T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME TEKNİKLERİNE DAYALI ENKAZ ALTI CANLI VE KONUM TESPİTİ

Özden NİYAZ

DOKTORA TEZİ
Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Elektronik Programı

Danışman
Prof. Dr. Burcu ERKMEN

Eş-Danışman
Doç. Dr. Peyman MAHOUTI

Mart, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME TEKNİKLERİNE DAYALI ENKAZ ALTI CANLI VE KONUM TESPİTİ

Özden NİYAZ tarafından hazırlanan tez çalışması 13.03.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Elektronik Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Prof. Dr. Burcu ERKMEN
Yıldız Teknik Üniversitesi
Danışman

Doç. Dr. Peyman MAHOUTI
Yıldız Teknik Üniversitesi
Eş-Danışman

Jüri Üyeleri

Prof. Dr. Burcu ERKMEN, Danışman
Yıldız Teknik Üniversitesi _____

Prof. Dr. Nurhan TÜRKER TOKAN, Üye
Yıldız Teknik Üniversitesi _____

Prof. Dr. Mürvet KIRCI, Üye
İstanbul Teknik Üniversitesi _____

Doç. Dr. Revna ACAR VURAL, Üye
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üye. Nurullah ÇALIK, Üye
İstanbul Medeniyet Üniversitesi _____

Danışmanım Prof. Dr. Burcu ERKMEN sorumluluğunda tarafımca hazırlanan Derin Öğrenme Tekniklerine Dayalı Enkaz Altı Canlı ve Konum Tespiti başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Özden NİYAZ

İmza

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 121E409 numaralı proje kapsamında desteklenmiştir.

Depremde hayatını kaybedenlere
ve geride kalanlara adanmıştır.

TEŞEKKÜR

Doktora öğrenimim boyunca bilgi ve deneyimleriyle yolumu aydınlatan kıymetli danışman hocam Prof. Dr. Burcu Erkmen'e sonsuz hürmet ve minnetlerimi sunarım. Kendisi, akademik gelişimimde her zaman yanımda olmuş, teşvik edici yaklaşımı ve derin bilgisiyle bana ilham vermiştir.

Eş danışmanım Doç. Dr. Peyman Mahouti'ye tez çalışması boyunca göstermiş olduğu desteği ve değerli katkıları için içten teşekkürlerimi sunarım. Proje yürütücüsü ve çok değerli hocam Prof. Dr. Nurhan Türker Tokan'a, her daim bu projenin bir parçası olmamı desteklediği ve çalışmalarıma sunduğu katkılar için en derin teşekkürlerimi sunarım. Prof. Dr. Ahmet Serdar Türk ve sevgili hocam Doç. Dr. Sultan Aldırmaz'a, projeye dair değerli fikirleri ve bilimsel bakış açılarıyla sundukları değerli katkılar için çok teşekkür ederim. Tezin ilerlemesine önemli katkılar sağlayan değerli hocam Dr. Öğr. Üyesi Nurullah Çalık'a teşekkürü borç bilirim. Ayrıca, bu çalışmanın gerçekleşmesine katkıda bulunan TÜBİTAK ve AFAD'a sağladıkları destek için teşekkürlerimi sunarım. Proje ekibimize katkı ve yardımları için çok teşekkür ediyorum.

Sevgileri ve destekleriyle her zaman yanımda olduğunu hissettiren dostlarıma minnettarım. İyi niyetini esirgemeyerek bu zorlu süreci hafifleten kıymetli hocalarıma ve sevgili çalışma arkadaşlarıma içtenlikle teşekkür ederim.

Hayata ilk geldiğim günden beri daima yanımda olan biricik aileme en kalbi teşekkürlerimi sunarım. Onların sabrı, anlayışı ve teşviki olmasaydı, bu yolculuğu tamamlamak çok zor olurdu. Onların varlığı, sevgisi ve desteği, benim her zaman en değerli kaynağım olmuştur. Bu tez, ailemin emeği ve fedakarlıkları sayesinde hayat bulmuştur.

Hayat arkadaşım Ulaş Yılmaz'a ve canımız Pippin'e, her an yanımda oldukları, sevgileriyle her daim yüzümde bir gülümseme bıraktıkları için kalbimin en derinlerinden teşekkür ediyorum.

Özden NİYAZ

İÇİNDEKİLER

SİMGE LİSTESİ viii

KISALTMA LİSTESİ ix

ŞEKİL LİSTESİ x

TABLO LİSTESİ xiii

ÖZET xv

ABSTRACT xvii

1 GİRİŞ 1

1.1 Literatür Araştırması . . . 1

1.1.1 Canlı Tespitine Genel Bakış . . . 2

1.1.2 Tespit Sinyalleri . . . 4

1.1.3 Veri Kaynakları . . . 6

1.1.4 Ölçüm Düzenekleri . . . 7

1.1.5 Ön İşleme Yöntemleri . . . 9

1.1.6 Tespit Yöntemleri . . . 10

1.2 Tezin Amacı . . . 14

1.3 Hipotez . . . 14

2 YÖNTEM 15

2.1 Ön İşleme Yöntemleri . . . 16

2.1.1 Gürültü Giderme . . . 16

2.1.2 Hızlı Fourier Dönüşümü . . . 18

2.1.3 Kısa Zamanlı Fourier Dönüşümü . . . 18

2.1.4 Ampirik Mod Ayrışımı . . . 19

2.1.5 Değişken Mod Ayrışımı . . . 19

2.2 Derin Öğrenme Yöntemleri . . . 21

2.2.1 Üretici Çekişmeli Ağ . . . 21

2.2.2 Uzun Kısa Süreli Bellek . . . 22

2.2.3 Konvolüsyonel Sinir Ağları . . . 24

2.2.4 Zamansal Konvolüsyonel Ağlar 25

3 KURGU TANIMI VE MATERYAL 26
3.1 Ekipmanların ve Ölçüm Ortamının Tanıtımı 28
3.2 Ön Çalışmalar 30
3.2.1 Solunum Sensörü ile Kaydedilen Veri 30
3.2.2 Benzetim Ortamında Oluşturulan Veri 32
3.3 Laboratuvar ve Saha Çalışmaları 37
3.3.1 Laboratuvar Ortamında Toplanan Veri 37
3.3.2 Saha Ortamında Toplanan Veri 44

4 CANLI TESPİTİ 54
4.1 Derin Öğrenmede Model Doğrulama 54
4.2 Performans Metrikleri 55
4.3 Solunum Sinyalleri ile Ön Çalışma 56
4.4 Benzetim Ortamında Oluşturulan Veriler ile Canlı Tespiti 57
4.5 Laboratuvar Ortamında Toplanan Veriler ile Canlı Tespiti 59
4.6 Saha Ortamında Toplanan Veriler ile Canlı Tespiti 64

5 KONUM TESPİTİ 68

6 SONUÇ 72

KAYNAKÇA 75

A ETİK KURUL KARARLARI 82

B EK ÇALIŞMALAR 84

TEZDEN ÜRETİLMİŞ YAYINLAR 86

SİMGE LİSTESİ

ϵ	Elektriksel Geçirgenlik
σ	Elektriksel İletkenlik
f	Frekans
ε_0	Havanın Bağıl Geçirgenliği
μ_0	Havanın Manyetik Geçirgenliği
λ	Eşik Değeri
ε_r	Malzemenin Dielektrik Sabiti
μ_r	Malzemenin Bağıl Manyetik Geçirgenliği
π	Pi Sabiti
σ	Standart Sapma
α	Zayıflama Katsayısı

KISALTMA LİSTESİ

CFAR	Sabit Yanlış Alarm Oranı
CNN	Konvolüsyonel Sinir Ağları
DFT	Ayrık Fourier Dönüşümü
DL	Derin Öğrenme
EMD	Ampirik Mod Ayrışımı
FFT	Hızlı Fourier Dönüşümü
GAN	Çekişmeli Üretici Ağ
IMF	İçsel Mod Fonksiyonları
IR-UWB	Darbe Radarlı Ultra Geniş Bant
JTFA	Zaman-Frekans Analizi
LOS	Görüş Hattı
LSTM	Uzun Kısa Süreli Bellek
RNN	Yinelemeli Yapay Sinir Ağları
RCNN	Bölge Tabanlı Konvolüsyonel Sinir Ağları
SNR	Sinyal-Gürültü Oranı
STFT	Kısa Zamanlı Fourier Dönüşümü
TCN	Zamansal Konvolüsyonel Ağlar
UWB	Ultra Geniş Bant
USRP	Evrensel Yazılım Tabanlı Radyo
VMD	Değişken Mod Ayrışımı
VNA	Vektör Ağ Analizörü
WT	Dalgacık Dönüşümü
WVD	Wigner-Ville Dağılımı

ŞEKİL LİSTESİ

Şekil 1.1 Literatür araştırmasının genel yapısı 3
Şekil 1.2 Radar ile canlı tespitine ilişkin şematik gösterim 4
Şekil 1.3 Sinyalin yapı malzemesinin ardında yayılımı 8
Şekil 1.4 Duvar arkası ölçüm düzeni 8
Şekil 2.1 Tez kapsamında izlenen adımların blok diyagramı 15
Şekil 2.2 Üretici çekişmeli ağ yapısı 21
Şekil 2.3 LSTM (a) Ağ yapısı (b) Bir hücreli hafıza bloğu 23
Şekil 2.4 CNN ağının genel yapısı 25
Şekil 3.1 Ölçüm sisteminin genel yapısı 29
Şekil 3.2 Laboratuvarda oluşturulan enkaz modeli a) Önden görünümü b) Yandan görünümü 29
Şekil 3.3 Laboratuvarda bulunan enkaz alanı a) Ölçüm düzeneği b) Uzaktan takip 30
Şekil 3.4 Solunum sinyali oluşturmaya yönelik ölçüm düzeneği 31
Şekil 3.5 Normal nefes ve konuşma sırasında kaydedilen sinyaller 32
Şekil 3.6 Enkaz modelinde yer alan tuğla, beton, ahşap ve gaz beton gösterimi 34
Şekil 3.7 Sağlıklı bir yetişkin nefes alıp verirken göğüs çapında meydana gelen ideal değişim (solunum hızı dakikada 12 iken) 34
Şekil 3.8 Üç farklı sınıfa ait örneğin zamana bağlı değişimi 35
Şekil 3.9 Ortamın zayıflama analizine ait S_{21} kaydı ve frekans seçimi . . . 37
Şekil 3.10 Enkaz boş iken alınan çeşitli faz değişimleri 38
Şekil 3.11 Yatay ve dikey pozisyonlarda faz değişimi 39
Şekil 3.12 Birinci frekansta enkaz boş iken kaydedilen genlik ve faz değişimleri 40
Şekil 3.13 Birinci frekansta enkazda nefes alan biri varken kaydedilen genlik ve faz değişimleri 40
Şekil 3.14 Birinci frekansta enkazda biri hareket ediyorken kaydedilen genlik ve faz değişimleri 41
Şekil 3.15 İkinci frekansta enkaz boş iken kaydedilen genlik ve faz değişimleri 41
Şekil 3.16 İkinci frekansta enkazda nefes alan biri varken kaydedilen genlik ve faz değişimleri 42

Şekil 3.17 İkinci frekansta enkazda biri hareket ediyorken kaydedilen genlik ve faz değişimleri 42
Şekil 3.18 Üçüncü frekansta enkaz boş iken kaydedilen genlik ve faz değişimleri 43
Şekil 3.19 Üçüncü frekansta enkazda nefes alan biri varken kaydedilen genlik ve faz değişimleri 43
Şekil 3.20 Üçüncü frekansta enkazda biri hareket ediyorken kaydedilen genlik ve faz değişimleri 44
Şekil 3.21 Farklı frekanslarda genliğin zamana bağlı değişimi (enkaz boş, nefes sinyali, hareket sinyali) 44
Şekil 3.22 Farklı frekanslarda fazın zamana bağlı değişimi (enkaz boş, nefes sinyali, hareket sinyali) 45
Şekil 3.23 Enkaz altı canlı tespiti için sahada (çift katlı enkaz) bulunan enkaza ait yükseltici kullanılarak elde edilen zayıflama analizi (antenler arası mesafe = 657 cm) 47
Şekil 3.24 Enkaz boşken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri 47
Şekil 3.25 Enkaz boşken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri 48
Şekil 3.26 Enkaz içinde derin nefes alan biri varken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri 48
Şekil 3.27 Enkaz içinde derin nefes alan biri varken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri 49
Şekil 3.28 Enkaz içinde göğsünü hareket ettiren biri varken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri 49
Şekil 3.29 Enkaz içinde göğsünü hareket ettiren biri varken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri 50
Şekil 3.30 Enkaz içinde rastgele hareket eden biri varken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri 50
Şekil 3.31 Enkaz içinde rastgele hareket eden biri varken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri 51
Şekil 3.32 Enkaz içinde ara sıra duvara vuran biri varken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri 51
Şekil 3.33 Enkaz içinde ara sıra duvara vuran biri varken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri 52
Şekil 3.34 Farklı frekanslarda genliğin zamana bağlı değişimi (enkaz boş, nefes sinyali, göğüs hareketi sinyali, rastgele hareket sinyali, vurma sinyali) 52

Şekil 3.35 Farklı frekanslarda fazın zamana bağlı değişimi (enkaz boş, nefes sinyali, göğüs hareketi sinyali, rastgele hareket sinyali, vurma sinyali) 53
Şekil 4.1 Derin öğrenme modellerini oluşturmaya yönelik genel yapı 55
Şekil 4.2 Benzetim ortamında oluşturulan veriler ile canlı tespit modeli . . 57
Şekil 4.3 Orijinal sinyal ve GAN ile üretilmiş sinyal (genlik) 60
Şekil 4.4 Orijinal sinyal ve GAN ile üretilmiş sinyal (faz) 60
Şekil 5.1 İki aşamalı tespit modeline ait gösterim 68
Şekil 5.2 Konum tespit sistemi için kullanılan ölçüm alanı (AFAD sahası) . 69
Şekil 5.3 Hedef konumlandırma ölçüm sahasında kullanılan uygulama uzayı 70
Şekil B.1 Saha ortamında toplanan verilerin maksimum FFT genliklerinin incelenmesi 84
Şekil B.2 Saha ortamında toplanan veriler üzerinde uygulanan farklı gürültü giderme yöntemlerinin frekans dağılımına etkisi 84
Şekil B.3 Saha ortamında toplanan ham veriler 85
Şekil B.4 Saha ortamında toplanan verilere gürültü giderme işlemi uygulanması 85

TABLO LİSTESİ

Tablo 1.1 Son yıllarda hedef tespitine yönelik yapılan çalışmalara ait bilgiler (2019-2024) 13
Tablo 3.1 Nefes alınmış durumda iken akciğerin elektriksel özellikleri . . . 27
Tablo 3.2 Nefes verilmiş durumda iken akciğerin elektriksel özellikleri . . 27
Tablo 3.3 Elektromanyetik alan benzetim programında oluşturulan profiller 33
Tablo 3.4 Laboratuvarda yapılan ölçüme katılan kişilerin özellikleri 39
Tablo 4.1 Solunum sensörü verileri için farklı derin öğrenme modellerinin performans karşılaştırması (doğrulama ve test) 56
Tablo 4.2 Solunum sensörü verileri için farklı derin öğrenme modellerinin performans metrikleri 56
Tablo 4.3 TCN ağının hiperparametre aralığı 57
Tablo 4.4 Benzetim ortamında oluşturulan veriler ile canlı tespit modelinin sonuçları (TCN) 58
Tablo 4.5 Benzetim ortamında oluşturulan veriler ile solunum sınıflandırma modelinin sonuçları 58
Tablo 4.6 Laboratuvar ortamında toplanan veriler ile tespit sonuçları (TCN) 59
Tablo 4.7 Laboratuvar ortamında toplanan veriler ile oluşturulan kapsamlı sınıflandırma problemleri 61
Tablo 4.8 CNN ağının hiperparametre aralığı 61
Tablo 4.9 LSTM ağının hiperparametre aralığı 61
Tablo 4.10 TCN ağının hiperparametre aralığı 62
Tablo 4.11 Farklı derin öğrenme modellerinin çeşitli problemler üzerindeki performans metrikleri 62
Tablo 4.12 Derin öğrenme modelleri ile elde edilen tespit sonuçları (başarım oranı [%]) 63
Tablo 4.13 Veri setlerindeki hareket durumları ve toplam kayıt süreleri . . . 64
Tablo 4.14 Saha ortamında toplanan veri setinden elde edilen istatistiki özellikler 65
Tablo 4.15 Saha ortamında toplanan veriler ile oluşturulan kapsamlı sınıflandırma problemleri 65
Tablo 4.16 CNN ağının hiperparametre aralığı 66
Tablo 4.17 TCN ağının hiperparametre aralığı 66

Tablo 4.18 Saha ortamında toplanan veriler ile oluşturulan kapsamlı sınıflandırma problemleri ve tespit sonuçları 67
Tablo 5.1 Kişinin bulunduğu konum ve anten bilgisine göre ilk aşamanın cevabı 70
Tablo 5.2 Kişinin bulunduğu konum ve anten bilgisine göre ikinci aşamanın cevabı 71
Tablo 5.3 Konuma bağlı hedef tespit modellerinin performans metrikleri . . 71
Tablo 6.1 Tez çalışmasında kullanılan modeller, teknolojiler, veri enstrümantasyonu ve sonuçlar 74

ÖZET

Derin Öğrenme Tekniklerine Dayalı Enkaz Altı Canlı ve Konum Tespiti

Özden NİYAZ

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Doktora Tezi

Danışman: Prof. Dr. Burcu ERKMEN
Eş-Danışman: Doç. Dr. Peyman MAHOUTI

Günümüzde, deprem kaynaklı binaların çökmesi sonucu meydana gelen hayat kayıpları ve enkaz altında uzun süre bekleyen kurtarma müdahaleleri, ciddi bir sorun olarak öne çıkmaktadır. Özellikle deprem kuşağında bulunan ülkemizde, mevcut arama-kurtarma yöntemlerinin dezavantajları nedeniyle, radar sinyallerinden yararlanarak derin öğrenme tabanlı enkaz altı canlı ve konum tespit sistemlerine duyulan ihtiyaç giderek artmaktadır. Bu tez çalışmasında, 150–650 MHz bandında ölçülen radar sinyalleri kullanılarak, enkaz ortamında solunum ve hareket kaynaklı sinyallerin ayrıştırılması hedeflenmiştir. Zorlu çevresel koşullar altında geleneksel yöntemlerin yetersiz kaldığı durumlarda, zaman–frekans dönüşümleri ile veriye özgü geliştirilmiş derin öğrenme modellerinin entegrasyonunun, tespit doğruluğunu artıracağı öngörülmüştür.

Çalışmanın kapsamlı değerlendirmesi, benzetim ortamında oluşturulan fantom verileri, laboratuvar ortamında gerçekleştirilen kontrollü ölçümler ve gerçek saha verilerinin kullanılmasıyla farklı senaryolarda gerçekleştirilmiştir. Laboratuvar ortamında gerçek yapı malzemelerinden oluşturulan enkaz modeli ve gerçek arama-kurtarma sahalarından elde edilen uzun süreli ölçümler, derin öğrenme tabanlı yaklaşımların çeşitli sinyal işleme teknikleriyle desteklendiğinde enkaz altındaki bireylerin tespitini kolaylaştırdığını ortaya koymuştur. Ayrıca, çoklu anten konfigürasyonları aracılığıyla elde edilen faz ve genlik bilgilerinin işlenmesiyle, hedefin konumunun belirlenebileceği derin öğrenme yöntemleri kanıtlanmıştır.

Önerilen sistem, enkaz ortamındaki karmaşık sinyaller arasında operatör kaynaklı gürültülerden arındırılmış biçimde, enkaz altında sesini duyuramayan bireylerin tespitine odaklanmaktadır. Bununla birlikte, sınırlı katılımcı sayısı, ortam gürültüsü ve yüksek hesaplama gereksinimleri gibi unsurlar, ileri araştırmaların ele alması gereken noktalar arasında yer almaktadır.

Sonuç olarak, bu tez çalışması radar verilerine özgü olarak oluşturulmuş derin öğrenme tekniklerine dayalı olarak enkaz altında canlı ve konum tespiti gerçekleştirmekte olup, arama kurtarma operasyonlarına yönelik geliştirilebilecek tespit cihazlarına dair kapsamlı bir kaynak sunmaktadır.

Anahtar Kelimeler: Enkaz altı canlı tespiti, konum tespiti, örüntü tanıma, derin öğrenme, canlı tespit radarı.

ABSTRACT

Deep Learning-Based Detection and Localization of Human Under Debris

Özden NİYAZ

Department of Electronics and Communication Engineering
Doctor of Philosophy Thesis

Supervisor: Prof. Dr. Burcu ERKMEN
Co-supervisor: Assoc. Prof. Dr. Peyman MAHOUTI

Today, the loss of life caused by building collapses during earthquakes and the extended waiting times for rescue operations under debris have become serious issues. In our country, situated in an earthquake-prone region, the limitations of current search-and-rescue methods have increased the demand for deep learning-based systems that utilize radar signals to detect survivors and determine their locations. In this thesis, the objective is to distinguish between respiration- and movement-induced signals in debris environments by employing radar signals measured in the 150–650 MHz band. It is anticipated that, in conditions where traditional methods fall short under harsh environmental circumstances, integrating time–frequency transformations with data-specific deep learning models will enhance detection accuracy.

A comprehensive evaluation was conducted across various scenarios using phantom data generated in a simulation environment, controlled measurements in the laboratory, and real field data. Controlled measurements from a laboratory-constructed debris model using actual building materials and long-term data from real search-and-rescue sites have demonstrated that deep learning approaches supported by diverse signal processing techniques facilitate the detection of individuals under debris. Furthermore, deep learning methods that process phase and amplitude information obtained through multiple antenna configurations have proven effective in determining the target's location.

The proposed system focuses on detecting individuals whose voices cannot be heard under debris by filtering out operator-induced noise from complex signal environments. Nonetheless, challenges such as a limited number of participants, ambient noise, and high computational requirements highlight areas for future research.

In conclusion, this thesis presents a deep learning-based approach specifically developed for radar data to detect survivors and determine their positions under debris, thereby providing a comprehensive resource for the development of detection devices for search-and-rescue operations.

Keywords: Human detection under debris, localization, pattern recognition, deep learning, live detection radar.

