1 = Sequential()
    _model1.add(Flatten(input_shape=vgg16.output_shape[1:]))
    _model1.add(Dense(256, activation='relu'))
    _model1.add(Dropout(0.5))
    _model1.add(Dense(nb_classes_material, activation='softmax'))
    model_material=Model(inputs=vgg16.input, outputs=_model1(vgg16.output))

# model
for layer in model_material.layers[:15]:
    layer.trainable = False

```

```

model_material.compile(loss='categorical_crossentropy',
                        optimizer=SGD(lr=1e-4, momentum=0.9), metrics=['accuracy'])
return model_material

# model soil definition

classes_soil = ['dry soil', 'moist soil', 'wet soil']
nb_classes_soil = len(classes_soil)
current_dir = "/notebooks"
img_rows, img_cols = 224, 224
def build_model_soil() :
    input_tensor = Input(shape=(img_rows, img_cols, 3))
    vgg16 = VGG16(include_top=False, weights='imagenet',
input_tensor=input_tensor)
    _model = Sequential()
    _model.add(Flatten(input_shape=vgg16.output_shape[1:]))
    _model.add(Dense(256, activation='relu'))
    _model.add(Dropout(0.5))
    _model.add(Dense(nb_classes_soil, activation='softmax'))
    model_soil = Model(inputs=vgg16.input, outputs=_model(vgg16.output))

# model
for layer in model_soil.layers[:15]:
    layer.trainable = False
model_soil.compile(loss='categorical_crossentropy',
                   optimizer=SGD(lr=1e-4, momentum=0.9), metrics=['accuracy'])
return model_soil

# model shape definition
classes_shape = ['küp', 'silindir', 'üçgen']
nb_classes_shape = len(classes_shape)
def build_model_shape() :
    input_tensor = Input(shape=(img_rows, img_cols, 3))

```

```

vgg16 = VGG16(include_top=False, weights='imagenet',
input_tensor=input_tensor)

```

```

_model = Sequential()
_model.add(Flatten(input_shape=vgg16.output_shape[1:]))
_model.add(Dense(256, activation='relu'))
_model.add(Dropout(0.5))
_model.add(Dense(nb_classes_shape, activation='softmax'))
model_shape = Model(inputs=vgg16.input, outputs=_model(vgg16.output))

```

```

# model
for layer in model_shape.layers[:15]:
    layer.trainable = False
model_shape.compile(loss='categorical_crossentropy',
                    optimizer=SGD(lr=1e-4, momentum=0.9), metrics=['accuracy'])
return model_shape

```