1
GİRİŞ

Günümüzde doğal afetlere karşı alınan önlemlere rağmen, afetin yıkıcı sonuçları devam etmektedir. 6 Şubat 2023 tarihinde Türkiye'de meydana gelen ve en büyüğü 7.7 M_w şiddetinde olan depremler; 10 ili etkilemiş, 48.000'den fazla can kaybına sebep olmuş, 35.355 binanın yıkılması ile sonuçlanmıştır [1]. Arama kurtarma ekipleri haftalar boyunca yoğun çalışmalar yürütmüş ve enkaz altında en uzun süre hayatta kalan afetzedeler, $296.$ saatte kurtarılmıştır [2]. Bu üzücü sonuçlar, mevcut arama ve kurtarma yöntemlerinin ihtiyaç duyulan hız ve yeterlilik seviyesine henüz ulaşamadığını göstermektedir. Literatürde ve sahada kullanılan tespit teknolojileri önemli ilerlemeler kaydetmiş olsa da, yenilikçi tespit yöntemleri geliştirilmediği sürece, bu konu önemini ve güncelliğini korumaya devam edecektir. Bu bağlamda, literatür araştırmasında mevcut tespit yaklaşımları detaylı bir şekilde incelenmiş ve gelecekteki çalışmalara yönelik öngörüler sunulmuştur.

1.1 Literatür Araştırması

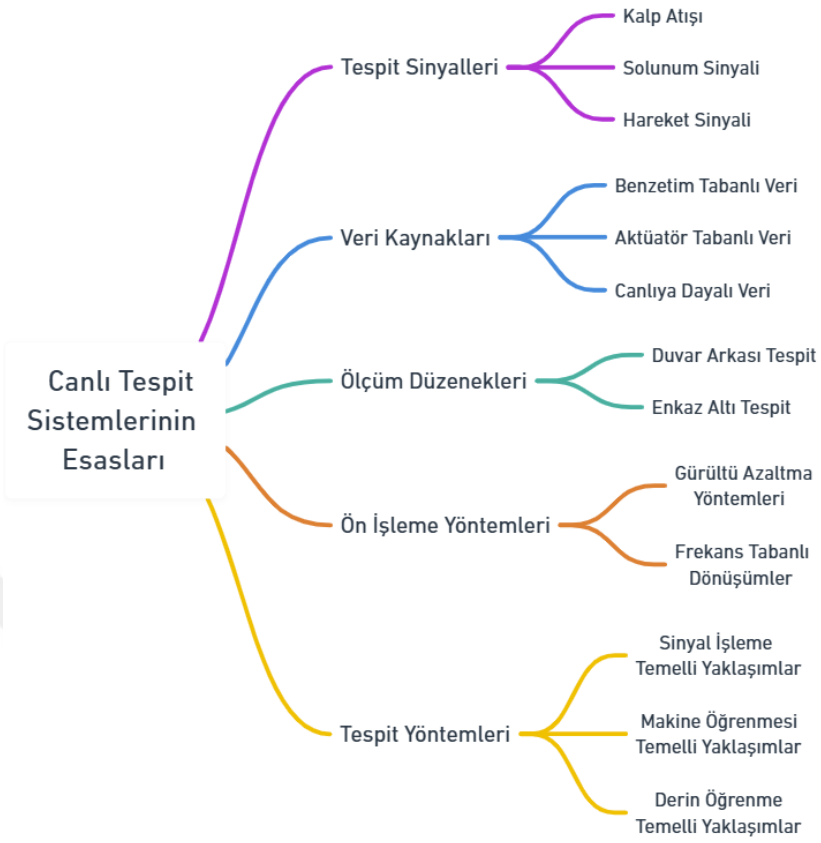
Afet ve felaket bölgelerinde enkaz altında sıkışık alanda kalan insanların tespiti için geliştirilen teknolojiler, son yıllarda kayda değer ilerlemeler göstermiştir. Özellikle, toprak veya kar altında kalan kişilerin tespiti amacıyla kullanılan yer radarı ve temassız algılama sistemleri bu alanda son zamanlardaki önemli gelişmeler arasında yer almaktadır [3, 4]. Mikrodalga sistemlerindeki teknolojik ilerlemeler, bu sistemlerin yalnızca uzun menzilli algılama uygulamaları için değil, aynı zamanda insan varlığının tespiti ve insan aktivitelerinin belirlenmesi gibi kısa menzilli uygulamalarda da kullanılabilmesini mümkün kılmaktadır [5]. Benzer bir çalışmada, arama kurtarma operasyonlarında kullanılan radar sistemleri, robotik platformlar, drone teknolojileri, gaz sensörleri, optik, akustik, sismik ve kızılötesi algılama tekniklerinin kapsamlı karşılaştırmalı analizleri sunulmuş; bu tekniklerin avantajları ve sınırlılıkları detaylı bir şekilde incelenmiştir [6]. Özellikle hayati belirtilerin (örneğin solunum ve kalp atışı) algılanmasına yönelik geliştirilen radar sistemlerinin kolay kullanımlı ve hızlı bir şekilde konuşlandırılabilir olması

gerektiğine vurgu yapan bir başka çalışmada, duvarlar ve büyük engellerin arkasındaki insanları tespit etmeye yönelik teknolojiler ele alınmış, ticari olarak mevcut araçların verimliliği değerlendirilmiş ve farklı operasyonel koşullara uygun sistemlerin tasarımına yönelik öneriler sunulmuştur [7]. Radar, yapay zeka, drone, robotik sistemler, gaz sensörleri, akustik, kızılötesi ve optik algılama gibi teknolojilerin bir arada değerlendirildiği benzer bir çalışmada ise insan tespitine yönelik gelişmekte olan yöntemlerin penetrasyon kabiliyetleri, çevresel koşullara bağımlılıkları ve karmaşık arka planlardan kaynaklanan zorlukları üzerinde durulmuştur [8].

Mikrodalga sistemlerinden faydalanılarak baştan sona bir enkaz altı canlı tespit cihazı tasarımına yönelik araştırma taksonomisi, Şekil 1.1'de sunulduğu üzere, kapsamlı bir şekilde ortaya konulmuştur. Literatür araştırmasında öncelikle nefes alma, kalp atışı ve hareket gibi hayati sinyallerin tespiti üzerine yapılan ön çalışmalar incelenmiş, bu tür bir tasarımda hangi sinyallerden yararlanılabileceği ele alınmıştır. Bu kapsamda, nefes alma sinyallerinin genlik ve frekans varyasyonları üzerinden değerlendirilmesi, kalp atışlarının düzenli veya düzensiz ritimlerinin analizi ve kısıtlı alanlardaki hareketlerin algılanmasına yönelik yöntemler incelenmiştir. Ayrıca, benzetim tabanlı, aktüatör odaklı, bir veya birden fazla insanın bulunduğu senaryolardan elde edilen veri türleri değerlendirilerek, bu verilerin sistem oluşturma süreçlerine katkıları ortaya konulmaktadır. Araştırmanın çevresel kurulum kısmında, sinyallerin duvar arkasına veya enkaz altına geçerek algılanabilirliği ve bu tür ortamların sinyal yayılımı üzerindeki etkileri ele alınmıştır. Bunun yanı sıra, sinyallerin işlenmesi sürecinde gürültü ve parazitlerin azaltılmasına yönelik filtreleme yöntemleri, frekans tabanlı dönüşümler ve sinyal iyileştirme teknikleri ayrıntılı olarak ele alınmıştır. Tespit yöntemleri bağlamında, sinyal işleme tabanlı, makine öğrenmesi tabanlı ve derin öğrenme tabanlı modellerin uygulanabilirliği değerlendirilmiş; bu yöntemlerin her birinin güçlü ve sınırlı yönleri kapsamlı bir şekilde incelenmiştir.

1.1.1 Canlı Tespitine Genel Bakış

Hayatta kalan bir kişinin bilinci kapalı olsa dahi, kalp kasılmaları ve solunumun göğüs kafesinde meydana getirdiği periyodik hareketlerin durması mümkün değildir. Radar tabanlı insan tespit sistemlerinin temel prensibi, Şekil 1.2'de gösterildiği gibi, hayatta kalan kişinin mikrohareket ve hareket sinyallerinin iletilen ve alınan radar sinyalleri arasında bir zaman gecikmesi oluşturmasına dayanır. Bu prensip sayesinde, bilinci kapalı olup yanıt veremeyen afetzedelerin tespiti de mümkün hale gelmektedir.



Şekil 1.1 Literatür araştırmasının genel yapısı

1.1.1.1 Görüş Hattında Canlı Tespiti Çalışmaları

Hayati belirtilerin temassız tespiti, görüş hattında (LOS) çalışan radarlar ile mikrohareket sinyallerinin tespiti sayesinde yapılmaktadır. Soluk alıp vermek hayatta kalan kişinin göğüs kafesini periyodik olarak genişletir ve daraltır [9]. Görüş hattında tespit yöntemiyle elde edilen verilerden, arka plan gürültüsü çıkarıldıktan sonra, yaşamsal özelliklerin elde edilmesi Dalgacık Dönüşümü (WT) kullanılarak gerçekleştirilmektedir. Bu sayede solunum hızı ve nabız tespit edilebilmektedir ve aynı çalışmada uzaklık tahmini sayesinde düşme takibi de yapılabilmektedir [10]. Ultra Geniş Bant (UWB) radar teknolojisi kullanarak görüş hattında yapılan çalışmalarda solunum hızı ve kalp atışı, Hızlı Fourier Dönüşümü (FFT) ile tespit edilmektedir [11, 12].

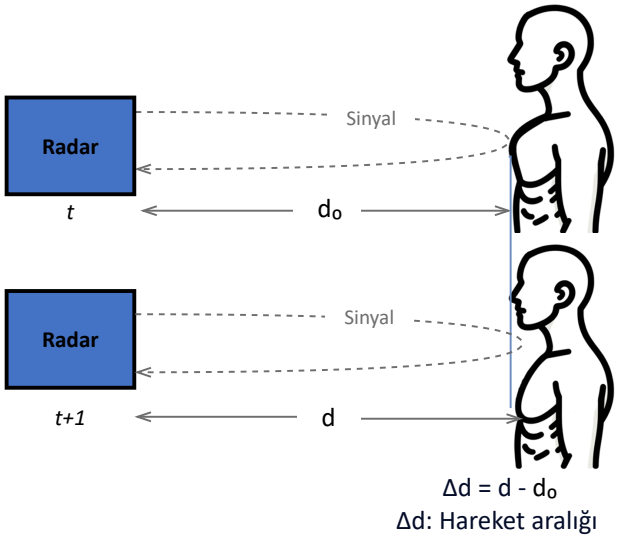
1.1.1.2 Yapı Malzemeleri Ardında Canlı Tespiti Çalışmaları

Yaklaşık 40 yıl önce çalışılmaya başlanan ve günümüzde halen önemini koruyan duvar arkası veya enkaz altı tespit çalışmaları, genellikle beton duvarlar veya çeşitli yapı malzemelerinden oluşan blokların arkasına canlıların yerleştirilmesi

ile gerçekleştirilmektedir. Bloğun arkasındaki canlıların yaşamsal sinyallerinin değerlendirilmesine odaklanan ve radar tabanlı duvar arkası tespit sistemlerini içeren çalışmalar, sıkça karşılaşılan öncü yöntemler arasında yer almaktadır. Bu bağlamda, yaklaşık 30 metre mesafeden beton blok gibi engellerin arkasından insan kalp atışı ve solunumunun tespit edilebildiği sistemler, düşük yoğunluklu bir mikrodalga ışını kullanmakta ve geri yansıyan dalgaların analizi ile hayati bulguları çıkarmaktadır [13]. Ancak, bu alanda uzun yıllardır sürdürülen çalışmaların en büyük zorluklarından biri, nefes sinyalleri ile benzerlik gösteren ve tespiti zorlaştıran gürültü (parazit) etkisinin giderilmesine yönelik çözümler bulmaktır [14]. Bununla birlikte, etraftaki değişkenlerden kaynaklanan interferans etkisi de hala çözülmesi gereken önemli bir sorun olarak varlığını sürdürmektedir [15]. Geçmişte yapılan bu kapsamlı araştırmalara, güncel yaklaşımlar ve ileri teknoloji tabanlı çözümler ile katkı sağlanması gerekmektedir.

1.1.2 Tespit Sinyalleri

İnsan vücudunda periyodik olarak devam eden kalp atışı ve solunumdan kaynaklanan göğüs hareketleri, radar sistemleri tarafından algılanabilen hayati belirtilerdir. Bu hayati belirtiler, göğüs kafesinin küçük genlikli mikro hareketlerinden oluşur ve genellikle kalp atışı, solunum ve genel hareket sinyalleri olarak sınıflandırılır. Kalbin kasılması ve gevşemesiyle oluşan hızlı, düşük genlikli periyodik sinyaller, göğüs kafesindeki küçük titreşimlerle kendini gösterir. Göğüs kafesinin nefes alıp verme döngüsü sırasında meydana gelen daha yavaş ve yüksek



Şekil 1.2 Radar ile canlı tespitine ilişkin şematik gösterim

genlikli periyodik hareketlerden oluşur. Mahsur kalmış bir kişinin istemli ya da istemsiz hareketlerinden kaynaklanan, genliği ve frekansı düzensiz olabilen sinyalleri ifade eder.

1.1.2.1 Kalp Atışı

Sağlıklı bir insanın kalbi, dakikada 60 ile 100 arasında atarak vücuda kan pompalar. Bu durum, özellikle anteroposterior göğüs bölgesinde küçük genlikli ve periyodik hareketlerin oluşmasına neden olur. Hastalara ön tıbbi müdahale yapabilmek amacıyla, bant geçiren filtre kullanarak kalp sinyalini elde etmeye yönelik çalışmalar bulunmaktadır [16]. Kalp atışı tespiti üzerine diğer çalışmalar ise 30 cm genişliğinde bir duvarında arkasında oturan bir insanın kalp atışı eş zamanlı olarak bir nabız sensöründen alınan verilerin anlık frekansları Wigner-Ville Dağılımı (WVD) kullanılarak elde edilmiş ve her iki kaynaktan alınan verilerin $\%95$ güven aralığında olduğu Bland-Altman analizleriyle doğrulanmıştır [17].

1.1.2.2 Solunum Sinyali

Sağlıklı bir insanın solunum sistemi, dakikada 12 ile 20 kez nefes alıp vererek vücudun oksijen ihtiyacını karşılar. Bu durum, özellikle anteroposterior göğüs ve karın bölgesinde, kalp atışına kıyasla daha düşük frekanslı, periyodik ve genlik bakımından daha belirgin değişimlerin oluşmasına neden olur. Yapılan araştırmalar, 20 cm kalınlığında bir beton duvar arkasından 2.5 metreye kadar olan mesafelerde solunum sinyallerinin UWB radarlar ile tespit edilebileceğini göstermiştir [18]. Bir çalışmada, aktüator kullanılarak farklı mesafelerde solunuma benzer hareketlerin tespit edilebilirliği incelenmiş ve WT yöntemiyle solunum hızı belirlenmiştir [19]. Deneysel sonuçlar, insan ve radar arasındaki mesafenin artmasıyla solunum sinyalinin tepe faktörünün yavaşça yükseldiğini, kısa mesafelerde ise güçlü yansımalar nedeniyle tepe faktörünün küçüldüğünü ortaya koymuştur. Bu durum, performansı iyileştirmek için adaptif eşikleme ve arka plan bastırma tekniklerinin kullanımını gerekli kılmıştır [20]. Ayrıca, UWB yansıma verileri, radarın operasyonel bant genişliği içerisindeki farklı alt bantlara ayrılarak analiz edilmekte ve bu alt bantlar arasında frekans boyunca ortalama alma yöntemiyle nefes sinyalleri güçlendirilmektedir [21].

1.1.2.3 Hareket Sinyali

UWB radar teknolojisi, yüksek bant genişliği sayesinde mesafe çözünürlüğü ve duvar penetrasyonu sağlamaktadır. İnsan hareketlerinin, özellikle periyodik hareketlerin (örneğin uzuv hareketleri), güçlü arka plan gürültüsü altında

bile tespit edilebildiği gösterilmiştir. Bu amaçla, FFT ve S-dönüşümü gibi yöntemler kullanılarak insan hareket sinyallerinin merkez frekansları çıkarılmakta ve konumları yüksek doğrulukla belirlenmektedir. Bu teknoloji, enkaz altında kalan deprem veya patlama mağdurlarının yerini tespit etmek gibi kritik arama kurtarma uygulamalarında kullanılmaktadır [22].

1.1.3 Veri Kaynakları

Radar tabanlı canlı tespit sistemleri üzerine yapılan araştırmalarda dört temel veri kaynağı ön plana çıkmaktadır. Bunlar, sayısal ortamda oluşturulan sentetik verilerden oluşan benzetim tabanlı veriler, aktüatörler kullanılarak elde edilen kontrollü ölçümler, gerçek bireylerden alınan canlı insan verileri ve birden fazla insanın bulunduğu ortamlardan toplanan karmaşık sinyalleri içeren çoklu insan verileridir. Her bir veri türü, radar tabanlı hayati sinyal algılama sistemlerinin geliştirilmesine önemli katkılar sağlamakta ve farklı kullanım senaryolarına yönelik çözümler sunmaktadır.

1.1.3.1 Benzetim Tabanlı Veri

Benzetim tabanlı çalışmalar, UWB radar sistemlerinin enkaz altında kalan bireylerin tespiti için etkinliğini değerlendirmek adına önemli bir araç sunmaktadır. Simüle edilmiş senaryolarda, düşük merkez frekanslarına sahip çift frekanslı UWB radar ve adaptif karma iptali yöntemi, duvar ve enkazdan yansıyan solunum benzeri karmayı ayıklamak için adaptif algoritmalar kullanarak geleneksel yöntemlere kıyasla üstün performans sergilemiştir [23]. Duvar arkasındaki bir insanın solunum sinyalinin tespiti için optimal iletim sinyali tasarımı kapsamında Gaussian sinyalleri ve türevleri test edilmiş, dalgacık dönüşümleriyle arka plan gürültüsü etkilerine rağmen doğru sinyaller tespit edilmiştir [24]. Çok katmanlı simüle edilmiş enkaz modelleri, Fresnel katsayıları ve Green fonksiyonuyla doğrulanarak göğüs hareketlerinden hedef konumunun belirlenmesine olanak tanımış ve maksimum tespit menzili 3 metre olarak hesaplanmıştır [25]. Benzetim tabanlı bu yaklaşımlar, enkaz özellikleri ve sinyal zayıflamaları göz önünde bulundurularak yüksek doğrulukla yaşam tespiti sağlamaktadır [26].

1.1.3.2 Aktüatör Tabanlı Veri

Aktüatör tabanlı çalışmalar, canlıların hareketini taklit eden mekanik aksamlar kullanılarak gerçekleştirilmektedir. Karmaşık ortamlarda düşük Sinyal-Gürültü Oranı (SNR) altında yaşam belirtilerinin tespitini kolaylaştırmak için kontrol edilebilir koşullar sunmaktadır. Bir çalışmada, WT ile alınan darbelerin çarpıklık

ve basıklık değerleri analiz edilerek radar ile insan arasındaki mesafe belirlenmiş, yalnızca etkili alandaki darbeler kullanılarak solunum hızları ölçülmüştür ve geleneksel yöntemlere kıyasla daha başarılı sonuçlar elde edilmiştir [19]. Bir başka çalışmada, insansız hava aracı platformlarına monte edilen UWB radarlar, engel arkasındaki insanları tespit etmek için kullanılmıştır. Hava aracı kaynaklı titreşimlerin neden olduğu gürültüyü bastırmak ve solunum sinyalini güçlendirmek amacıyla analitik sinyal çıkarımı ve alt uzay bileşen ayrımı teknikleri uygulanmıştır. Laboratuvar ve saha deneyleri, yöntemin hem titreşim kaynaklı gürültüyü önemli ölçüde azalttığını hem de gerçekçi koşullarda etkili olduğunu göstermiştir [27].

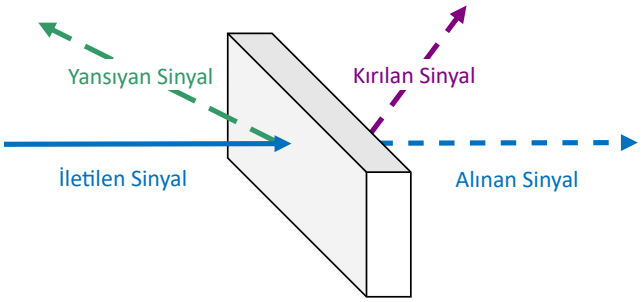
1.1.3.3 Canlıya Dayalı Veri

Yaşam tespiti çalışmalarında radar sistemleri, enkaz ortamında canlıya ait verilerin kaydedilmesi ve analizi için kullanılmaktadır. Gerçek insan solunum ve hareket verileri, enkaz koşullarına benzer özellikleri taşıyan ortamlarda toplanmaktadır [28]. İnsan hareketlerinin periyodik yapısı (örneğin, solunum ve uzuv hareketleri) temel alınarak, çapraz menzil radar verilerinde periyodik hareketlerin özelliklerini algılamak için FFT tabanlı bir yöntem uygulanmıştır [22]. Birden fazla sabit hedefin tespitindeki yanlış pozitif ve yanlış negatif sonuçların önüne geçmek için, enerji tabanlı yöntemlerden farklı olarak sinyallerin bağıntısı ve periyodikliğine dayanan çapraz korelasyon yöntemi önerilmiştir. Deneyler, bu yöntemin çoklu sabit hedeflerin tespit doğruluğunu önemli ölçüde iyileştirdiğini göstermiştir [29].

1.1.4 Ölçüm Düzenekleri

Enkaz altında canlı tespiti üzerine yapılan çalışmalarda kullanılan ölçüm düzenekleri, duvar arkası ve enkaz altı çalışmalar olarak ikiye ayrılabilir. Bu sistemlerde kullanılan yapı malzemelerinin elektriksel özellikleri, Şekil 1.3'te verilen sinyallerin yansıma ve iletim karakteristiklerini belirgin şekilde etkiler. Özellikle, malzemelerin dielektrik sabiti (ϵ) ve elektriksel iletkenliği (σ), yansıyan ve iletilen sinyalin gücünü önemli ölçüde değiştiren kritik parametrelerdir. Elektromanyetik dalgaların duvar gibi engellerden geçmesi sırasında malzemenin kalınlığı, homojenliği ve dielektrik özellikleri sinyal kaybını belirler. Beton, tuğla veya alçı gibi malzemeler kullanıldığında sinyalin zayıflama oranı farklılık gösterir fakat enkaz altı çalışmalara kıyasla daha azdır. Enkaz ortamında ise, malzemelerin karışık yapısı (beton, metal, ahşap vb. gibi) ve enkazın düzensizliği nedeniyle sinyalin kırılma ve yansıma gibi oranları değişir. Su içeriği yüksek malzemeler, elektromanyetik dalgaları daha fazla zayıflatarak sinyalin gücünü azaltır ve algılama sürecini zorlaştırır. Bir diğer yandan çevresel hareketin veya radyo frekansında

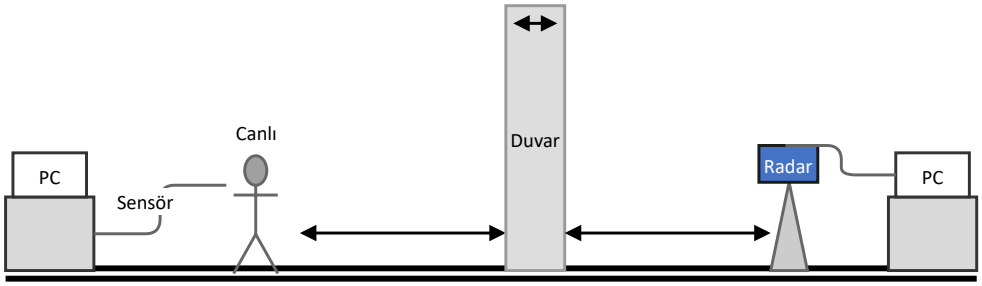
yapılan iletişimlerin iletilen sinyaller üzerindeki karmaşık etkisi de bulunmaktadır [30]. Bu durum, özellikle göçük altında kalan kişilerin tespitinde, doğru sonuçlara ulaşmayı daha karmaşık hale getirmektedir.



Şekil 1.3 Sinyalin yapı malzemesinin ardında yayılımı

1.1.4.1 Duvar Arkası Tespit

Duvar arkası ölçüm çalışmalar genel olarak Şekil 1.4'te verildiği gibi canlının betorname bir blok önüne ve ölçüm sisteminin ise bu bloğun ardına yerleştirilmesiyle gerçekleştirilir. Yapılan çalışmalarda enkaza benzer deney ortamları oluşturulsa da, pratikte betonarme duvar veya silindirik boru gibi yapıların arkasından alınan ölçümlerin de zaman zaman enkaz altı ölçümleri olarak adlandırıldığı görülmektedir [31].



Şekil 1.4 Duvar arkası ölçüm düzeni

1.1.4.2 Enkaz Altı Tespit

Duvar arkası çalışmalara kıyasla, daha karmaşık yapı bileşenlerinden oluşan ortamlar, özellikle çok katmanlı enkaz alanları, sinyal yayılımı ve hedef algılama açısından daha fazla zorluk barındırmaktadır. Enkaz altı tespit ortamları, karmaşık yapı bileşenlerinden oluştuğu için düşük genlikli yaşamsal bulguların elde edilmesi oldukça zordur. Yansıyan ve kırılan sinyaller, yapının karmaşıklığı nedeniyle

önemli ölçüde zayıflar ve bu durum algılama sürecini daha da güçleştirir. Enkaz altında bulunan bir insanın tespitine yönelik olarak, 270 MHz ve 400 MHz merkez frekanslarına sahip iki Darbe Radarlı Ultra Geniş Bant (IR-UWB) radarını birleştiren çift frekanslı bir radar sistemi geliştirilmiştir [32]. Bu sistem, genişletilmiş eşdeğer bant genişliği sayesinde, zayıf hayati sinyallere karşı hassasiyeti artırmaktadır. Daha sonra, çapraz korelasyon tekniği, iki kanalın işlenmiş verilerine uygulanarak tespit edilen SNR iyileştirilmiştir [33]. Ayrıca, FFT tabanlı algoritmalar kullanılarak, enkaz yapıları altında yaşam tespitinin mümkün olduğu gösterilmiştir[34].

1.1.5 Ön İşleme Yöntemleri

Radar sistemlerinden gürültülü olarak elde edilen sinyallerin ön işlemesi için yaygın olarak kullanılan yöntemler gürültü azaltma ve frekans tabanlı dönüşümlerdir. Bu yöntemler, sinyallerdeki istenmeyen bileşenleri ortadan kaldırarak enkaz altı canlı tespitini kolaylaştırmaktadır.

1.1.5.1 Gürültü Azaltma Yöntemleri

Radar sistemleri tarafından iletilen ve alınan sinyaller, çevresel faktörler ve sinyal interferansları nedeniyle gürültü bileşenleri içerebilmektedir. Duvarlar ve enkazdan yansıyan, insan solunum sinyallerine benzeyen karışıklıkları ayıklamak için adaptif bir algoritma kullanmaktadır [23]. Yöntem, özellikle duvar arkasındaki gizli bir insanın solunum sinyalini tespit etmeye odaklanmıştır. Bu bağlamda, iletim sinyali olarak Gaussian sinyali ve türevleri test edilmiş, alıcı çıkışındaki sonuçlar karşılaştırılarak performans analiz edilmiştir. Hedefle ilgili bilgileri etkin bir şekilde elde etmek ve arka plan gürültüsünü ortadan kaldırmak için dalgacık dönüşümleri yeterli bir yöntem olarak kullanılmıştır [24]. Düşük SNR koşullarında, durağan ve durağan olmayan gürültülerin bastırılması için yenilikçi bir yöntem geliştirilmiştir [35].

1.1.5.2 Frekans Tabanlı Dönüşümler

Literatürde, çeşitli yöntemler bu sistemlerin performansını artırmak ve hayati belirtileri daha güvenilir bir şekilde algılamak için önerilmiştir. Bazı çalışmalar, Kısa Zamanlı Fourier Dönüşümü (STFT) ile sinyallerin standart sapmasını kullanarak menzil belirlerken, Ampirik Mod Ayrışımı (EMD) tabanlı frekans birikim tekniğiyle solunum frekansını tespit etmektedir. Bu kombinasyon, algılama performansını artırmada etkili bir yöntem olarak değerlendirilmiştir [36, 37]. Doppler radarları, insan aktivitelerine ait mikro-Doppler etkilerini tanıyarak yaşam

belirtilerini algılayabilir. EMD gibi zaman-frekans analiz yöntemleri, bu etkileri analiz etmek için kullanılmıştır [38]. Dalgacık dönüşümüne dayalı yöntemler, enkazdaki karma ve gürültüyü azaltarak hayati belirtileri daha güvenilir bir şekilde çıkarmaktadır. Bu yöntemlerin, geleneksel güç spektral yoğunluğu yöntemlerine kıyasla doğruluğu artırdığı gösterilmiştir [39, 40]. Tekil Değer Ayrışımı (SVD), UWB radar sinyallerindeki gürültüyü etkili bir şekilde azaltmak için kullanılmıştır. Bunu takiben, enerji oranı elemesi ve WT gibi yöntemlerle solunum ve kalp atış sinyalleri izole edilmiştir [41]. Birleşik Zaman-Frekans Analizi (JTFA) tabanlı yöntemler, düşük SNR koşullarında solunum sinyallerini ayırt etmek için geliştirilmiştir. Radar ile hedef arasındaki mesafe, bu analiz yoluyla tahmin edilmiştir [42, 43]. Zamanlama titremesinden kaynaklanan etkilerin azaltılması için, sinyalin düşük dereceli temsili ve seyrek bileşen çıkarımı yöntemleri kullanılmıştır. Bu teknikler, karmaşık enkaz koşullarında sinyal doğruluğunu artırmada etkili olmuştur [44].

1.1.6 Tespit Yöntemleri

Enkaz altında canlı tespiti için kullanılan yöntemler; sinyal işleme, makine öğrenmesi ve derin öğrenme temelli yöntemler olarak üç temel gruba ayrılabilir.

1.1.6.1 Sinyal İşleme Temelli Yaklaşımlar

Deprem ve diğer afet durumlarında enkaz altında kalan kişilerin tespiti, sinyal işleme tabanlı yaklaşımlarla önemli bir ilerleme kaydetmiştir. UWB radar kullanılarak geliştirilen yöntemler, düşük SNR oranlarında bile etkili sonuçlar sunmaktadır. [45] ile verilen çalışma, düşük SNR koşullarında enkaz altındaki canlıların solunum hareketlerini tespit etmek için geliştirilen bir algoritma ile durağan olmayan karma sinyalleri ayırmış ve gürültü bastırma ile solunum sinyali çıkarımı sağlayarak başarılı bir performans göstermiştir. Başka bir çalışma ise Bağımsız Bileşen Analizi (ICA) algoritmasını kullanarak X-band radar tabanlı bir yöntem önermiştir. Bu sistem, etkin gürültü temizleme yeteneğiyle dikkat çekmiş ve hafif yapısıyla insansız hava araçlarına monte edilerek erişilmesi zor bölgelerde kullanım için uygun bir çözüm sunmuştur [46]. Spektral analiz yöntemleri de dikkate değer gelişmeler göstermiştir. Diğer bir çalışma, Gaussian gürültüsüne dayanıklı bispektrum analizine dayalı bir algoritma ile solunum sinyallerini tespit etmiş ve geleneksel güç spektral yoğunluğu tabanlı yöntemlere kıyasla üstün bir performans sergilemiştir [47]. Başka bir çalışma ise düşük SNR koşullarında UWB radarın performansını artırmak amacıyla yenilikçi bir solunum modeli ve eşik tabanlı tespit yöntemlerini içermiştir. Bu yöntem, deneysel doğrulamalarda SNR'da

önemli bir iyileşme sağlamıştır [48]. Sonraki çalışmalarda, düşük frekanslı radarlar ve Sabit Yanlış Alarm Oranı (CFAR) üzerinde durulmuştur. Bir başka araştırmada, IR-UWB radarın düşük merkez frekansı ile solunum hareketi tepkileri analiz edilmiş ve karma enerji tahmininde doğruluk artırılmıştır [49]. Ayrıca, zamanla değişen Fourier katsayılarını modelleyen bir yaklaşım geliştirilmiş ve minimum hata tahmini sağlayan yenilikçi bir çözüm sunulmuştur. Bu yöntem, düşük SNR koşullarında bile etkili sonuçlar elde etmiştir [50]. Diğer çalışmalarda, otomatik kazanç kontrolü ve filtreleme teknikleri birleştirilerek SNR'yi artıran yöntemler geliştirilmiş ve bu yöntemler mesafe tahmini yapmada üstün bir performans sergilemiştir [51]. Benzetim tabanlı bir araştırma ise Fresnel katsayılarını kullanarak enkaz altındaki hedeflerin yansıma özelliklerini analiz etmiş ve hedef tespitinde yüksek doğruluk sağlamıştır [25]. İnsan ve hayvan ayrımına odaklanan başka bir çalışma, dalgacık entropisi ve korelasyon katsayısı gibi özellikler kullanarak başarılı sınıflandırma yapmıştır [52]. Son dönemde, açık veri setleri ve performans değerlendirmelerine dayalı yeni yöntemler geliştirilmiştir. Geniş bir veri seti ile UWB radarın performansı değerlendirilmiş ve yüksek doğruluk sağlayan düşük karmaşıklığa sahip bir yöntem sunulmuştur [53]. Başka bir çalışma ise FFT kullanarak solunum hızını tahmin eden bir algoritma geliştirmiştir. Bu algoritma, solunum hızını ölçerek arama kurtarma operasyonlarında afetzedelerin sağlık durumları hakkında değerli bilgiler sağlamıştır [54].

1.1.6.2 Makine Öğrenmesi Temelli Yaklaşımlar

Radardan alınan karmaşık verilerin analiz edilmesi ve daha doğru sınıflandırma sonuçları elde edilmesi amacıyla literatürde çeşitli makine öğrenme algoritmaları kullanılmaktadır. Yapılan bir çalışma, enkaz altında solunum hareketlerinden kaynaklanan göğüs hareketlerini tespit etmek için UWB radar kullanmıştır. Ancak, radar görüş alanında birden fazla kişinin bulunması ve bu kişilerin radara eşit mesafede yer alması durumunda mevcut kişi sayısının doğru bir şekilde belirlenememesi, çözülmesi gereken önemli bir sorun olarak öne çıkmıştır. Bu problem için laboratuvar ortamında gerçekleştirilen bir deneyde, üç kişinin radara eşit mesafede yerleştirildiği bir senaryo oluşturulmuş ve varyans ile tekil değerler özellik olarak çıkarılmıştır. Çalışmada denetimli makine öğrenme algoritmaları uygulanmış ve en yüksek doğruluk oranı $\%97.5$ ile karar ağaçları temelli bir sınıflandırıcı ile elde edilmiştir. Bu sonuç, özellikle sınıflandırma doğruluğu açısından önemli bir başarıyı temsil etmektedir [55]. Başka bir çalışma ise radar sinyallerinin bitki örtüsünden ve hareketli yapraklardan kaynaklanan sinyallerle karışmasının yol açtığı zorlukları ele almıştır. Araştırmada, bitki örtüsü arkasında gizlenmiş insanları tespit etmek için transfer öğrenme tabanlı makine öğrenme

yöntemleri kullanılarak radar sensörleriyle bir araç geliştirilmiştir. Üç aylık bir süre boyunca farklı bitki örtüsü ve rüzgar koşullarında veri toplanmış ve bu veri seti, insanları tespit etmek için kaydedilmiştir. Yöntem, bitki örtüsü ve rüzgar gibi çevresel etkilerin sinyal üzerinde oluşturduğu karışıklığa rağmen yüksek tespit doğruluğu sergilemiş ve ilk müdahale ekiplerinin yeteneklerini artırma potansiyelini ortaya koymuştur [56].

1.1.6.3 Derin Öğrenme Temelli Yaklaşımlar

Özellikle doğal afetler veya kazalar sonrası enkazda kalan kişilerin hızlı ve etkili bir şekilde bulunması hayati önem taşımaktadır. Derin Öğrenme (DL) temelli yaklaşımlar, bu tür durumlarda sinyalleri analiz ederek enkaz altındaki canlıları tespit etmede büyük bir potansiyel sunar. Enkaz altı hedef tespiti algoritmalarına yönelik çalışmalara, Tablo 1.1'de sunulan ve benzer çalışma problemleri için kullanılan derin öğrenme modellerinin detaylı bir şekilde incelenmesiyle başlanmıştır. Literatürde gerçek enkaz altında derin öğrenme ile nefes tespiti yapan bir çalışma bulunmadığından tabloda verilen ilgili çalışmalar incelenmiştir. Nefes alma örüntüsü, yaşamsal işaretlerin tespiti, insan duruşu ve hareketinin tespitini hedefleyen ve radar kullanılarak elde edilen veri setleri derin öğrenme modelleri ile yüksek doğruluk oranlarında sonuç vermektedir.

Derin öğrenme tabanlı yaklaşımlar, özellikle görüntü sınıflandırma yöntemleri kullanılarak enkaz altında kalan kişilerin tespitine yönelik önemli çalışmalara olanak sağlamıştır. Örneğin, enkaz altında kalan kişilerin tespitine yönelik bir çalışmada, afetzedeleri belirlemek için ResNet-50 modeli kullanılarak transfer öğrenme temelli bir yöntem geliştirilmiştir [57]. Başka bir çalışmada ise, görüntü sınıflandırma tabanlı tespit, Bölge Tabanlı Konvolüsyonel Sinir Ağları (RCNN) ve YOLOv10 kullanılarak gerçekleştirilmiştir [58]. Öte yandan, yılan robotlar ile DL tabanlı nesne tanıma algoritmalarını birleştiren bir araştırmada, 15 ms'lik sonuç çıkarım süresi ile performans sergilenmiştir [59]. Görüntü tabanlı çalışmaların yanı sıra, IR-UWB radar ile ölçülen veri setlerinden faydalanılan bir çalışmada, Konvolüsyonel Sinir Ağları (CNN) tabanlı bir insan hareket tanıma yöntemi önerilmiş ve test verilerinde $\%99.7$'nin üzerinde doğruluk elde edilmiştir [60]. Radar verilerine SNR'yi artırmak amacıyla gürültü azaltma işlemi uygulanmış ve elde edilen ölçüm matrisi, özellik çıkarımı için altı katmanlı bir CNN modeline aktarılmıştır. CNN'in özellik çıkarma kapasitesi sayesinde ilgili hedef noktaları veri matrisinden başarılı bir şekilde elde edilmiş ve ardından bir kümeleme algoritması ile bu noktalar basitleştirilerek enkaz altındaki birden fazla hedefin hassas tespiti gerçekleştirilmiştir [61].

Tablo 1.1 Son yıllarda hedef tespitine yönelik yapılan çalışmalara ait bilgiler (2019-2024)

Referans	Yıl	Problem	Radar Teknolojisi	Veri Setinin Elde Edilme Yöntemi	Modeller	Verilen Skor
[62]	2019	İnsan solunum örüntüsü tanıma	UWB Radar Sensör	UWB radar kullanılarak elde edilen solunum sinyal verileri kullanılmaktadır.	Tek Boyutlu CNN	Tanıma oranı: %93.9
[63]	2019	İnsan duruşu tanıma	Duvar Arkası Radar	Deneysel kurulumla toplanmıştır.	CNN	Doğruluk oranı: %98.56
[64]	2020	Solunum ve düşme tespiti	Tavana monte Radar (sub-6 GHz)	Sensör sistemi tarafından elde edilmiştir.	RadarNet	Doğruluk oranı: %95
[60]	2021	İnsan hareket durumu	Duvar Arkası UWB Radar	Deneysel kurulumla toplanmıştır.	CNN	Doğruluk oranı: %99.7
[65]	2021	Altı farklı solunum örüntüsü tanımlama	USRP	Evrensel Yazılım Tabanlı Radyo (USRP) ile toplanmıştır.	Derin Çok Katmanlı Algılayıcı	Doğruluk oranı: %87
[66]	2022	Temassız solunum hızı izleme	mmWave Radar	mmWave radar ve kamera kurulumuyla toplanmıştır.	CNN	Doğruluk oranı: %99
[67]	2022	Nabız ölçüm sistemi	Tıbbi radar	Tıbbi radar ve sensörler ile elde edilmiştir.	LSTM	Doğruluk oranı: %96.67
[68]	2022	Çoklu sabit insan hedefi tespiti	Duvar Arkası UWB Radar	Toplanan ham radar verileri üzerinde SNR iyileştirme yöntemi uygulanmaktadır.	CNN	CFAR: %3
[69]	2023	Gerçek zamanlı vital işaretlerin izlenmesi	IR-UWB Radar	Veriler aynı anda bir IR-UWB radar kullanılarak ölçülmüştür.	Vision Transformer	MAE: %2.28
[59]	2024	Enkaz altı canlı tespiti	Termal görüntü, mikrofon	Özel olarak toplanan 200 görüntü içeren veri seti kullanılmaktadır.	CNN (YOLOv8, YOLOv10)	Doğruluk oranı: %98.5

1.2 Tezin Amacı

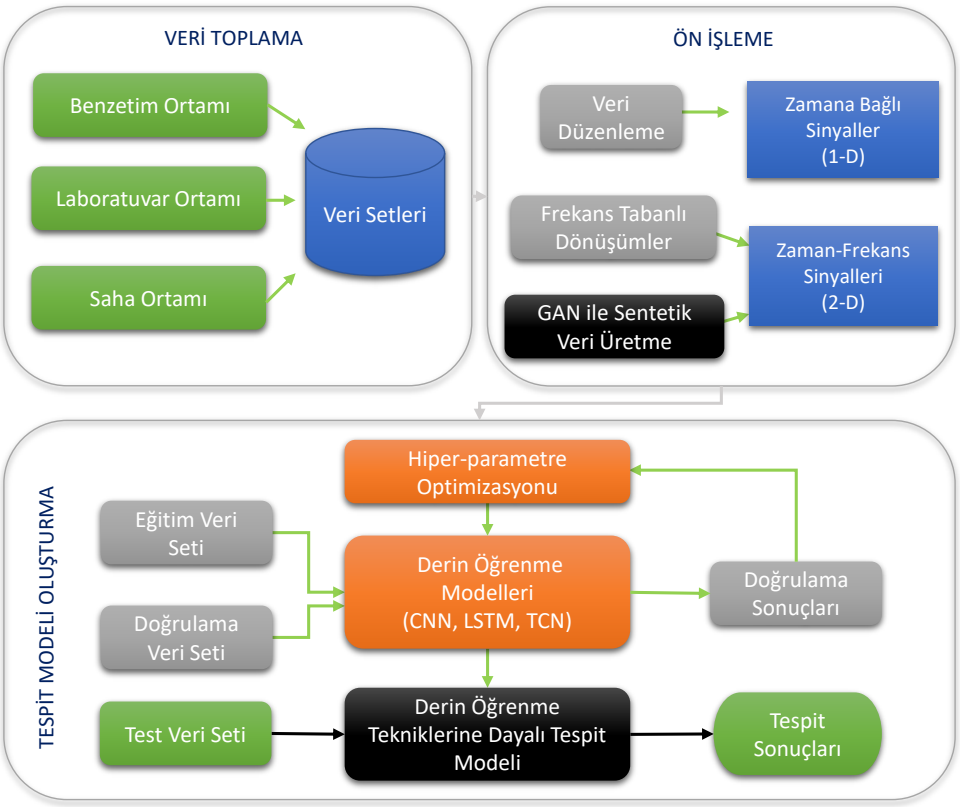
Bu tez, enkaz altında hayatta kalmış canlıları tespit edebilmek için elektromanyetik tabanlı ölçüm yöntemlerini derin öğrenme algoritmalarıyla birleştirmeyi amaçlamaktadır. Bu doğrultuda, benzetim ortamındaki elektromanyetik çalışmalara ek olarak laboratuvar ve saha ölçümleri de gerçekleştirilerek, yüksek doğrulukta bir hedef tespit sistemi geliştirilmesi hedeflenmiştir. Ayrıca, canlı tespit sistemine ek olarak, çoklu antenli ölçümlerden elde edilen verilerin yine derin öğrenme tabanlı yöntemlerle işlenmesi sonucunda, enkaz altındaki hedefin konumunun belirlenmesini sağlayacak bir sistem kurgulanması da amaçlanmaktadır.

1.3 Hipotez

Enkaz altı canlı tespitinde, elektromanyetik tabanlı ölçümleri derin öğrenme algoritmalarıyla birlikte işleyen akıllı bir tespit cihazına ihtiyaç olduğu öngörülmektedir. Özellikle karmaşık sinyal koşullarında, farklı enkaz türleri ve ölçüm senaryolarında güvenilir bir tespit sistemi geliştirilebileceği düşünülmektedir. Bu doğrultuda, elektromanyetik temelli ölçüm verilerini derin öğrenme yöntemleriyle bütünleştiren yenilikçi bir tespit cihazının, farklı enkaz tipleri ve karmaşık sinyal koşullarında canlı varlığını ve konumunu yüksek doğrulukla belirleyebileceği ve güvenilir sonuçlar üretebileceği hipotez edilmektedir.