```
#####
```

```
if __name__ == "__main__":
```

```

    # model soil
    model_soil = build_model_soil()
    model_soil.load_weights("soil-model.hdf5")

```

```

    # model shape
    model_shape = build_model_shape()
    model_shape.load_weights("shape-model.hdf5")

```

```

    # model material
    model_material = build_model_material()
    model_material.load_weights("material-model.hdf5")

```

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Umut ÖZKAYA
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Diyarbakır / 1987
Telefon : 0542 2870104
Faks : -
e-mail : uozkaya@ktun.edu.tr

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Konya Lisesi, Meram, KONYA	2005
Üniversite	: Eskişehir Osmangazi Üniversitesi, Odunpazarı, ESKİŞEHİR	2012
Yüksek Lisans	: Selçuk Üniversitesi, Selçuklu, KONYA	2016
Doktora	: Konya Teknik Üniversitesi, Selçuklu, KONYA	2020

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2012-2014	Bozok Üniversitesi	Araştırma Görevlisi
2014-2018	Selçuk Üniversitesi	Araştırma Görevlisi
2018-	Konya Teknik Üniversitesi	Araştırma Görevlisi

UZMANLIK ALANI

Elektromanyetik Alanlar ve Mikrodalga Tekniği, GPR, Anten Teorisi, Yapay Zekâ, Yapay Sinir Ağları, Görüntü İşleme, Derin Öğrenme

YABANCI DİLLER

İngilizce (YÖKDİL 2017– 72.5)

PROJELER

YAYINLAR

SCI-İndeksli Dergilerde Yayınlanmış Makaleler

- Umut Ozkaya, Farid Melgani, Mesay Belete Bejiga, Levent Seyfi, Massimo Donelli, ‘GPR B-Scan Image Analysis with Deep Learning Methods’,

Measurement,2020, <https://doi.org/10.1016/j.measurement.2020.107770>. (Kabul edildi, Doktora Tezinden).

- U. Ozkaya, L. Seyfi , ‘Deep Dictionary Learning Application in GPR B-Scan Images.’- Signal, Image and Video Processing, July 2018, doi:10.1007/s11760-018-1313-x. (Doktora Tezinden)
- Umut Özkaya, Levent Seyfi, A Comparative Study on Parameters of Leaf Shape Patch Antenna Using Hybrid Artificial Intelligence Network Models, Neural Computing and Applications, DOI: 10.1007/s00521-016-2620-1.
- Umut Özkaya, Levent Seyfi, A Novel Fuzzy Logic Model for Intelligent Traffic Systems, Electronics World, Vol. 122(1960), pp.36-39. April 2016. ISSN:1365-4675.

Diğer İndeksli Uluslararası Hakemli Dergilerde Yayımlanmış Makaleler

- U. Ozkaya, L. Seyfi, ‘Yere Nüfuz Eden Radar B Tarama Görüntülerinin Az Parametreye Sahip Konvolüsyonel Sinir Ağı İle Değerlendirilmesi’. Geomatik, 2021. (Kabul Edildi-Doktora Tezinden).
- U. Ozkaya, L. Seyfi, ‘A Hybrid Pattern Recognition System for Detecting Buried Object in GPR Images’- Helix Vol. 8(2): 3151-3159, DOI 10.29042/2018-3151-3159.
- Şaban Öztürk, Umut Özkaya, Bayram Akdemir, Levent Seyfi, Soft Tissue Sacromas Segmentation using Optimized Otsu Thresholding Algorithms, International Journal of Engineering Technology, Management and Applied Sciences, September 2017, Volume 5, Issue 9, ISSN 2349-4476.
- Umut Özkaya, Levent Seyfi, Optimal Rectangular Microstrip Antenna with and without Air Gaps Design by means of Particle Swarm Optimization and Vortex Search Algorithm, International Journal of Computer Theory and Engineering (ISSN:1793-8201).
- Umut Özkaya, Levent Seyfi, Dimension Optimization of Microstrip Patch Antenna in X/Ku Band via Artificial Neural Network, Social and Behavioral Sciences, Volume 195, pp. 2520–2526, ISSN: 1877-0428, doi:10.1016/j.sbspro.2015.06.434. (Yüksek Lisans Tezinden).

Uluslararası Konferans Bildirileri (Tam Metin Basılan):

- Umut Özkaya, Levent Seyfi ve Ercan Yıldız, Analysis of Electromagnetic Radiation in Daily Life, 2nd International Symposium on Innovative Approaches in Scientific Studies, pp. 505-509, Samsun, Turkey, 30 Nov.-2 December, 2018.
- Umut Özkaya, Levent Seyfi, Radiation Exposure Level Identification of Cellular Phone in Standby Model, 2nd International Symposium on Innovative Approaches in Scientific Studies, pp. 510-513, Samsun, Turkey, 30 Nov.-2 December, 2018.
- Umut Özkaya, Levent Seyfi, Fine-Tuning Models Comparisons on Garbage Classification for Recyclability, 2nd International Symposium on Innovative Approaches in Scientific Studies, pp. 514-517, Samsun, Turkey, 30 Nov.-2 December, 2018.

- Umut Özkaya, Levent Seyfi, Dimension Forecast in Microstrip Antenna for C/X/Ku Band by Artificial Neural Network, 2nd International Symposium on Innovative Approaches in Scientific Studies, pp. 518-522, Samsun, Turkey, 30 Nov.-2 December, 2018.
- Umut Özkaya, Levent Seyfi, Hybrid Neural Network Optimization for Feed Point Determination in Antenna Design, International Conference on Information Technologies, pp. 28-35, Kaunas, Lithuania, 27-29 April, 2018.
- Umut Özkaya, Şaban Öztürk, Levent Seyfi, Bayram Akdemir, “Non-Magnetic Materials Assignment based on Artificial Neural Network”, 1st International Symposium on Innovative Approaches in Scientific Studies, 11-13 April, 2018, Antalya-Turkey.
- Umut Özkaya, Şaban Öztürk, Levent Seyfi, Bayram Akdemir, “Faults Detection With Image Processing Methods In Textile Sector”, 1st International Symposium on Innovative Approaches in Scientific Studies, 11-13 April, 2018, Antalya-Turkey.
- Şaban Öztürk, Umut Özkaya, Bayram Akdemir, Levent Seyfi, A. Afşin Kulaksız, Combining Different Image Parts of Instruments with Image Mosaicing, 4th International Scientific-Practical Conference Problems of Infocommunications. Science and Technology, October 10-13, 2017 Kharkiv, Ukraine.
- Umut Özkaya, Levent Seyfi, Economic Analysis of Wind Turbine Plant in Konya Region, International Conference on Advances in Science and Arts (ICASA 2017), pp. 186-189, İstanbul, 29-31 March, 2017.
- Umut Özkaya, Şaban Öztürk, Levent Seyfi, Bayram Akdemir, Novel Strategies for MPPT Operation, International Conference on Advances in Science and Arts (ICASA 2017), pp. 180-185, İstanbul, 29-31 March, 2017.
- Umut Özkaya, Şaban Öztürk, Levent Seyfi, Bayram Akdemir, Region Analysis of Buried Object Based on Fully Automated Image Processing, International Conference on Advances in Science and Arts (ICASA 2017), pp. 175-179, İstanbul, 29-31 March, 2017.
- Umut Özkaya, Levent Seyfi, Torque Control of Three Degree Freedom Robot Manipulator by Artificial Neural Network, 1st International Mediterranean Science and Engineering Congress (IMSEC 2016), pp. 1669-1674, Adana, Turkey, 26-28 October 2016, e-ISBN 978-975-1111-XX-1.
- Umut Özkaya, Levent Seyfi, Modeling and Analysis of Absorbing Boundary Condition in Antenna Design, CBU International Conference Innovations in Science and Education, pp. 832-839, Prague, Czech Republic, 23-25 March 2016, ISSN: 805-997X (Print), 1805-9961 (Online).

Uluslararası Konferans Bildirileri (Özet Metin Basılan):

- Umut Özkaya, Levent Seyfi, Optimal Rectangular Microstrip Antenna with and without Air Gaps Design by means of Particle Swarm Optimization and Vortex Search Algorithm, IT025, pp. 50.
- Umut Özkaya, Levent Seyfi, Diagnosis of Diabetes Risk by Using Artificial Neural Networks, International Congress on Fundamental and Applied Sciences (ICFAS 2016), pp. 84, 22-26 August 2016, İstanbul, Turkey.