2
YÖNTEM

Bu bölümde, tez kapsamında hedef tespiti üzerine kullanılan yöntemler bütüncül bir bakış açısıyla ele alınmıştır. Öncelikle veriler üzerinde uygulanan ön işleme yöntemleri ayrıntılı biçimde açıklanmıştır. Ardından, frekans tabanlı dönüşümler ve Çekişmeli Üretici Ağ (GAN) ile sentetik veri üretimine yer verilmiştir. Kullanılan derin öğrenme modellerine ilişkin ayrıntılı anlatım bu bölümde verilmektedir. Şekil 2.1'de tez çalışmasında izlenen adımların temel blok diyagramı gösterilmektedir. Bu gösterimde, ham verinin toplanmasından başlayarak, ön işleme ve model eğitimi aşamalarına, en sonunda da performans değerlendirmesine kadar uzanan süreç gösterilmektedir.



Şekil 2.1 Tez kapsamında izlenen adımların blok diyagramı

Bu çalışmada öncelikle veri toplama sürecinde elde edilen ham veriler üzerinde çeşitli ön işleme teknikleri uygulanarak gürültü giderme, zaman-frekans analizi ve belirli frekans bantlarının ayrıştırılması gibi işlemler gerçekleştirilmiştir. Bu aşamada, STFT ile sinyalin zaman-frekans bileşenleri elde edilmiş, EMD yardımıyla da sinyal farklı modlara bölünerek her bir modun özellikleri bağımsız olarak incelenmiştir. Ayrıca, Değişken Mod Ayrışımı (VMD) tekniği ile ise sinyalin daha dar bant genişliklerine sahip alt bileşenlerine ayrıştırılmıştır.

Ön işleme aşamasının ardından, hedef tespit ve sınıflandırma amacıyla farklı derin öğrenme yöntemleri değerlendirilmiştir. GAN modelinde sentetik veri üretimi yapılarak veriyi çoğaltmak hedeflenmiştir. Uzun Kısa Süreli Bellek (LSTM) ise özellikle zaman serisi verilerindeki uzun dönemli bağımlılıkları yakalamada kullanılmıştır. CNN, uzamsal veya zamansal örüntüleri tespit ederken yüksek başarı sağladığı için tercih edilmiş, Zamansal Konvolüsyonel Ağlar (TCN) ise özellikle zaman serisi verilerinde uzun vadeli bağımlılıkların verimli bir şekilde modellenmesi amacıyla bu çalışmaya dahil edilmiştir.

2.1 Ön İşleme Yöntemleri

Tez kapsamında kullanılan ön işleme yöntemleri, gürültü giderme, FFT, STFT, EMD ve VMD olarak sıralanmaktadır.

2.1.1 Gürültü Giderme

Sinyal işleme ve örüntü tanıma üzerine yapılan çalışmalarda, gürültü giderme (*denoising*) önemli bir adımdır. Gürültü; algılama cihazlarının hatalarından, iletişim kanallarındaki ve radar sinyallerindeki bozulmalardan veya verinin elde edildiği ortamın kalitesinden kaynaklanabilir. Gürültüyü etkin bir şekilde azaltmak için WT tabanlı yöntemler sıklıkla kullanılır [70].

Dalgacık dönüşümü ile gürültü giderme (*wavelet denoising*), sinyali farklı frekanslarda ayrıştırarak düşük enerjili gürültü bileşenlerini bastırırken, sinyalin önemli bileşenlerini korumaya çalışmaktadır. Bu yöntem, dalgacık eşikleme (*wavelet thresholding)* prensibine dayanmaktadır. Dalgacık dönüşümü sonrası gürültünün bastırılması için belirli bir eşik değeri kullanılarak, belirli katsayılar sıfırlanır veya küçültülür. James-Stein küçültme fonksiyonu veya evrensel eşikleme (*universal thresholding*) yöntemi daha küçük enerjili bloklarda daha fazla küçültme yaparken, yüksek enerjili sinyal bileşenlerini daha az bastırarak korunmasını sağlar [71, 72].

Bir ayrık sinyal $x(n)$, gürültü içeren bir işaret olarak Denklem 2.1'de verildiği gibi modellenebilir.

$$y(n) = x(n) + \eta(n), \quad n = 1, 2, \ldots, N \tag{2.1}$$

Burada; $y(n)$ gözlemlenen gürültülü sinyal, $x(n)$ gerçek (gürültüsüz) sinyal, $\eta(n)$ gürültü, N ise sinyalin örnek sayısıdır.

Dalgacık dönüşümü uygulandığında sinyal, yaklaşım ve detay katsayıları ile temsil edilmektedir. Denklem 2.2'de W_y gürültülü sinyalin dalgacık dönüşümündeki katsayıları, W_x gerçek sinyalin dalgacık dönüşümündeki katsayıları, W_η ise gürültünün dalgacık katsayılarındaki temsilidir.

$$W_y = W_x + W_\eta \tag{2.2}$$

Dalgacık katsayıları üzerinde eşikleme işlemi uygulanarak gürültü bastırılır. Genel olarak kullanılan eşikleme fonksiyonu Denklem 2.3'te gösterildiği gibidir.

$$\hat{W}_x = T(W_y, \lambda) \tag{2.3}$$

Burada λ, belirli bir eşik değeri olup aşağıdaki yöntemlerle belirlenebilir: evrensel eşikleme yöntemi Denklem 2.4 ve blok James-Stein (*blockJS*) yöntemi Denklem 2.5 ile verilmektedir. σ gürültü standart sapmasını, N sinyalin uzunluğunu temsil eder.

$$\lambda = \sigma\sqrt{2\ln N} \tag{2.4}$$

$$\hat{W}_x = W_y \cdot \max\left(1 - \frac{\lambda^2}{\|W_y\|^2}, 0\right) \tag{2.5}$$

Gürültüsü azaltılmış dalgacık katsayıları ile sinyalin tekrar zaman alanına dönüştürülmesi için Denklem 2.6'da verilen ters dalgacık dönüşümü uygulanır. Burada $\hat{x}(n)$, gürültüsü giderilmiş tahmini sinyali temsil etmektedir.

$$\hat{x}(n) = W^{-1}(\hat{W}_x) \tag{2.6}$$

2.1.2 Hızlı Fourier Dönüşümü

Hızlı Fourier Dönüşümü, Fourier dönüşümünün hızlı ve verimli bir şekilde hesaplanmasını sağlamaktadır. Ayrık Fourier Dönüşümü (DFT), bir sinyalin frekans bileşenlerini analiz etmek için kullanılır. FFT, özellikle büyük veri setleri için DFT'nin karmaşıklığını azaltarak hesaplamaları büyük ölçüde hızlandırmaktadır. Bir $x(n)$ ayrık zaman sinyali için Fourier dönüşümü Denklem 2.7'de verildiği gibi tanımlanmaktadır.

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j\frac{2\pi kn}{N}} \tag{2.7}$$

Burada; $x(n)$ ayrık zaman sinyali, $X(k)$ frekans bileşenlerini temsil eden Fourier katsayıları, N FFT uzunluğu (sinyalin örnek sayısı), k frekans indeksidir. FFT algoritması, DFT'nin tekrarlayan hesaplamalarını azaltmak için sinyali alt parçalara bölerek özyinelemeli bir işlem yapmaktadır.

2.1.3 Kısa Zamanlı Fourier Dönüşümü

Kısa Zamanlı Fourier Dönüşümü, zamanla değişen sinyallerin frekans içeriğini analiz etmek için kullanılan bir tekniktir. Geleneksel Fourier dönüşümü, bir sinyalin tüm zaman boyunca frekans bileşenlerini belirlemek için uygundur ancak sinyalin zamanla değişen yapısı hakkında bilgi vermez. Bu nedenle, zaman-frekans analizine ihtiyaç duyulan durumlarda STFT kullanılmaktadır.

STFT, bir sinyalin $x(n)$ bir pencereli fonksiyon ile çarpılarak kısa zaman aralıklarında analiz edilmesi temeline dayanır. Matematiksel olarak, STFT Denklem 2.8'de verildiği gibi ifade edilir.

$$\mathrm{X}(m,k) = \sum_{n=-\infty}^{\infty} x[n] w[n-m] e^{-\frac{2\pi kn}{N}} \tag{2.8}$$

$x(n)$ zaman domeninde analiz edilen ayrık sinyal, $w(n)$ pencere fonksiyonu, N FFT uzunluğunu ifade eder.

STFT'nin temel fikri, sinyali bir pencere fonksiyonu yardımıyla küçük zaman aralıklarına bölmek ve her bir aralıkta Fourier dönüşümü uygulamaktır. Pencere fonksiyonu $w(n)$ genellikle sınırlı bir genişliğe sahiptir, merkezi m olan bir aralıkta kaydırma yapar. Genellikle Hamming, Hanning veya Gauss gibi yaygın pencere türlerinden biri kullanılır.

STFT'nin çıktısı bir zaman-frekans düzleminde temsil edilir ve bu düzlemde sinyalin hem zaman hem de frekans boyutundaki değişimleri analiz edilebilir [73].

2.1.4 Ampirik Mod Ayrışımı

Ampirik Mod Ayrışımı, zaman domenindeki karmaşık sinyalleri daha basit bileşenlere ayırmak için kullanılan bir yöntemdir. Bu yöntem, herhangi bir sinyali İçsel Mod Fonksiyonları (IMF) olarak adlandırılan bir dizi bileşene ayırır. EMD, özellikle doğrusal olmayan ve durağan olmayan sinyallerin analizi için tasarlanmıştır.

EMD, bir sinyalin farklı ölçeklerdeki bileşenlerini ayrıştırmak için, sinyalin maksimum ve minimum noktalarından üst ve alt zarflar oluşturulur. Bu zarfların ortalaması alınarak ortalama zarf hesaplanır. Sinyal bu ortalamadan çıkarılarak IMF bileşenleri elde edilir ve uygunluk kriterleri sağlanana kadar işlem tekrarlanır [74].

Algorithm 1 Ampirik Mod Ayrışımı

Girdi: $x(t)$ – İşlenmesi gereken sinyal
Çıktı: IMF_k – Ayrıştırılmış mod bileşenleri
$r \leftarrow x(t)$ ▷ Başlangıçta kalıntı sinyal, giriş sinyali olarak alınır
$k \leftarrow 1$
while r durağan değil **do**
  $h \leftarrow r$
  repeat
    Üst zarfı $U(t)$ ve alt zarfı $L(t)$ hesapla
    Ortalama zarfı hesapla: $m(t) = \frac{U(t)+L(t)}{2}$
    Güncellenmiş bileşeni hesapla: $h \leftarrow h - m(t)$
  until h bir IMF koşulunu sağlayana kadar
  $IMF_k \leftarrow h$
  $r \leftarrow r - IMF_k$
  $k \leftarrow k + 1$
end while
Dönüş: $\{IMF_1, IMF_2, ..., IMF_k\}$

2.1.5 Değişken Mod Ayrışımı

Değişken Mod Ayrışımı, zaman-frekans analizinde kullanılan bir yöntemdir. EMD, sinyali veri odaklı iteratif bir süreçle iç içe modlara ayırırken, VMD ise sinyali önceden belirlenen mod sayısına göre ayrıştırır.

VMD, sinyaldeki farklı modları ayrıştırmak için modları tanımlama, optimizasyon problemi ve iteratif güncelleme adımlarını takip eder. Her bir mod, merkezi bir frekans etrafında dar bir bant genişliğine sahiptir. VMD, modların merkezi

frekanslarını ve bileşenlerini optimize etmek için bir değişken yaklaşım kullanır. Amaç, her bir modun Hilbert dönüşümünü kullanarak analitik sinyalleri elde etmektir. Modların ve frekansların optimize edilmesi, iteratif bir algoritma ile gerçekleştirilir. Bu süreç sonunda, sinyal birden çok moda ayrılmış olur ve her bir mod, farklı bir frekans aralığını temsil eder [75].

Algorithm 2 Değişken Mod Ayrışımı

Girdi: $x(t)$ – İşlenmesi gereken sinyal, K – Mod sayısı, α – Düzenleme parametresi, τ – Yakınsama toleransı
Çıktı: $u_k(t)$ – Ayrıştırılmış mod bileşenleri, ω_k – Mod merkez frekansları
Başlangıç değerlerini ata: $u_k^0, \omega_k^0, \lambda^0$
$n \leftarrow 0$
repeat
  for $k = 1$ to K **do**
    Mod bileşenlerini Fourier alanında güncelle:

$$U_k^{n+1}(\omega) = \frac{X(\omega) - \sum_{i \neq k} U_i^n(\omega) + \lambda^n(\omega)/2}{1 + \alpha(\omega - \omega_k^n)^2}$$

    Mod merkez frekanslarını güncelle:

$$\omega_k^{n+1} = \frac{\int \omega |U_k^{n+1}(\omega)|^2 d\omega}{\int |U_k^{n+1}(\omega)|^2 d\omega}$$

  end for
  Lagrange çarpanını güncelle:

$$\lambda^{n+1}(\omega) = \lambda^n(\omega) + \alpha \left(X(\omega) - \sum_k U_k^{n+1}(\omega) \right)$$

  $n \leftarrow n + 1$
until

$$\sum_k \|U_k^{n+1} - U_k^n\|_2^2 < \tau$$

Dönüş: $\{u_1(t), u_2(t), ..., u_K(t)\}$

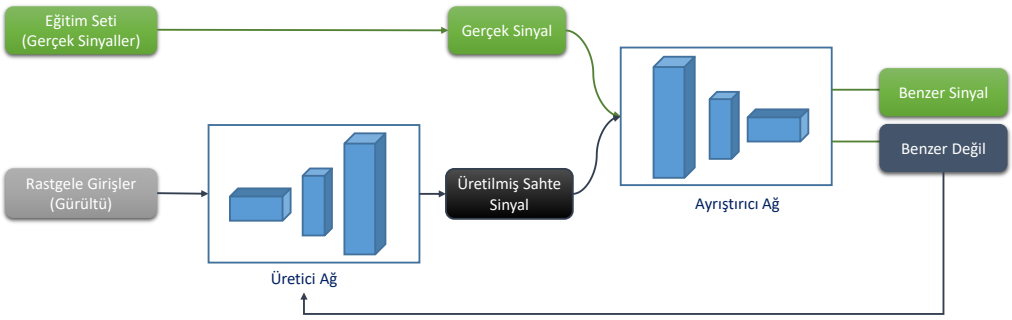
2.2 Derin Öğrenme Yöntemleri

Tez kapsamında hedef tespit algoritmalarında kullanılan derin öğrenme modelleri; GAN, CNN, LSTM ve TCN olarak sıralanmaktadır.

2.2.1 Üretici Çekişmeli Ağ

Üretici Çekişmeli Ağlar, örnekler kümesinden elde edilen veri dağılımını dolaylı biçimde öğrenerek, bu dağılımdan benzer nitelikte yeni örnekler üretmeyi hedefler. Aslında üretici ağ, hedef veri dağılımındaki gerçek örnekleri taklit eden sentetik örnekler oluşturmayı öğrenir. Bu süreçte rastgele gürültüyü girdi olarak kullanarak, çıktıyı gerçek verilere mümkün olduğunca yaklaştırmaya çalışır [76]. GAN mimarisi, Şekil 2.2'de gösterildiği üzere, veri üretimi ve doğrulamasını birlikte ele alan bir üretici ağ ve bir ayrıştırıcı ağdan oluşur. Üretici ağ, özellik girdi katmanıyla başlar, ardından gelen tamamen bağlı katmanlarda etkinleştirme fonksiyonları uygulanır ve çıktı katmanında ise -1 ile 1 arasında değerler üreten bir *tanh* katmanı bulunur. Ayrıştıcı ağ tarafında ise leaky ReLU aktivasyonları içeren tamamen bağlı katmanlar dizisiyle derinleştirilir ve ikili sınıflama için bir *sigmoid* katmanıyla sonlanır. Bu düzenek, üreticinin sahte örnekleri üretmesine, ayrıştıcı ağın bu örnekleri gerçek verilerle kıyaslayarak hatayı geriye yaymasına ve böylece modelin her ağ bileşeninin de iteratif olarak uygunlaştırılmasına imkan tanır.

Goodfellow ve arkadaşları tarafından sunulan ve üreticinin, ayrıştıcı ağın yanlış karar verme olasılığını artırmayı hedeflediği formülasyonun, deneysel olarak daha iyi sonuçlar verdiği bilinmektedir [77]. Ancak GAN eğitiminin istikrarlı bir şekilde sürdürülebilmesi halen açık bir araştırma konusudur. Yine de, sunulan derin evrişimli GAN gibi dikkatle tasarlanmış ağ yapıları ve doğru hiperparametre seçimiyle, örüntü üretimi gibi görevlerde son derece başarılı sonuçlar elde edilebilmektedir [77].



Şekil 2.2 Üretici çekişmeli ağ yapısı

2.2.2 Uzun Kısa Süreli Bellek

Yinelemeli Sinir Ağları (RNN) kullanıldığında zamanla sönümlenen gradyan problemi ortaya çıkabilmektedir, bu sorununun önüne geçmek için LSTM ağı geliştirilmiştir [78]. LSTM yapısı, hafıza blokları olarak adlandırılan birbiriyle bağlı yapılardan oluşmaktadır. Her blok, kendine bağlı hafıza hücreleri ve hücreler için yazma, okuma ve sıfırlama işlemlerinin sürekli versiyonlarını temsil eden üç etmenli birimleri (giriş, çıkış ve unutma kapıları) içermektedir.

LSTM ağları, standart bir RNN'yi andırır, ancak geleneksel toplama birimleri gizli katmanda hafıza blokları ile değiştirilmiştir, bu durum Şekil 2.3.a'da gösterilmektedir. Aslında, Şekil 2.3.b'de gösterildiği gibi bir LSTM hafıza bloğu, tek bir hücreden oluşur. Ayrıca, standart RNN'lere uygulanabilen aynı çıkış katmanları LSTM ağları için de kullanılabilir [79].

LSTM ağları, içsel bir yineleme mekanizmasına sahiptir. Bilgi taşıma süresi unutma kapısı $f^{(t)}$ tarafından kontrol edilir. Matematiksel olarak, unutma kapısı Denklem 2.9'da verildiği gibi tanımlanmaktadır.

$$f_i^{(t)} = \sigma\left(b_{f_i} + \sum_j U_{f_i,j} x_j^{(t)} + \sum_j W_{f_i,j} h_j^{(t-1)}\right) \tag{2.9}$$

Burada; $x^{(t)}$ o anki giriş vektörünü, $h^{(t-1)}$ bir önceki zaman adımındaki gizli katman vektörünü, b_f, U_f, W_f ise sırasıyla unutma kapıları için bias, giriş ağırlıkları ve tekrar eden ağırlıkları temsil eder. LSTM'nin hücre durumu Denklem 2.10'da verildiği gibi güncellenir. Her bir LSTM hücresi, dahili bir durum değişkeni olan hücre durumu $s_i^{(t)}$ ile güncellenir.

$$s_i^{(t)} = f_i^{(t)} s_i^{(t-1)} + g_i^{(t)} \sigma\left(b_i + \sum_j U_{i,j} x_j^{(t)} + \sum_j W_{i,j} h_j^{(t-1)}\right) \tag{2.10}$$

Burada, giriş kapısı $g^{(t)}$, yeni bilginin hücre durumuna ne kadar katkı yapacağını belirler ve Denklem 2.11'de verildiği gibi bir sigmoid fonksiyonu ile hesaplanmaktadır.

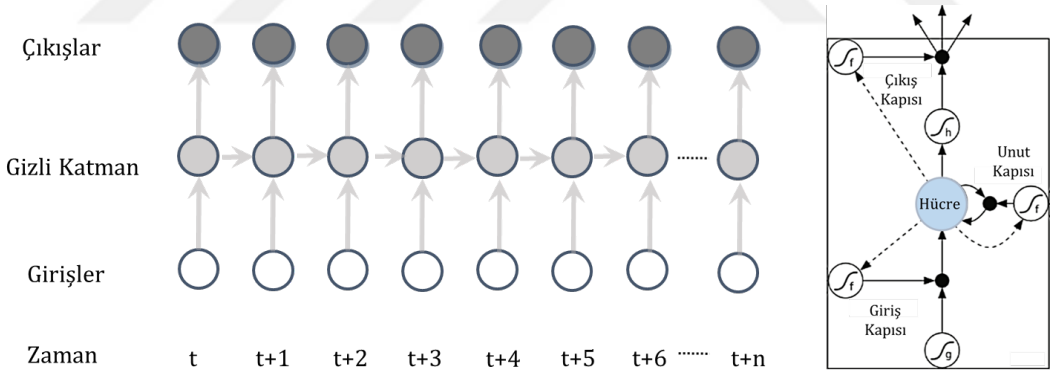
$$g_i^{(t)} = \sigma\left(b_{g_i} + \sum_j U_{g_i,j} x_j^{(t)} + \sum_j W_{g_i,j} h_j^{(t-1)}\right) \tag{2.11}$$

LSTM çıkışı ise, hücre durumu ile çıkış kapısı Denklem 2.12 ve Denklem 2.13 ile verildiği gibi $q^{(t)}$ üzerinden hesaplanır.

$$h_i^{(t)} = \tanh(s_i^{(t)}) q_i^{(t)} \tag{2.12}$$

$$q_i^{(t)} = \sigma \left(b_{o_i} + \sum_j U_{o_i,j} x_j^{(t)} + \sum_j W_{o_i,j} h_j^{(t-1)} \right) \tag{2.13}$$

Bu mekanizmalar sayesinde LSTM ağları, uzun vadeli bağımlılıkları öğrenme ve sönümlenen gradyan sorununu önleme konusunda geleneksel RNN'lere göre çok daha etkilidir [80]. LSTM ve diğer derin öğrenme modellerinin eğitim sürecinde birkaç önemli hiperparametre kullanılır. Epoch, tüm veri setinin ağda kaç kez tarandığını ifade eder. Mini-batch boyutu, eğitim sırasında her iterasyonda modele verilen veri örneklerinin sayısını ifade eder. Gradyan sınırı, geri yayılım sırasında gradyanların aşırı büyümesini engelleyerek gradyan problemini önleyen bir değerdir. Öğrenme oranı, kayıp fonksiyonunun minimumuna doğru ilerlerken her iterasyondaki adım boyutunu belirler. Drop faktörü; öğrenme oranının azaltıldığı faktördür, öğrenme sürecini optimize etmek için kullanılır.



Şekil 2.3 LSTM (a) Ağ yapısı (b) Bir hücreli hafıza bloğu

2.2.3 Konvolüsyonel Sinir Ağları

Konvolüsyonel Sinir Ağları, özellikle ızgara (*grid*) benzeri veri yapıları üzerinde çalışan, görüntü veya zaman serisi gibi verilerde başarılı olan bir derin öğrenme modelidir. Bu ağlar, konvolüsyon işlemini kullanarak verileri işler ve bu sayede özellikle örüntü tanıma gibi alanlarda büyük başarılar elde etmiştir. Bir konvolüsyon katmanında giriş (x) ve ağırlık (w) kullanılarak çıkış (y) Denklem 2.14'te verildiği gibi hesaplanır.

$$y_{i,j} = \sum_{m,n} x_{i+m,j+n} \cdot w_{m,n} + b \tag{2.14}$$

Burada; (x) giriş örüntüsünü temsil etmektedir, (w) konvolüsyon çekirdeğidir, (b) bias terimidir. Standart bir konvolüsyon katmanında her çıkış kanalında tek bir bias paylaşılır. Eğer giriş verisinin kenarlarına sıfır dolgu (*zero padding*) uygulanıyorsa, her konum için ayrı bias değerlerini öğrenmek gerekmektedir. Klasik CNN mimarilerinde, havuzlama (*pooling*) katmanları yüksek kaydırma (*stride*) değerleri kullanarak çıkış boyutunu küçültür. Ancak piksel bazlı sınıflandırmada çıkışın giriş boyutuna yakın olması istenir. Çözüm olarak;

- Daha geniş kaydırma değerleri kullanan havuzlamadan kaçınılabilir,
- Daha dar kaydırma değerleri (*stride = 1*) tercih edilebilir,
- Daha düşük çözünürlüklü bir çıktı haritası üretilip sonradan ölçeklenebilir.

Bir görüntüde her pikselin doğru şekilde sınıflandırılması için, tahminler iteratif olarak iyileştirilebilir. İlk tahmin ($\hat{\mathbf{Y}}^{(1)}$) giriş görüntüsünden üretilir ve ardından Denklem 2.15 ve Denklem 2.16 ile verilen ifadeler kullanılarak iteratif olarak iyileştirilir.

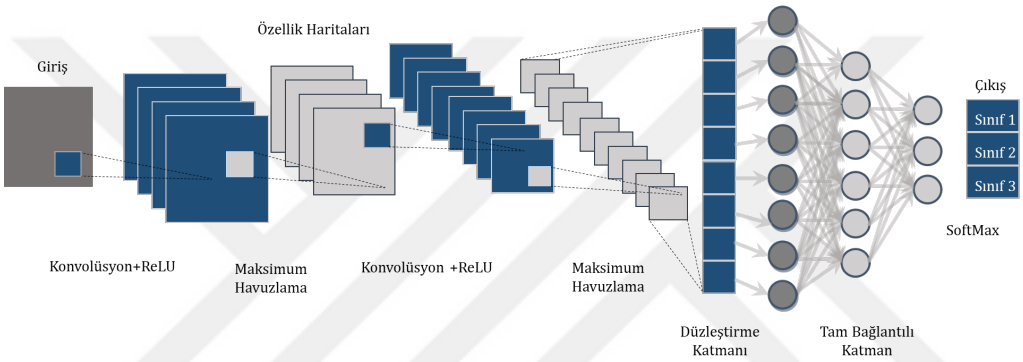
$$\mathbf{H}^{(t)} = \sigma\Big(\mathbf{U} * \mathbf{X} + \mathbf{W} * \hat{\mathbf{Y}}^{(t-1)}\Big) \tag{2.15}$$

$$\hat{\mathbf{Y}}^{(t)} = \text{softmax}\big(\mathbf{V} \cdot \text{flatten}(\mathbf{H}^{(t)})\big) \tag{2.16}$$

- $\mathbf{H}^{(t)}$ gizli katman çıktısıdır,
- $\mathbf{U}, \mathbf{W}$ konvolüsyonel filtrelerdir (tüm iterasyonlar boyunca paylaşılır),

- $\mathbf{V}$) vağırlık matrisidir,
- σ aktivasyon fonksiyonudur (örn. ReLU),
- $\hat{\mathbf{Y}}^{(t)}$ çıkış tahminidir.

Piksel bazında sınıflandırma tamamlandıktan sonra, tahminleri iyileştirmek için graf tabanlı modeller ve doğrudan öğrenme modelleri kullanılabilir. Bu yöntemler sayesinde, çıkış haritasındaki keskin sınırları düzeltmek ve daha anlamlı segmentasyon bölgeleri oluşturmak mümkün olur. Konvolüsyonel ağlar, özellikle piksel bazlı segmentasyon gibi yüksek boyutlu yapılandırılmış çıkışlar üretmek için güçlü bir modeldir. CNN ağının genel yapısı Şekil 2.4'te verilmektedir. [80].



Şekil 2.4 CNN ağının genel yapısı

2.2.4 Zamansal Konvolüsyonel Ağlar

Zamansal Konvolüsyonel Ağlar, diğer ismiyle bir boyutlu CNN mimarileri, zaman serisinin adımları üzerinde çalışan zamansal konvolüsyonel katman kullanmaktadır. Bu bağlamda, zaman terimi, belirli bir zaman adımı için hesaplanan aktivasyonların gelecekteki zaman adımlarından bağımsız olduğunu ifade etmektedir. Önceki zaman adımlarıyla anlam oluşturmak için genellikle birden fazla konvolüsyonel katman bir araya getirilmektedir. Genişleme faktörü (*dilation factor*), birim aralıklı konvolüsyonlarda belirli aralıklarla giriş verilerini seçerek alıcı alanını (*receptive field*) genişleten katsayıdır. Ardışık konvolüsyonel katmanların genişleme faktörü, daha büyük alıcı alan boyutları elde etmek için üstel olarak artmaktadır. TCN'nin genel yapısı, bir dizi artık (*residual*) bloktan oluşmaktadır. Her blok, aynı genişleme faktörüne sahip zaman konvolüsyonel katmanlardan oluşur. Bu katmanlardan sonra, normalizasyon işlemi ve ReLU aktivasyon fonksiyonu uygulanmaktadır

3
KURGU TANIMI VE MATERYAL

Radar tabanlı enkaz altı canlı tespit sistemi, enkaz altında bulunan kişilerin istemli veya istemsiz hareketlerinden kaynaklanan gecikmeyi (gönderilen ve alınan sinyaller arasındaki fark) analiz ederek canlıları tespit etmeye dayanan bir prensiple tasarlanmıştır. Bu sistem ayrıca, solunumun ve yapı malzemelerinin farklı elektriksel özelliklerinin elektromanyetik dalgaların davranışını doğrudan etkilemesi prensibini de temel almaktadır.

Elektromanyetik dalgaların yayılımı, bir ortamda ilerleyişi, bu ortamın bağıl geçirgenlik değeri (ε_r) ve elektriksel iletkenliği (σ) ile doğrudan ilişkilidir. Bu iki parametre, dalganın hızını, yansımasını, zayıflamasını ve enerji kaybını belirleyen temel faktörlerdir. Bağıl geçirgenlik, ortamdaki elektrik alanın depolama kapasitesini ifade eder ve dalga hızı ile kırılma indisi üzerinde etkili bir parametredir. Dalganın hızı (v), Denklem 3.1'de verildiği gibi ortamın bağıl geçirgenliği (ε_r) ve manyetik geçirgenliğine (μ_r) bağlıdır.

$$v = \frac{1}{\sqrt{\mu_r \varepsilon_r \varepsilon_0 \mu_0}} \tag{3.1}$$

Bu ifadede sırasıyla ε_0 ve μ_0, vakumun elektrik geçirgenlik sabiti ve vakumun manyetik geçirgenlik sabitidir. Ortamın kırılma indisi (n) de Denklem 3.2'de verildiği gibi bağıl geçirgenlik (ε_r) ve manyetik geçirgenlik (μ_r) ile ilişkilidir.

$$n = \sqrt{\varepsilon_r \mu_r} \tag{3.2}$$

Elektriksel iletkenlik (σ), bir ortamın elektrik akımını taşıma kapasitesini ifade eder ve dalga zayıflaması üzerinde etkilidir. Elektriksel iletkenlik, ortamda elektromanyetik dalganın zayıflamasına neden olur. Zayıflama katsayısı (α),

Denklem 3.3'te verildiği gibi ifade edilir.

$$\alpha = \sqrt{\pi f \mu \sigma} \tag{3.3}$$

Bu ifadede f dalganın frekansı ve μ ortamın manyetik geçirgenliğidir. Bağıl geçirgenlik (ε_r) ve elektriksel iletkenlik (σ), elektromanyetik dalganın ortamdaki yayılımını, zayıflamasını ve kırılma davranışını belirleyen temel faktörlerdir [81].

Bir insan nefes aldığında akciğerinin hacmi artmakta ve göğüs kafesi genişlemektedir, nefes verdiğinde ise akciğerinin hacmi azalmakta ve göğüs kafesi daralmaktadır. Solunum sırasında meydana gelen bu değişim, akciğerin elektriksel özelliklerinde, Tablo 3.1 ve Tablo 3.2'de gösterildiği gibi, nefes alma ve verme durumları arasında farklılık oluşmasına neden olmaktadır [82].

Tablo 3.1 Nefes alınmış durumda iken akciğerin elektriksel özellikleri

Frekans [MHz]	**Bağıl Geçirgenlik [ε_r]**	**Elektriksel İletkenlik [S/m]**
200	2.66×10^{1}	3.35×10^{-1}
400	2.38×10^{1}	3.74×10^{-1}
600	2.28×10^{1}	4.07×10^{-1}

Tablo 3.2 Nefes verilmiş durumda iken akciğerin elektriksel özellikleri

Frekans [MHz]	**Bağıl Geçirgenlik [ε_r]**	**Elektriksel İletkenlik [S/m]**
200	5.92×10^{1}	6.10×10^{-1}
400	5.46×10^{1}	6.83×10^{-1}
600	5.28×10^{1}	7.50×10^{-1}

Yapı malzemelerinin de elektriksel özellikleri ve yapı içerisindeki oranları, elektromanyetik dalgaların davranışını doğrudan etkiler. Bina yapımında kullanılan temel malzeler çimento, agrega, ahşap, tuğla, demir, alüminyum, polivinil klorür, kiremit ve gaz betonudur. Yapı içindeki genel malzeme dağılımı binadan binaya değişiklik göstermektedir [83].

Enkaz altı canlı tespiti sistemine yönelik kavram kanıtını sağlamak için çalışmalar üç farklı yaklaşım ile gerçekleştirilmiştir:

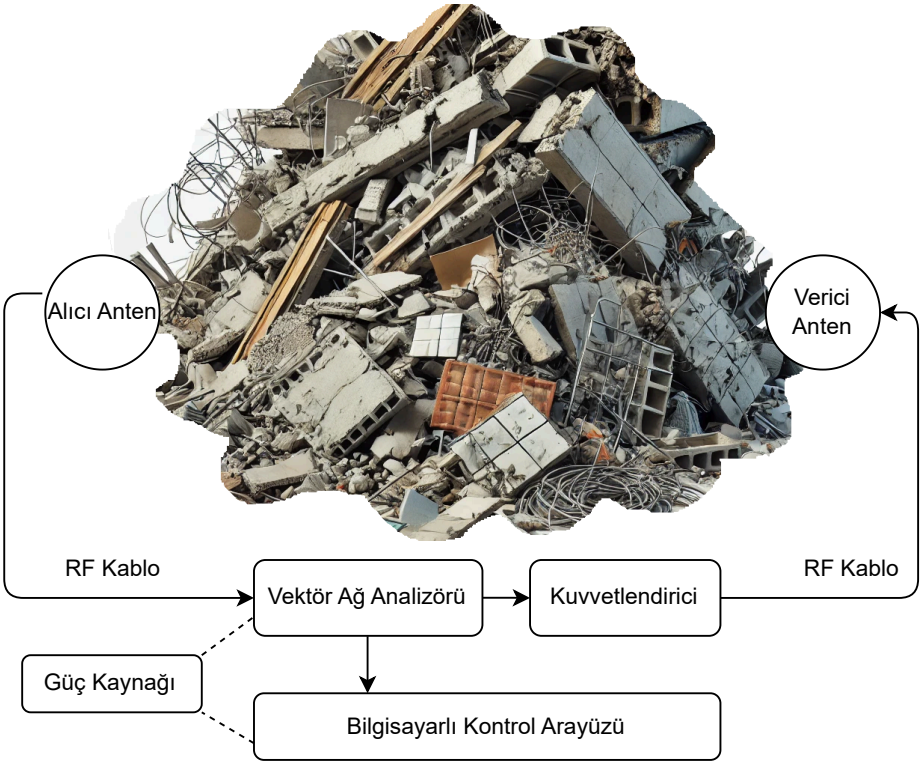
- Benzetim temelli enkaz ve fantom modelleri ile yapılan çalışmalar,
- Laboratuvar ortamında kurulan gerçekçi enkaz modeli ile yapılan çalışmalar,
- AFAD'ın arama kurtarma eğitimleri için kullandığı sahadaki gerçek enkaz alanında gerçekleştirilen çalışmalar.

Proje ekibi tarafından gerçekleştirilen kurgu ve anten tasarımından ayrı olarak, tez kapsamında arayüz programının geliştirilmesi, deneysel ölçüm düzeneklerinin kurulmasına katkı, ölçüm içeriğine dair planlanlama, ölçüm verilerin kaydedilmesi, ölçümlerin kablosuz olarak alınması ve ön işlemeye dair yapılan çalışmalar bu bölümde verilmektedir.

3.1 Ekipmanların ve Ölçüm Ortamının Tanıtımı

Kullanılan radar sistemi; bir Vektör Ağ Analizörü (VNA), bir güç amplifikatörü, bir alıcı ve bir verici antenden oluşmaktadır. VNA, bir ağın veya bir ağ bileşeninin parametrelerini ölçmek için kullanılan elektronik cihazdır. Ağ parametreleri genellikle S-parametreleri (saçılma parametreleri) olarak adlandırılır. RF veya mikrodalga bir ağın frekans tepkisi, başlangıç ve bitiş frekansları arasında incelenerek; S_{11}, S_{21} gibi saçılma parametreleri, yansıma katsayısı, kazanç ve kayıp ölçümleri yapılabilir. VNA, test altındaki ağa bilinen bir RF sinyali gönderir ve ağın yanıtını ölçerek analiz etmeye yarar. Proje ölçümlerinde, Planar TR1300/1 isimli vektör ağ analizörü kullanılmıştır. VNA'nın iki adet portu bulunmaktadır ve çıkış gücü -55 dBm ile +3 dBm arasında ayarlanabilir. Anten bağlantıları için RF koaksiyel kablolar kullanılmaktadır. Koaksiyel kabloların VNA portlarına bağlantısı için N-tipi SMA (Sub-minyatür A Tipi) konektörler kullanılmaktadır. Geniş bant amplifikatörü, yüksek çıkış gücü ($+26$ dBm) ve yüksek düz kazanç (tipik olarak 27 ± 2 dB) özelliklerine sahiptir. Alıcı ve verici antenler, $150 - 650$ MHz bandında çalışan projeye özgü tasarlanmış iki adet $bowtie$ ve bir adet $horn$ antenin ikili kombinasyonlarından oluşmaktadır. Verici anten, VNA'nın birinci portuna bağlanırken, alıcı anten ikinci porta bağlanmaktadır.

Ölçüm sistemi ise Şekil 3.1 ile verildiği gibi radar sistemindeki ekipmanlar ile bir bilgisayar, bir tablet, bir ağ yönlendiricisi ve güç kaynağından oluşmaktadır. Tez kapsamında geliştirilen ve MATLAB ile derlenen kontrol arayüz programı, her adımda ölçümlerin takip edilmesi için kullanılmaktadır. Program, enkazın zayıflama özelliklerini gözlemleyerek ideal çalışma frekanslarını otomatik olarak belirlemektedir. Yazılım, düşük kayıp özellikleri sergileyen üç frekansı seçer ve bu frekanslardaki sinyaller verici anten aracılığıyla enkaz modeline gönderilir. Alıcı anten tarafından alınan sinyaller, VNA'nın ikinci portuna iletilir. Genlik ve faz değişimleri frekansın bir fonksiyonu olarak ölçülmekte ve kontrol arayüzü üzerinden gözlemlenip kaydedilmektedir. Operatör etkisini ortadan kaldırarak gürültüsüz ölçüm ve kayıt işlemlerini tamamlayabilmek için, bir ağ yönlendiricisi üzerinden çevrimdışı bağlantı kurulmuş ve sistem, bir tablet aracılığıyla uzaktan kontrol edilmiştir.



Şekil 3.1 Ölçüm sisteminin genel yapısı

Laboratuvar ortamında, Şekil 3.2'de gösterildiği üzere, 135 cm yüksekliğinde ve 298 cm genişliğinde ahşap, fayans, cam, beton parçaları, tuğla, gazbeton ve perde betondan oluşan bir enkaz modeli oluşturulmuştur. Bu modelin içerisine, 190 cm derinlik boyunca bir insanın yerleşebileceği bir körüklü boru yerleştirilmiştir. Şekil 3.3'te AFAD sahasında kullanılan ölçüm düzeneği ve uzaktan takip gösterilmektedir.



Şekil 3.2 Laboratuvarda oluşturulan enkaz modeli a) Önden görünümü b) Yandan görünümü



Şekil 3.3 Laboratuvarda bulunan enkaz alanı a) Ölçüm düzeneği b) Uzaktan takip

3.2 Ön Çalışmalar

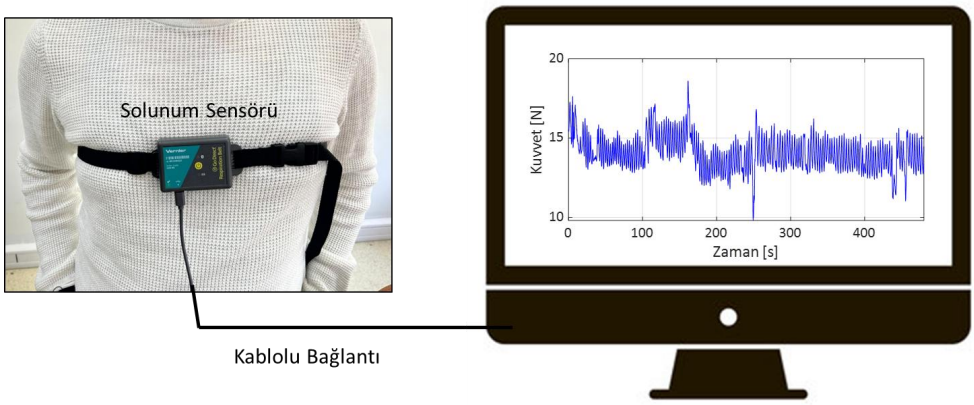
Solunum sinyallerine ilişkin ön çalışmalar kapsamında, solunum sensörü kullanılarak farklı bireylerden kayıtlar alınmış ve göğüs üzerindeki kuvvet değişimi incelenmiştir. Ardından, deneysel ortamlara geçilmeden önce elektromanyetik alan benzetim programı üzerinde bir fantom ve farklı yapı malzemelerinden oluşan enkaz modeli üzerinde çalışmalar yürütülmüştür.

3.2.1 Solunum Sensörü ile Kaydedilen Veri

Solunum sinyalleri, her bir bireyin her koşulda kendine özgü belirgin ve tekrarlayan örüntüler sergileyen zamana bağlı ölçülebilir sinyallerdir [84]. Bu sinyallerin doğru sınıflandırılması, çeşitli solunum bozukluklarının tespiti için oldukça önemlidir [85]. Ayrıca, bu sinyaller, göğüs hareketlerini kullanan radar çalışmaları için çeşitli sinyal işleme ve sınıflandırma yöntemlerinin geliştirilmesinde önemli bir rol oynamaktadır [86–88].

Solunum sinyallerinin incelenmesi, duvarların veya enkazın arkasında bulunan bir kişinin nefes alıp almadığını, konuşup konuşmadığını ve dolayısıyla canlı bir varlığın mevcut olup olmadığını tespit edebilmesi açısından önem taşımaktadır [89]. Bu sinyallerdeki değişimlerin anlaşılmasına, radar sistemi ile elde edilen gürültülü sinyalden gerçek solunum sinyalini ayırmak için ihtiyaç duyulmaktadır.

Vernier Go Direct Solunum Kemeri, insan solunumunu ölçmek için tasarlanmış bir basınç sensörüdür. Cihaz, bir kuvvet sensörü ve göğsü çevreleyen ayarlanabilir bir kayışa sahiptir ve bu sayede hem solunumu hem de solunum hızını ölçer. Bu sensör, solunum sırasında göğüs tarafından uygulanan kuvvetin gözlemlenmesini

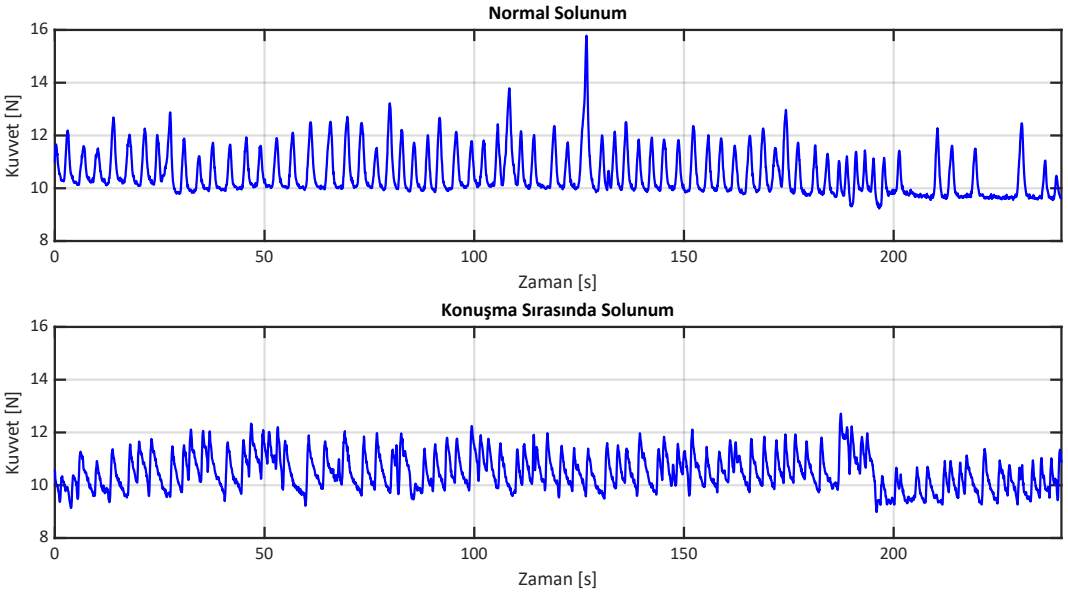


Şekil 3.4 Solunum sinyali oluşturmaya yönelik ölçüm düzeneği

sağlar. Sensör, solunum kuvvetini gerçek zamanlı olarak gösteren *Graphical Analysis* uygulaması ile birlikte çalışmaktadır. Cihaz bilgisayara kablosuz olarak bluetooth bağlantısı ile veya kablolu olarak USB bağlantısı ile bağlanarak veri toplamada esneklik sağlar. Ayrıca kemer, hem kablolu hem de kablosuz modlarda kullanım sağlayan şarj edilebilir bir batarya ile çalışır. Örnekleme frekansı ve süresi uygulama içerisinde değişitirilebilmektedir [90].

Ölçüm düzeninde, solunum sensörü kablo ile bilgisayara bağlanmıştır. Her katılımcı, sensör kemeri vücutlarının maksimum ön-arka çevresi etrafında ve iki göğüs arasındaki orta noktada konumlandırılmış olarak Şekil 3.4'te gösterildiği gibi ayakta dururken ölçülmüştür.

On farklı (altı kadın ve dört erkek) katılımcının solunum sinyalleri kaydedilmiştir. Katılımcıların yaşları 24 ile 59 arasında, ağırlıkları 50 ile 102 kg arasında ve boyları 160 ile 183 cm arasındadır. Her bir katılımcının solunum sinyalleri, normal nefes alma ve konuşma sırasında 480 saniye boyunca kaydedilmiştir. Örnekleme frekansı (kayıt alındığı esnada) saniyede 20 örnek olarak belirlenmiştir. Bu düzenek, farklı bireylerin iki farklı koşul altındaki solunum sinyallerinin, Şekil 3.5'te gösterildiği gibi her bir sinyal 480 saniye boyunca kaydedilmiştir. Veri seti, her bir katılımcı için iki solunum durumuna ait birer dakikalık kayıtlar halinde ayrılmıştır ve sonuç olarak 80 adet 1×1200 boyutunda sinyallerden oluşmaktadır.



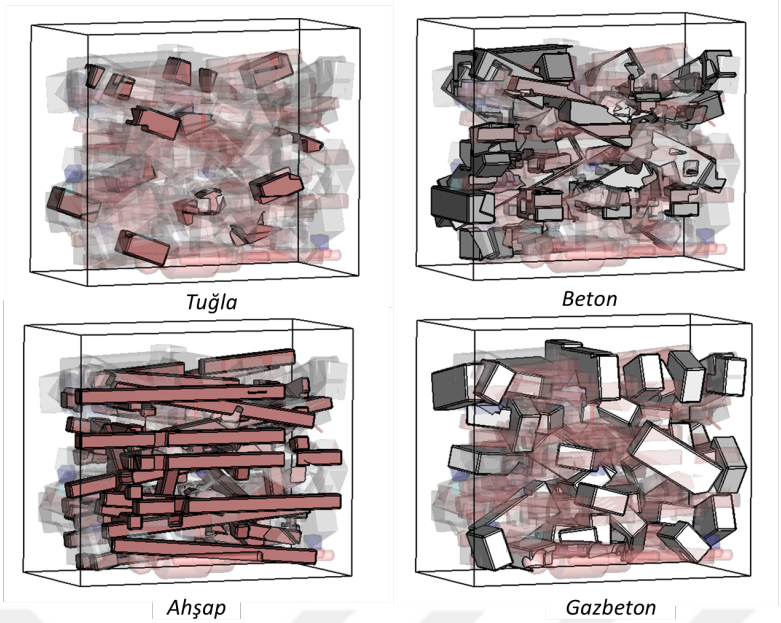
Şekil 3.5 Normal nefes ve konuşma sırasında kaydedilen sinyaller

3.2.2 Benzetim Ortamında Oluşturulan Veri

Bu tez çalışmasında deneysel ortamda yapılan çalışmalardan önce, gerçek senaryolara uygun olarak benzetim ortamında elde edilen verilerden yararlanılmıştır. Proje ekibi, elektromanyetik alan benzetim programında *(CST Studio Suite)*, içerisinde bir insan modelinin bulunduğu, deprem nedeniyle yıkılmış bir binanın enkaz modelini oluşturmuştur. Bu kapsamda, insan vücudunun fizyolojik, fiziksel ve elektriksel özelliklerini yansıtacak şekilde bir fantom modeli geliştirilmiştir. Oluşturulan gerçekçi kurgulara ait profiller, Şekil 3.6'da sunulmaktadır. $2 \times 1 \times 1.5\,\mathrm{m}^3$ (genişlik × derinlik × yükseklik) boyutunda bir enkaz yığını için tasarlanan kurgular Tablo 3.3 ile verildiği üzere; çeşitli yapı malzemesi oranlarından oluşan 4 farklı model, 3 farklı hava boşluğu oranı, fantomun farklı yerleşiminden oluşan 5 senaryo ve bunların her birinde fantomun bulunduğu 3 farklı derinlik değeri ile tasarlanmıştır. Böylelikle 180 ayrı olası kurgu sonucu elde edilmektedir. Fantomun boyu 150 cm ve göğüs çapı ise 20 cm'dir. Nefes almayı modellemek için her bir profilde 11 farklı göğüs esneme payı ile benzetim yapılmıştır. Göğüs çapı 20'den 25'e doğru ilerleyen 0.5 cm adımlar ile her bir profilde artırılmaktadır. 150 ile 650 MHz aralığında 500 kHz adımlar ile taranan spektrum düzleminde düzlem dalga uyarımı ile elde edilen S-parametreleri real ve imajiner kısımlar olarak kaydedilmektedir.

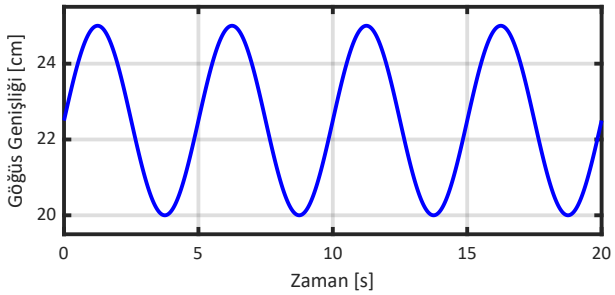
Tablo 3.3 Elektromanyetik alan benzetim programında oluşturulan profiller

İsim	Açıklama
Model 1	Kurgudaki yapı malzemesi oranları: %40 beton, %30 gazbeton, %25 tahta, %4.5 kil, %0.5 plastik+cam+demir
Model 2	Kurgudaki yapı malzemesi oranları: %30 beton, %35 gazbeton, %30 tahta, %4.5 kil, %0.5 plastik+cam+demir
Model 3	Kurgudaki yapı malzemesi oranları: %20 beton, %40 gazbeton, %35 tahta, %4.5 kil, %0.5 plastik+cam+demir
Model 4	Kurgudaki yapı malzemesi oranları: %10 beton, %45 gazbeton, %40 tahta, %4.5 kil, %0.5 plastik+cam+demir
Hava 1	Kurgudaki hava boşluğu oranı: %20
Hava 2	Kurgudaki hava boşluğu oranı: %30
Hava 3	Kurgudaki hava boşluğu oranı: %40
Senaryo 1	Fantom x düzlemine paralel ve ayakları y düzlemine daha yakın (x = 100 cm, y = 75 cm)
Senaryo 2	Fantom x düzlemine paralel ve ayakları y düzlemine daha yakın (x = 100 cm, y = 50 cm)
Senaryo 3	Fantom x düzlemine paralel ve ayakları y düzlemine daha yakın (x = 100 cm, y = 25 cm)
Senaryo 4	Fantomun ayak-kafa yerleşimi diagonel ve ayakları orijin noktasında (x = 50 cm, y = 50 cm)
Senaryo 5	Fantomun ayak-kafa yerleşimi diagonel ve ayakları x = 100 noktasına yakın (x = 150 cm, y = 50 cm)
Yükseklik 1	Fantomun bulunduğu yükseklik z = 0 cm
Yükseklik 2	Fantomun bulunduğu yükseklik z = 50 cm
Yükseklik 3	Fantomun bulunduğu yükseklik z = 100 cm
Göğüs Esneme Payı 1	Fantomun göğüs çapı 20 cm iken esneme payı = 0 cm Toplam göğüs çapı = 20 cm
Göğüs Esneme Payı 2	Fantomun göğüs çapı 20 cm iken esneme payı = 0.5 cm Toplam göğüs çapı = 20.5 cm
Göğüs Esneme Payı 3	Fantomun göğüs çapı 20 cm iken esneme payı = 1 cm Toplam göğüs çapı = 21 cm
Göğüs Esneme Payı 4	Fantomun göğüs çapı 20 cm iken esneme payı = 1.5 cm Toplam göğüs çapı = 21.5 cm
Göğüs Esneme Payı 5	Fantomun göğüs çapı 20 cm iken esneme payı = 2 cm Toplam göğüs çapı = 22 cm
Göğüs Esneme Payı 6	Fantomun göğüs çapı 20 cm iken esneme payı = 2.5 cm Toplam göğüs çapı = 22.5 cm
Göğüs Esneme Payı 7	Fantomun göğüs çapı 20 cm iken esneme payı = 3 cm Toplam göğüs çapı = 23 cm
Göğüs Esneme Payı 8	Fantomun göğüs çapı 20 cm iken esneme payı = 3.5 cm Toplam göğüs çapı = 23.5 cm
Göğüs Esneme Payı 9	Fantomun göğüs çapı 20 cm iken esneme payı = 4 cm Toplam göğüs çapı = 24 cm
Göğüs Esneme Payı 10	Fantomun göğüs çapı 20 cm iken esneme payı = 4.5 cm Toplam göğüs çapı = 24.5 cm
Göğüs Esneme Payı 11	Fantomun göğüs çapı 20 cm iken esneme payı = 5 cm Toplam göğüs çapı = 25 cm



Şekil 3.6 Enkaz modelinde yer alan tuğla, beton, ahşap ve gaz beton gösterimi

Frekans domeninde kaydedilen bu S-parametrelerinden asıl elde edilmek istenen veri düzeni, nefes alıp veren bir insanın zamana bağlı olarak göğüs yarıçapının değişimidir. Şekil 3.7'de gösterildiği gibi solunum döngüsünün ilk $\%40$'ı nefes alma, geri kalan $\%60$'ı ise nefes verme sürecine aittir [91]. Yetişkinlerde solunum hızı genellikle dakikada 12 ila 20 arasındadır [92]. Solunum kinematiği göğüs çevresi uzunluğunu zamana bağlı olarak değiştirmektedir.

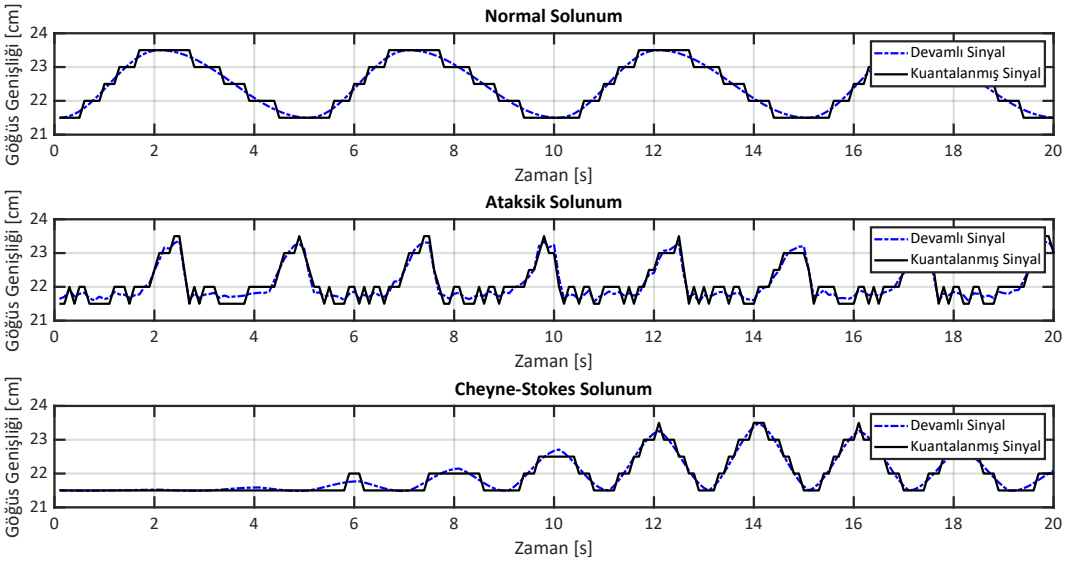


Şekil 3.7 Sağlıklı bir yetişkin nefes alıp verirken göğüs çapında meydana gelen ideal değişim (solunum hızı dakikada 12 iken)

Gerçekçi kurguda enkaz altında nefes alan bir kimsenin göğüs bölgesinin hareketinden kaynaklanan ve zamanla değişen genlik-faz değişiminin oluşturduğu bilgiden yararlanılmak istenmektedir. Bu nedenle, benzetim programından elde edilen 1980 dosyadan oluşan veri, MATLAB ortamında zamana bağlı sinyallere dönüştürülmüştür. Ölçüm ortamında mevcut olan gürültüler nedeniyle nefes alıp verme tespiti zorlaşmaktadır. Tespit işlemi, benzetim verilerinden yararlanıldığında ayırt edilmesi daha kolay hale gelir. Ancak, ağın aynı örüntüyü ezberlemesi istenmediğinden, bir kişinin solunumuna bağlı olarak göğüs

çapındaki değişimlerden sağlık durumunu belirlemek amacıyla üç farklı örüntü oluşturulmuştur. Benzetim verileri ile canlı tespitini daha karmaşık hale getirmek üzere Şekil 3.8'de verildiği üzere çeşitli sağlık durumlarında nefes alma örüntüleri sanal örnekler olarak veri setine eklenmiştir:

- Normal solunum: Sağlıklı yetişkinlerde normal nefes alıp vermeye ait örüntüdür. Solunum hızı $12, 15, 18$ ve 20 olarak belirlenmiştir.
- Ataksik solunum: Düzensiz solunumlarla karakterize edilen anormal bir solunum örüntüsüdür. Bu solunum örüntüsü genellikle beyindeki medulla solunum merkezinde hasar olduğunda ortaya çıkar. Bu hasar genellikle baş travması, travmatik beyin yaralanması, beyin tümörü, artmış intrakraniyal basınç gibi durumlarla ilişkilidir. Bu örüntü genellikle hastanın kritik bir durumda olduğunu göstermektedir [93].
- Cheyne-Stokes solunumu: Cheyne-Stokes solunumu, kısa apne periyotları ile ayrılan sığ ve derin solunum periyotlarıyla karakterize edilen anormal bir solunum desenidir. Bu solunum örüntüsü genellikle komada olan hastalarda görülür ve beyne giden oksijen eksikliğinden kaynaklanır. Diğer nedenler arasında artmış intrakraniyal basınç, travmatik beyin yaralanması, inme, kalp yetmezliği bulunmaktadır [93].



Şekil 3.8 Üç farklı sınıfa ait örneğin zamana bağlı değişimi

Zaman içinde değişen ve göğüs çapı aralığına uyumlu farklı solunum hızları, gerçek solunum hızlarını temsil eden 50 farklı değerle oluşturulmuştur. Her bir örnekte, aynı göğüs çapına karşılık gelen değerler kullanılarak aynı boyuttaki bir bireyin farklı solunum örüntüleri Şekil 3.8'de verilen örneklerle temsil edilmektedir

(Göğüs çapı değerleri 0.5 cm aralıklarla kuantalanmaktadır). Genlik ve faz bilgileri, 200 zaman adımı boyunca yeniden düzenlenmekte olup, bu zaman adımları 10 saniyede bir örneklenen 20 saniyelik bir ölçümü temsil etmektedir. Her bir örnek, 60 saniyelik bir solunum örüntüsünden rastgele seçilen 20 saniyelik bir kayıt ile oluşturulmuştur.

Her frekansta, genlik ve faz verileri iki ayrı özellik vektörü olarak kullanılabilmektedir. Tablo 3.3'te verilen profillerin kombinasyonlarıyla oluşturulan 180 farklı duruma ait ölçümler, 60 dakika boyunca ortam ve konum bilgisinden bağımsız olarak alınan bir ölçümü temsil edecek şekilde zaman adımları boyunca art arda eklenmiş ve her bir solunum örüntüsü için toplam 36.000 zaman adımı elde edilmiştir.

Benzetim ortamında oluşturulan modelden iki farklı amaca uygun veri seti oluşturulmuştur:

- Tespit modeli: Bir kişinin enkaz modelindeki varlığının fantoma ait nefes sinyalleri ile tespit edilmesi.
- Solunum sınıflandırma modeli: Enkaz modelinde varlığı tespit edilen kişinin sağlık durumunun belirlenmesi.

Solunum sınıflandırma modeli için oluşturulan veri setinde, *Normal*, *Ataksik* ve *Cheyne-Stokes* sınıflarına ait bu temsili ölçümler, 50 örneğe ait iki farklı (genlik ve faz) özellik vektörünü içermektedir. Böylece, her bir sınıf 50 adet 2×36.000 boyutunda veriden oluşmaktadır.

Tespit modeli için oluşturulan veri setinde *Nefes Tespit Edildi* ve *Nefes Tespit Edilemedi* olarak etiketlenenen iki farklı sınıf bulunmaktadır.

- *Nefes Tespit Edildi* sınıfı, *Normal*, *Ataksik* ve *Cheyne-Stokes* solunum örüntülerinin (2×36.000) art arda dizilmesiyle 2×108.000 boyutunda oluşturulmuştur.
- *Nefes Tespit Edilemedi* sınıfı, aynı boyutta (2×108.000) ancak yalnızca gürültü içeren DC değerlerinden oluşmaktadır.

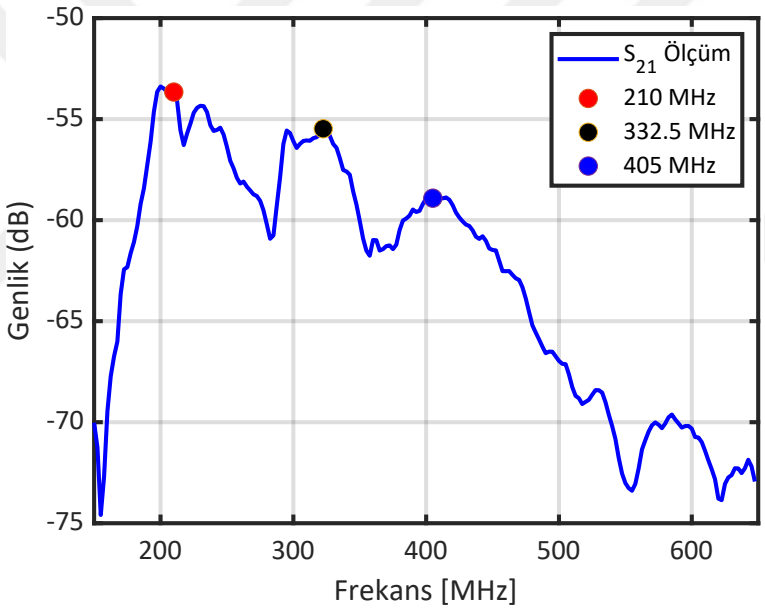
Her bir sınıfa, $10, 20$ ve 30 dB SNR değerinde beyaz Gauss gürültüsü eklenmiştir. Benzetim ortamında elde edilen 1001 farklı frekanstan $170, 290, 410, 530$ ve 650 MHz değerleri seçilerek spektrumun eşit aralıklarda değerlendirilmesi sağlanmıştır [26].

3.3 Laboratuvar ve Saha Çalışmaları

Tez çalışmasının yürütüldüğü deneysel ortamlar; Yıldız Teknik Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümü'nde bulunan Mikrodalga Laboratuvarı'nda gerçek yapı malzemeleri ile oluşturulmuş enkaz modeli ve İstanbul AFAD Birlik Müdürlüğü'nde yer alan gerçek enkazlardan oluşmaktadır.

3.3.1 Laboratuvar Ortamında Toplanan Veri

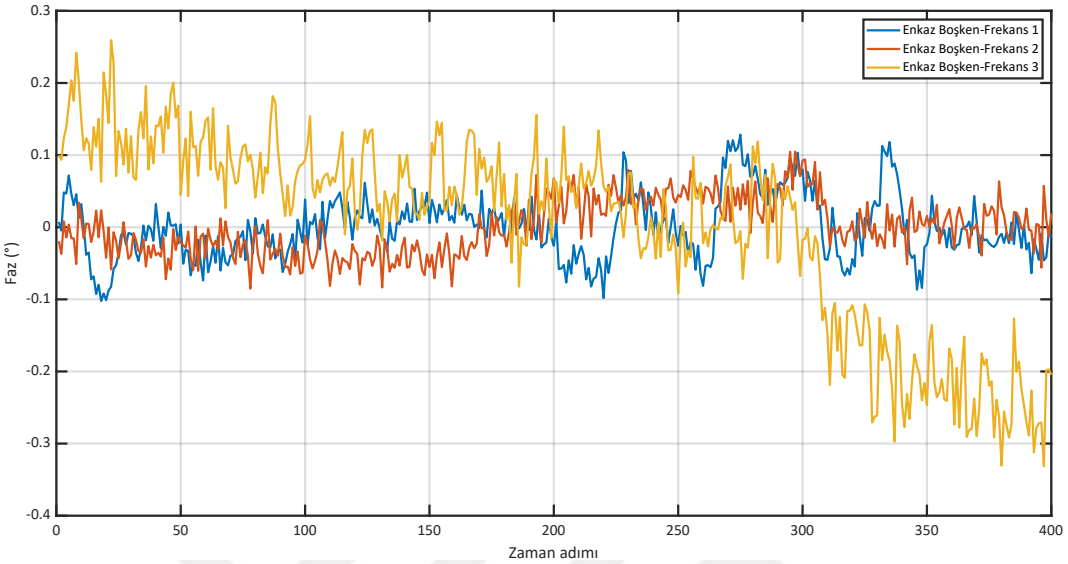
Laboratuvar ortamında, gerçek yapı malzemelerinden oluşturulan enkaz modeli üzerinde gerçekleştirilen ilk çalışmalar; öncelikle ortamın zayıflama analizi ve buna bağlı olarak uygun frekansların belirlenmesine odaklanmıştır. Bu doğrultuda, Şekil 3.9'da gösterildiği üzere, ortamın S_{21} kaydı alınarak geniş frekans aralığını tarayan ve maksimum genlikli tepe noktalarından üç farklı frekansı otomatik olarak seçebilen bir ara yüz yazılımı geliştirilmiştir.



Şekil 3.9 Ortamın zayıflama analizine ait S_{21} kaydı ve frekans seçimi

Şekil 3.9'da görülebileceği gibi S_{21} değeri 210 MHz'de -53.6 dB, 332.5 MHz'de -55.5 dB ve 405 MHz'de ise -59 dB değerindedir. Laboratuvar ortamında ölçüm alınırken yükseltici kullanılmamıştır. Laboratuvar ortamında, enkaz boşken kaydedilen sinyallerin zaman içinde nasıl değiştiğini belirlemek amacıyla uzun süreli ölçümler yapılmış ve elde edilen faz değişimlerine ait örnekler Şekil 3.10'da sunulmuştur. 20 saniye boyunca alınan ölçümlerin örnekleme frekansı 20 seçilmiştir ve 400 zaman adımı boyunca kayıt alınmıştır. Bu incelemeler sonucunda; ölçüm ortamının operatör kaynaklı gürültülere, kablo teması veya ölçüm alanına yakınlık gibi farklı etkenlere duyarlı olduğu görülmüştür. Özellikle enkazda biri bulunduğunda ve ufak hareketler gerçekleştiğinde alınan sinyallerin,

bu tür gürültü kaynaklarıyla benzer özellikler sergileyebildiği tespit edilmiştir. Dolayısıyla, alınan ölçümlerdeki dalgalanmaların, enkaz altında hareket eden bir varlığı tespit etmeye yönelik çalışmaları güçleştirebileceği ve ortam gürültüsünün ölçümleri önemli ölçüde etkileyebileceği ortaya konmuştur.

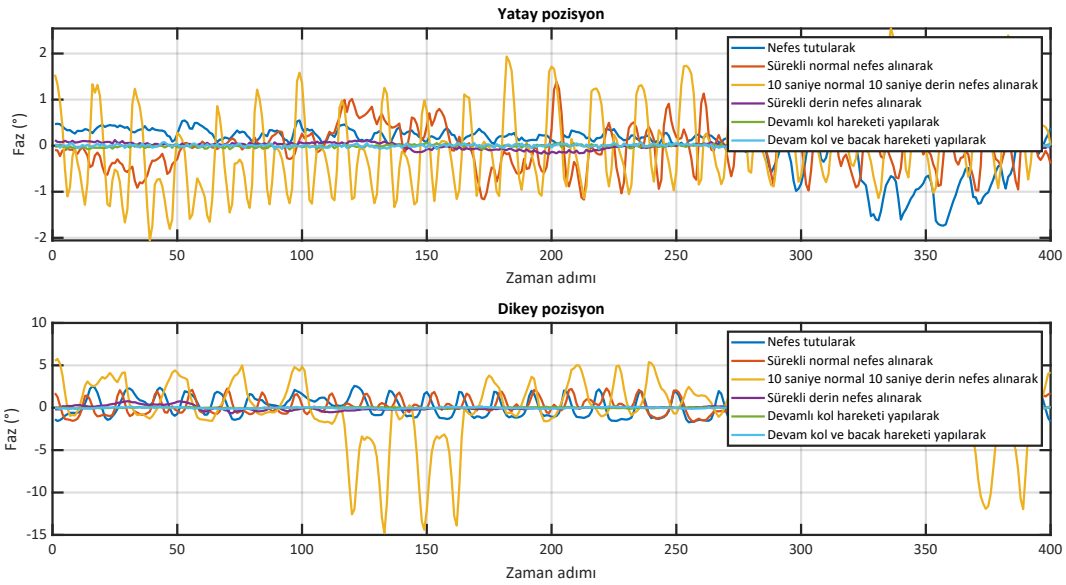


Şekil 3.10 Enkaz boş iken alınan çeşitli faz değişimleri

Laboratuvar temelli veri seti oluşturulmadan önce gerçekleştirilen ön incelemelerde, gönüllü bir katılımcı enkaz modelinin iç kısmında bulunan körüklü boru alanına yerleştirilmiştir. Katılımcıya, iki antenin arasında hem yatay (sırtüstü) hem de dikey (kol üstünde) pozisyonda uzanarak farklı solunum ve hareket senaryoları uygulanması istenmiştir. Bu senaryolar arasında belirli süreyle nefes tutma, sürekli normal nefes alma, 10'ar saniyelik normal ve derin nefes alma döngüleri, kesintisiz derin nefes alma, sürekli kol hareketi ve sürekli kol-bacak hareketi gibi eylemler yer almıştır. Böylece, gerçek bir enkaz ortamında karşılaşılabilecek farklı hareket durumlarının veri setine yansıtılması hedeflenmiştir. Tüm bu ön çalışma kayıtları, Şekil 3.11'de özetlenmiştir.

Laboratuvar ortamında kurulan gerçek enkaz modelinde, 20 farklı gönüllüden elde edilen ölçüm kayıtlarıyla kapsamlı bir veri seti oluşturulmuştur. Katılımcıların yaş, boy ve ağırlık dağılımları Tablo 3.4'te ayrıntılı bir biçimde sunulmaktadır. Bu çalışmada, her bir katılımcıdan beş farklı pozisyon ve üç ayrı nefes-hareket durumu için bi-statik anten aracılığıyla veri toplanmıştır. Ayrıca, enkazda hiç kimse bulunmadığı durumlarda da çevresel gürültünün etkilerini değerlendirmek amacıyla ilave kayıtlar yapılmıştır.

Uygulanan ölçüm prosedürü, veri çeşitliliğini artırmak ve farklı senaryolarda enkaz altı tespitin güvenilirliğini değerlendirmek amacıyla tasarlanmıştır. Her bir ölçüm,



Şekil 3.11 Yatay ve dikey pozisyonlarda faz değişimi

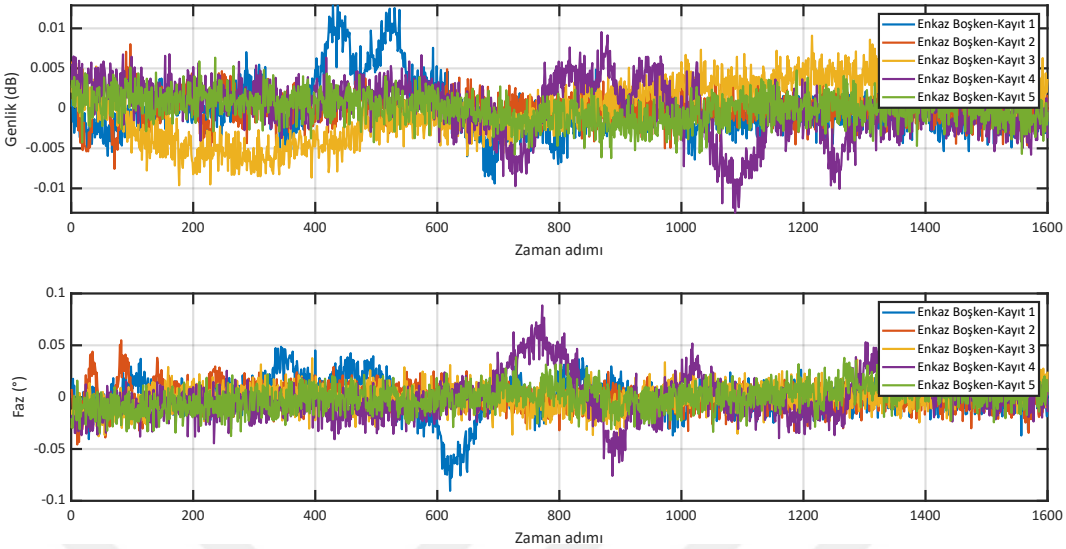
üç farklı frekansta, 20'şer saniyelik parçalar halinde kaydedilmiştir. Bu 20 saniyelik her bir zaman diliminde, örnekleme frekansı 80 seçilerek 1600 zaman adımına ait veri toplanmıştır. Ayrıca, katılımcı başına tüm kayıtlar yaklaşık 45 dakika ile bir saat arasında sürmekte olup, veri elde etme sürecinde sinyalin genlik ve faz bileşenlerini daha net yakalayabilmek için DC ofset bileşeni sinyallerden çıkartılmıştır.

Tablo 3.4 Laboratuvarda yapılan ölçüme katılan kişilerin özellikleri

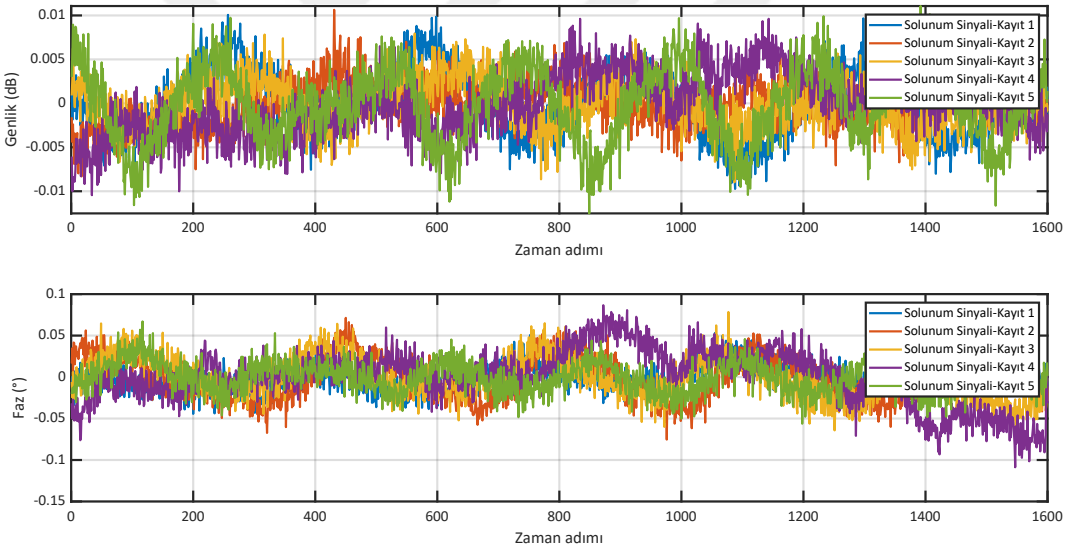
Katılımcı Sayısı	Cinsiyet	Boy [cm]	Ağırlık [kg]	Yaş
5	Kadın	160–177	58–85	27–45
15	Erkek	170–190	62–115	19–31

Şekil 3.9'da gösterildiği gibi seçilen birinci frekans 210 MHz, ikinci frekans 332.5 MHz ve üçüncü frekans ise 405 MHz'dir. Şekil 3.12'te, birinci frekansta enkaz alanının boş olduğu durumda elde edilen ham verilerin genlik ve faz değişimleri ayrıntılı bir şekilde gösterilmektedir. Bu veriler, herhangi bir canlı varlığının olmaması nedeniyle yalnızca çevresel gürültü ve sistem kaynaklı sinyalleri yansıtmaktadır. Benzer şekilde, Şekil 3.13'de birinci frekansta enkazda yalnızca nefes alan bir kişinin bulunması halinde kaydedilen genlik ve faz değişimleri sunulmuştur. Bu koşulda, nefes alıp verme hareketlerinin sinyal üzerinde oluşturduğu dalgalanmalar gözlemlenebilmekte ve söz konusu değişimler, enkaz altı canlı tespit çalışmalarında önemli bir gösterge olarak değerlendirilebilmektedir. Şekil 3.14 ise birinci frekansta, enkaz içerisinde bulunan kişinin aktif olarak hareket ettiği durumda kaydedilen genlik ve faz değişimlerini ortaya koymaktadır. Hareket kaynaklı daha yüksek genlikli dalgalanmalar ve faz kaymaları, kişinin nefes alma

durumuna kıyasla daha belirgin sinyaller oluşturmakta ve bu sayede hareketin varlığını tespit etmeye imkan tanımaktadır.

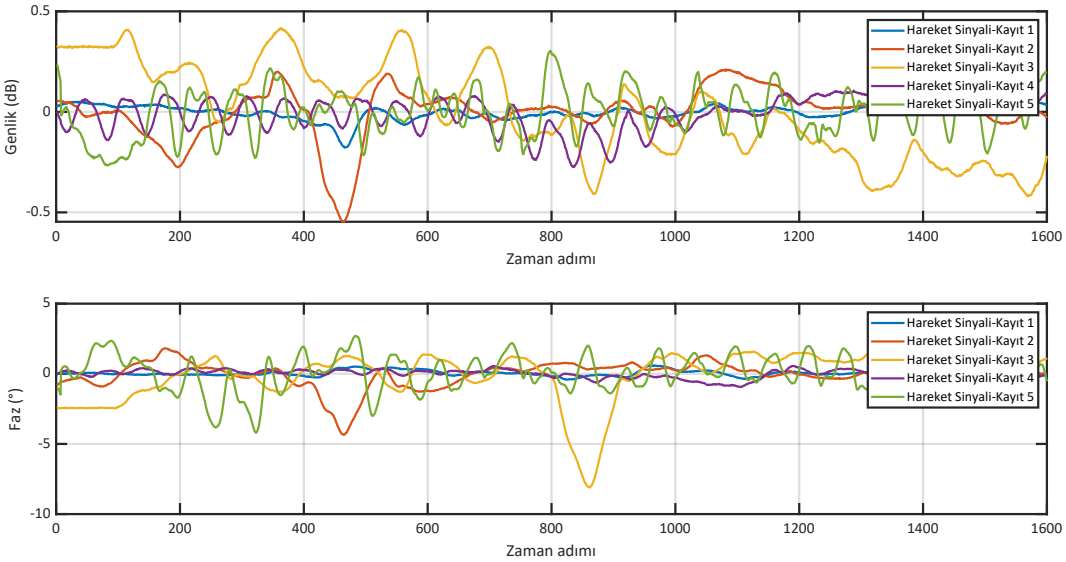


Şekil 3.12 Birinci frekansta enkaz boş iken kaydedilen genlik ve faz değişimleri



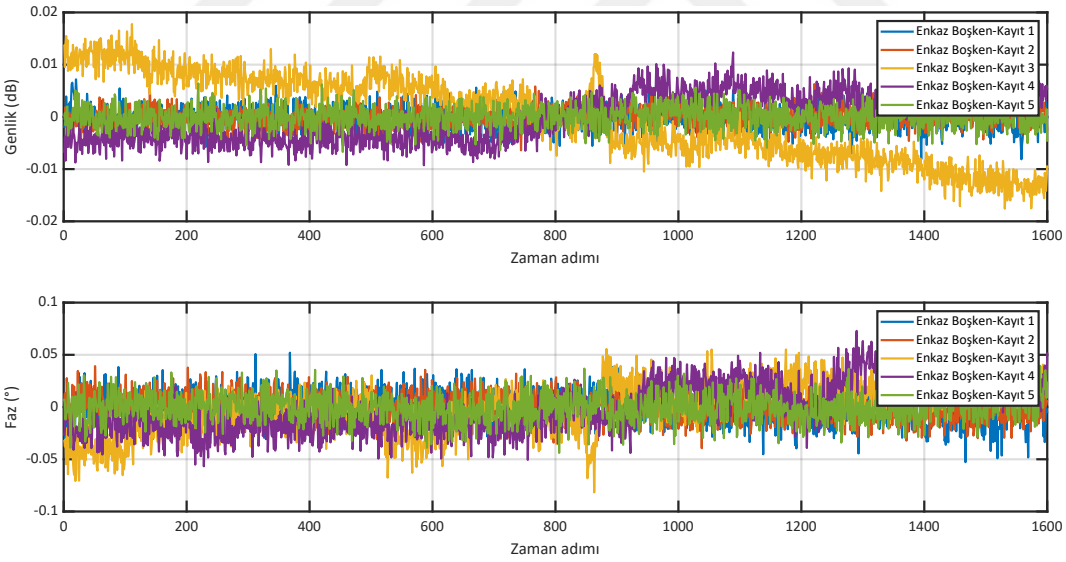
Şekil 3.13 Birinci frekansta enkazda nefes alan biri varken kaydedilen genlik ve faz değişimleri

İkinci frekansla ilgili kayıtlara ait sonuçlar, benzer bir düzen içerisinde Şekil 3.15, Şekil 3.16 ve Şekil 3.17'de sırasıyla sunulmaktadır. Şekil 3.15'te enkaz boşken alınan sinyallerin genlik ve faz değişimleri görülürken; Şekil 3.16, aynı frekansta nefes alan bir katılımcı olduğunda ortaya çıkan değişimlerin detaylarını yansıtmaktadır. Bu durumda genlik ve faz üzerinde gözlenen düzenli, hafif salınımlar, kişinin solunumuyla doğrudan bağlantılıdır. Şekil 3.17 ise aynı frekansta, yine bir katılımcının hareket ettiği sırada kaydedilen verilerin genlik ve fazdaki değişimini göstermektedir. Hareketlerin solunum sinyallerine ek bir varyasyon katması, enkaz altı hareketli bir varlığın daha kolay ayırt edilebilmesinin



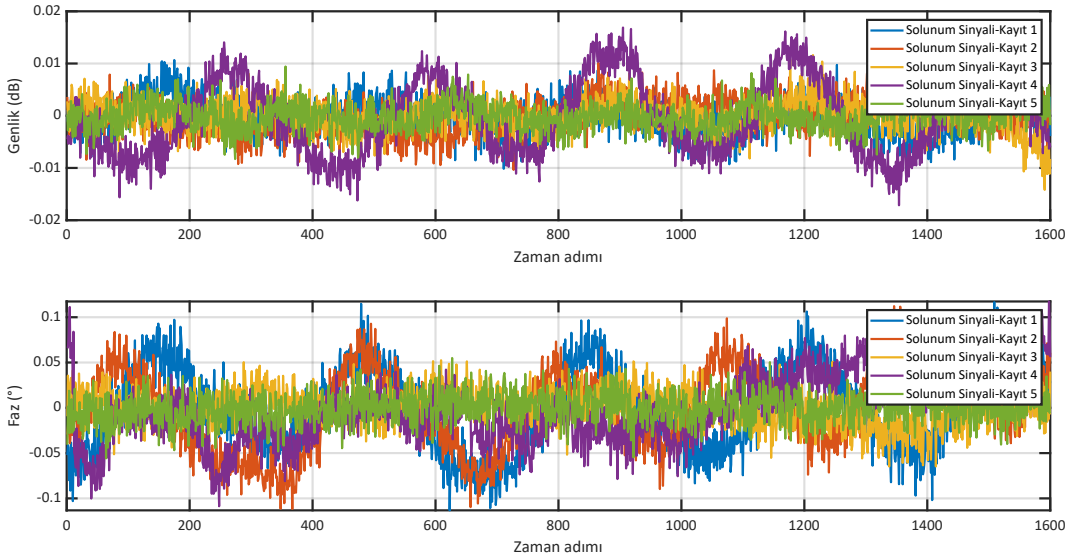
Şekil 3.14 Birinci frekansta enkazda biri hareket ediyorken kaydedilen genlik ve faz değişimleri

mümkün olduğunu göstermektedir. Fakat laboratuvar ortamında oluşturulan kontrollü enkaz modelinin gerçek enkaz modellerine kıyasla çok daha az karmaşık olduğu göz önünde bulundurulmalıdır.

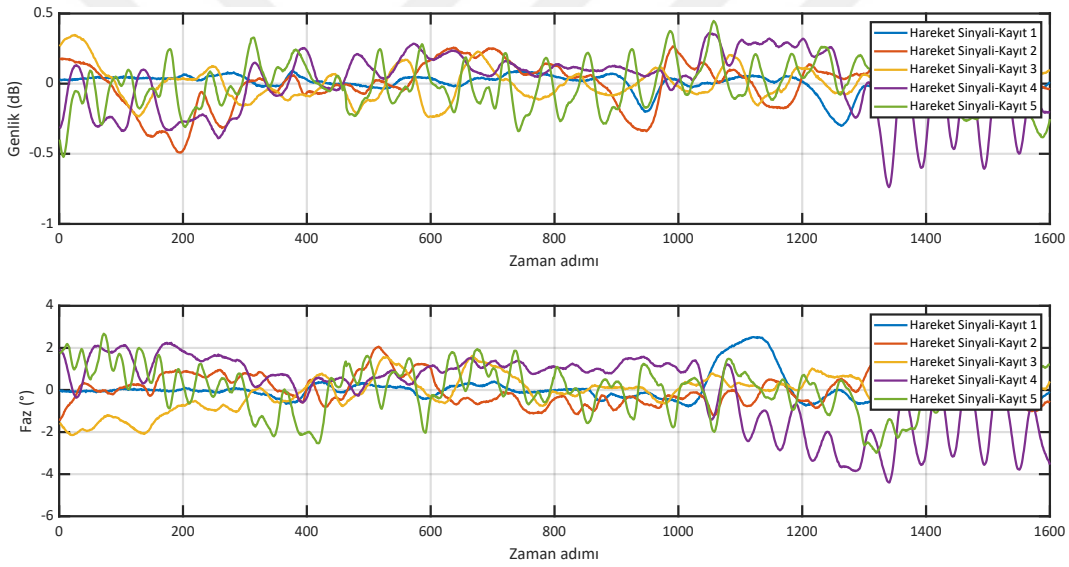


Şekil 3.15 İkinci frekansta enkaz boş iken kaydedilen genlik ve faz değişimleri

Üçüncü frekansta gerçekleştirilen ölçümler için elde edilen sonuçlar ise Şekil 3.18, Şekil 3.19 ve Şekil 3.20'de sırasıyla yer almaktadır. Şekil 3.18 enkazın boş olduğu koşullarda kaydedilen temel arka plan ve sistemsel gürültü bileşenlerini içermektedir. Bununla birlikte, Şekil 3.19, söz konusu frekans bandında yalnızca nefes alan bir katılımcının yarattığı nefes sinyallerinin genlik ve faz değerlerine etkisini ortaya koymaktadır. Son olarak, Şekil 3.20 ise kişinin hareket halindeyken oluşturduğu daha büyük genlik salınımlarını ve faz kaymalarını içermektedir. Farklı



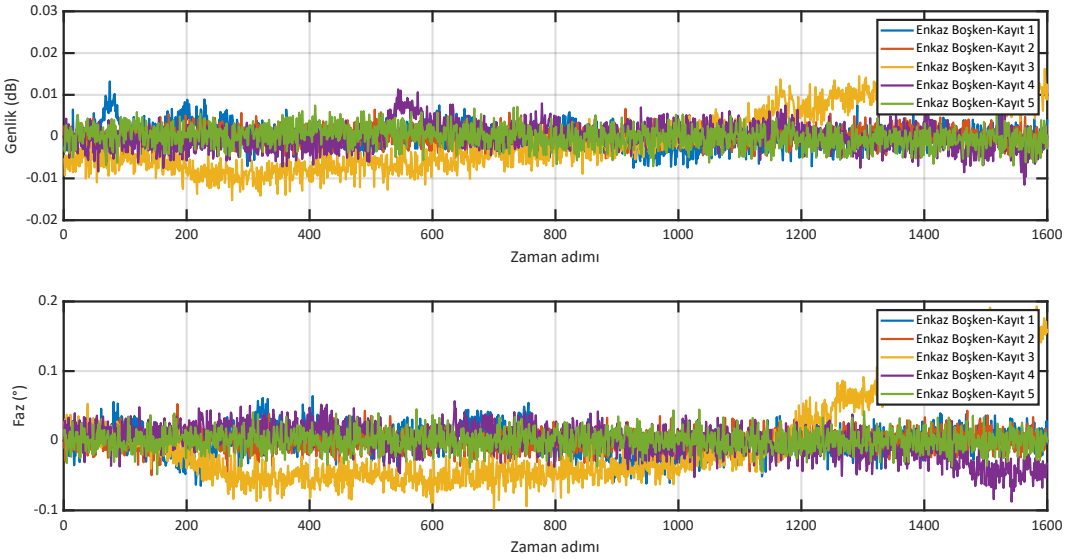
Şekil 3.16 İkinci frekansta enkazda nefes alan biri varken kaydedilen genlik ve faz değişimleri



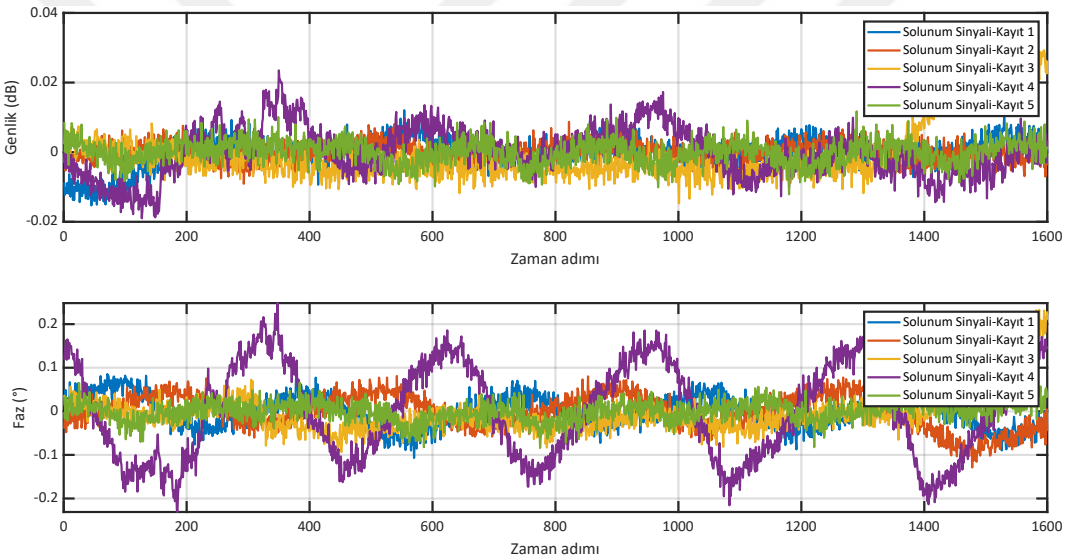
Şekil 3.17 İkinci frekansta enkazda biri hareket ediyorken kaydedilen genlik ve faz değişimleri

hareketlerin ve solunum örüntülerinin sinyal üzerindeki etkilerinin bu şekilde incelenmesi, enkaz arama çalışmalarında hangi frekans aralıklarının daha etkin sonuçlar vereceğini değerlendirmeyi amaçlamaktadır. Frekans bandında tek bir noktaya odaklanmanın getirdiği kısıtları aşmak ve farklı dalga boylarındaki sinyal yayılım özelliklerini detaylı biçimde değerlendirebilmek adına, üç ayrı frekansta ölçüm yapılmasına karar verilmiştir. Bu yaklaşım sayesinde, farklı frekanslardaki sinyallerin enkaz ortamında ne şekilde etkileşime girdiği gözlemlenebilmekte, böylece tespit performansı ve doğruluk düzeyi önemli ölçüde artırılmaktadır.

Farklı frekanslarda genliğin zamana bağlı değişiminin tek bir grafikte özetlendiği

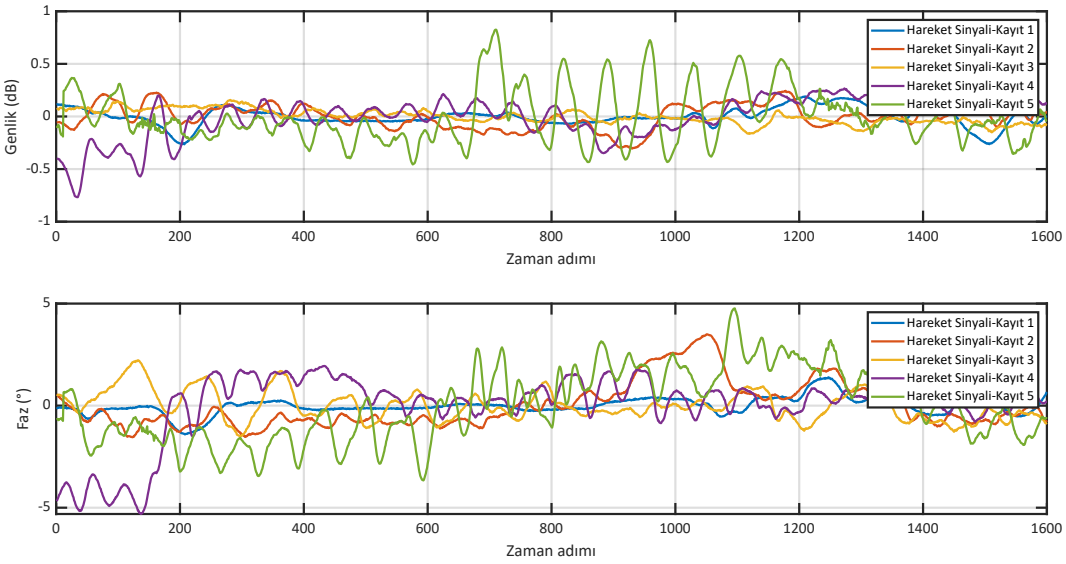


Şekil 3.18 Üçüncü frekansta enkaz boş iken kaydedilen genlik ve faz değişimleri

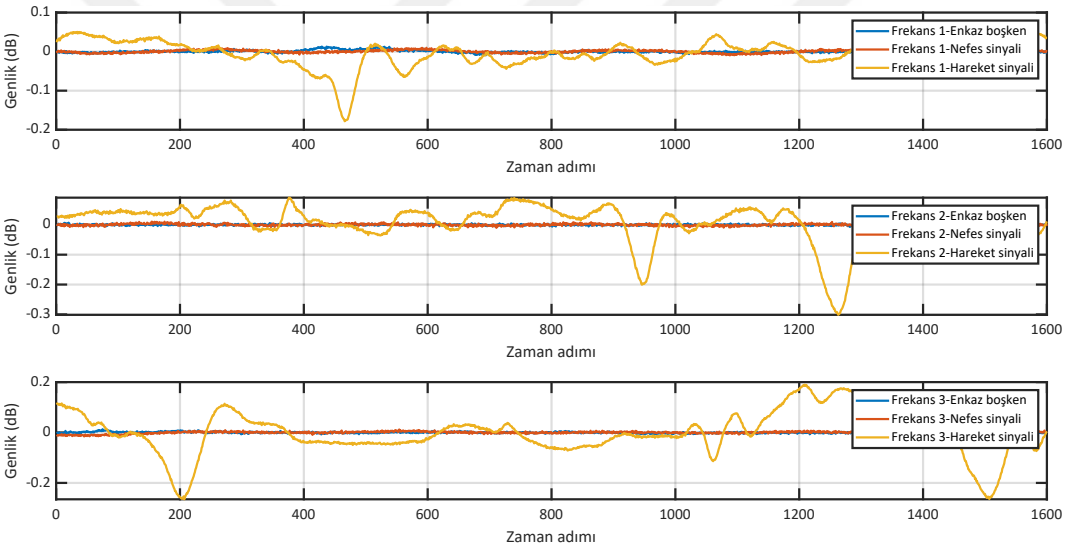


Şekil 3.19 Üçüncü frekansta enkazda nefes alan biri varken kaydedilen genlik ve faz değişimleri

sonuçlar ise Şekil 3.21'de verilmektedir. Burada, enkaz boş iken gözlenen düşük seviyeli değişimlerin, nefes sinyali durumunda nispeten daha düzenli ve orta şiddetli salınımlara, hareket halinde ise daha keskin ve yüksek genlikli salınımlara dönüştüğü izlenebilmektedir. Benzer şekilde, fazın zamana bağlı değişiminin farklı frekanslar için bir arada karşılaştırmalı olarak ele alındığı grafikler Şekil 3.22'de sunulmaktadır. Bu görselde de faz bileşeninde meydana gelen kayma miktarları, enkaz boş, nefes alan bir katılımcı ve hareket eden bir katılımcı örnek durumları açısından karşılaştırılabilir hale getirilmiştir. Elde edilen tüm bu veriler, nefes ve hareket tespitine ilişkin seçilen frekanslar arasındaki farklılıkları değerlendirmek üzere önemlidir.



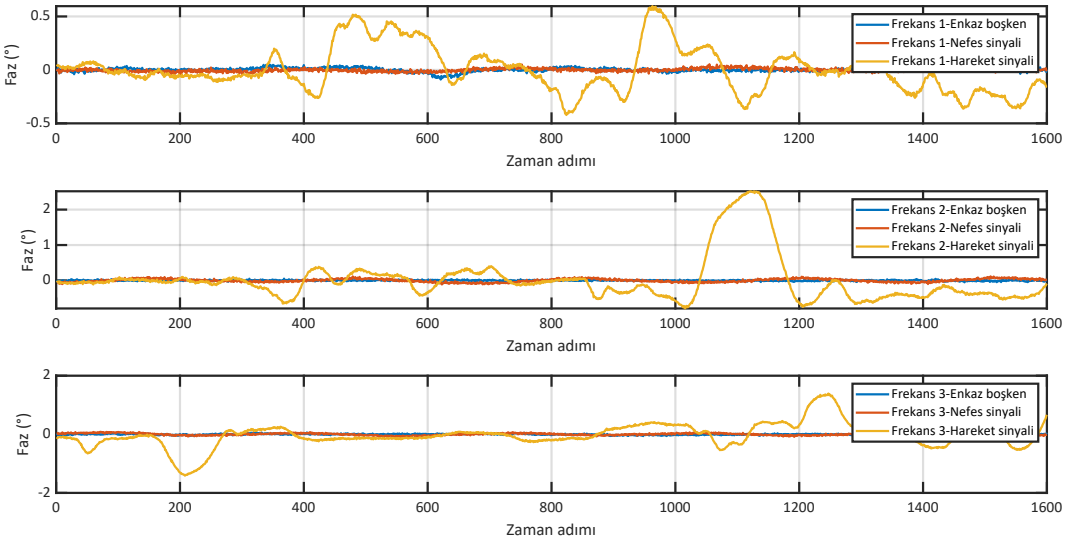
Şekil 3.20 Üçüncü frekansta enkazda biri hareket ediyorken kaydedilen genlik ve faz değişimleri



Şekil 3.21 Farklı frekanslarda genliğin zamana bağlı değişimi (enkaz boş, nefes sinyali, hareket sinyali)

3.3.2 Saha Ortamında Toplanan Veri

Saha ölçümleri, İstanbul AFAD Birlik Müdürlüğü bünyesinde yer alan ve arama kurtarma eğitim sahası olarak kullanılan dört farklı gerçek enkaz üzerinde gerçekleştirilen kapsamlı çalışmalarla başlamıştır. Bu enkazlar, betonarme yapı özelliklerine gerçekçi ölçüde yaklaşan farklı malzeme bileşimleri, kalınlıklar, yoğunluklar ve çelik donatı içeren katmanlı beton bloklarla inşa edilmiştir. Dolayısıyla, laboratuvar ortamındaki enkaz modeline kıyasla çok daha büyük boyutlara ve çok katmanlı bir yapıya sahip olan bu enkazlar, sinyalin yayılım ve zayıflama özelliklerine dair daha karmaşık senaryolar sunmaktadır. Yapı malzemelerinin ve enkazın derinlik ile genişlik ölçülerinin fazlalığı, enkaz altı



Şekil 3.22 Farklı frekanslarda fazın zamana bağlı değişimi (enkaz boş, nefes sinyali, hareket sinyali)

tespit çalışmalarında karşılaşılan zorlukları gerçek ortama yakın şekilde yansıtarak, ölçümlerde yüksek seviyede gürültü ve sinyal kısıtlamalarına yol açmaktadır.

Söz konusu dört farklı enkazda yapılan saha ölçümleri sırasında, hem sinyalin algılama performansını hem de enkaz altı tespit sisteminin güvenilirliğini artıracak veri toplama stratejileri uygulanmıştır. Bu stratejiler kapsamında, çeşitli anten konfigürasyonları ve farklı frekanslar kullanılarak enkaz altındaki canlı ya da cansız varlıkların tespitine yönelik çok sayıda tekrar kaydı alınmıştır. Bu kayıtlar, enkaz alanının farklı noktalarında ve farklı derinliklerde gerçekleştirilerek, enkaz altı tespit algoritmalarının değişken koşullara verdiği tepkilerin incelenmesine olanak tanımıştır. Özellikle, çelik içeren beton blokların ve çok katmanlı yapıların oluşturduğu etkiler, alınan sinyallerde önemli miktarda zayıflama ve gürültüye sebep olmaktadır. Bu durum, saha koşullarında yapılan ölçümlerin laboratuvar ortamında elde edilen sonuçlardan belirgin biçimde farklılaşmasına neden olmuş ve daha kapsamlı veri işleme ve sinyal iyileştirme tekniklerinin uygulanmasını gerektirmiştir.

Gerçek enkazların fiziki koşullarına ek olarak, AFAD sahasındaki çevresel etmenler de ölçümlerin güvenilirliğini ve doğruluğunu doğrudan etkilemiştir. Örneğin, saha içindeki diğer faaliyetler, araç trafiği, hava koşulları ve enkaz yüzeyindeki düzensizlikler gibi faktörler, sinyallerde ek gürültü veya yansıma örüntüleri oluşturmuştur. İstanbul Yeşilköy'de bulunan Atatürk Havalimanı'na yakın olan sahada uçakların kalkışı, inişi ve hava sahasında kullanılan haberleşme ağlarının da sinyaller üzerinde bozucu etkisi olmuştur. Bu süreçte, alınan tekrar kayıtlar, söz konusu istenmeyen etkileri ayrı ayrı analiz edebilmek adına önemli bir temel

sağlamıştır.

Yapılan saha ölçümleri sonucunda ortaya çıkan veri seti, farklı frekans bantlarında, değişik anten açılarında, çeşitli malzeme yoğunluğu ve kalınlığındaki beton blokların etkisini incelemeye elverişli bir çerçeve sunmaktadır. İstanbul AFAD Birlik Müdürlüğü'nde yer alan dört farklı gerçek enkaz üzerinde yürütülen uzun süreli ve çok yönlü saha ölçümleri, laboratuvar ortamında geliştirilen modellerin ve algoritmaların gerçek uygulamalara uyarlanmasında önemli bir referans noktası oluşturmaktadır.

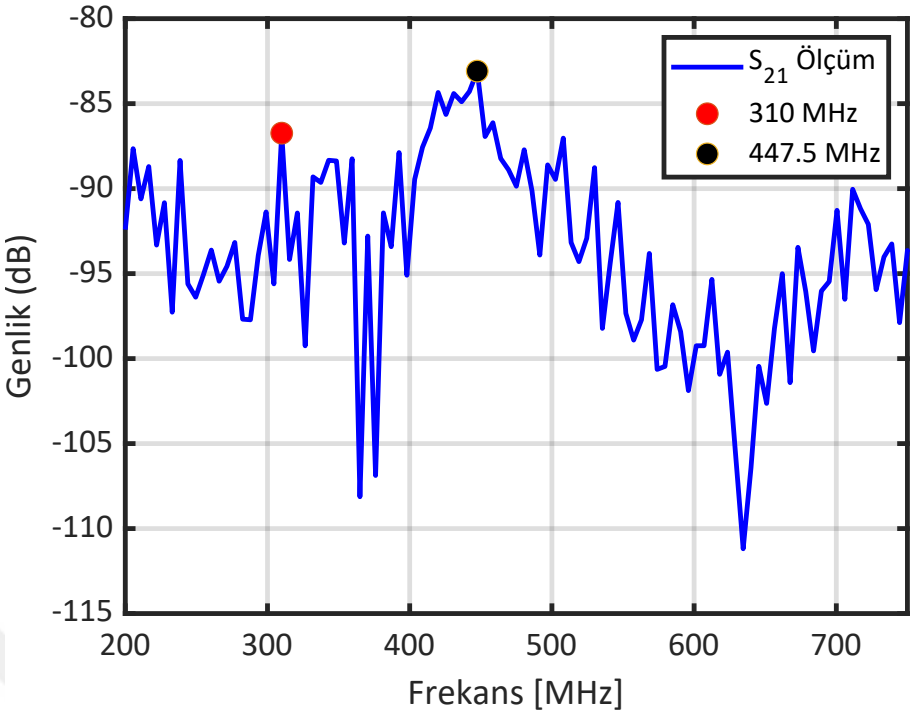
Saha ölçümleri neticesinde farklı problemleri tespit etmeye yönelik tekrarlı kayıtlar alınan ve tespit modelinde kullanılan veri seti; verici anten *horn*, alıcı anten *bowtie* iken ve antenler arası mesafe 657 cm iken 310 MHz ve 447.5 MHz frekansları seçilerek kaydedilmiştir. AFAD sahasında, yaşları 20 ile 27 arasında, boyları 170 ile 182 cm arasında ve ağırlıkları 65 ile 99 kg arasında değişen toplam dört farklı kişi enkaz içerisindeyken kayıt alınmıştır. Enkaz alanında canlı varken ve yokken ölçümler gerçekleştirilmiştir. Her kayıt, 60 saniyelik bir zaman dilimini temsil eden ve 1×4800 boyutlarında bir vektörle ifade edilen bilgileri içermektedir.

Bu veri setinin kaydedildiği gün enkaz ortamının zayıflama analizi Şekil 3.23'te verilmektedir. Şekil 3.23'ten görülebileceği üzere frekans bandındaki en yüksek genlikler seçilmiştir. S_{21} değeri 310 MHz'de -86.7 dB ve 447.5 MHz'de ise -83 dB değerindedir. Yükseltici kullanılmasına rağmen laboratuvar ortamına kıyasla sinyalin oldukça zayıfladığı görülmüştür.

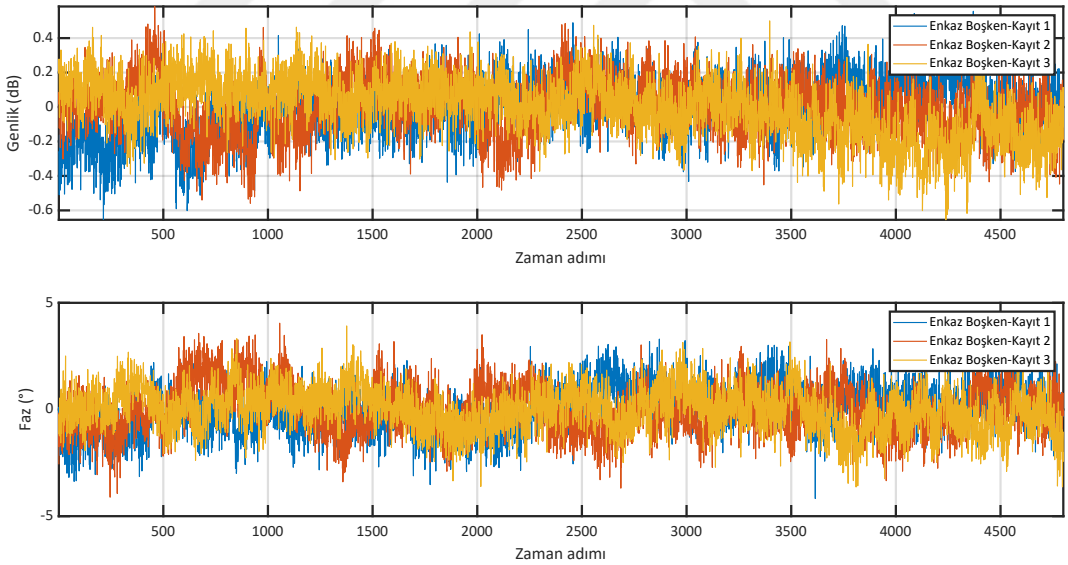
Şekil 3.24 ve Şekil 3.25'te, enkaz içerisinde kimse bulunmadığı durumda sırasıyla 310 MHz ve 447.5 MHz frekanslarında kaydedilen zamana bağlı genlik ve faz değişimleri gösterilmektedir. Bu iki şekilde de, herhangi bir canlı kaynağın olmamasından dolayı yalnızca çevresel gürültü ve sistem bileşenlerinin neden olduğu düşük seviyeli sinyal değişimleri gözlemlenmektedir.

Şekil 3.26 ve Şekil 3.27 ise enkaz içinde bir kişi bulunurken, bu kişinin yalnızca derin nefes alması sonucunda (gövdesini veya uzuvlarını kıpırdatmaksızın) 310 MHz ve 447.5 MHz frekanslarında kaydedilen genlik ve faz değişimlerini sunmaktadır. Bu durumda, derin nefes hareketi genlik ve faz sinyallerinde daha düzenli ve periyodik bir dalgalanma yaratmakta, enkaz altı canlı tespitinde solunum kaynaklı işaretlerin tespit edilebilirliğinin zorluğunu ortaya koymaktadır.

Şekil 3.28 ve Şekil 3.29'da ise, yine 310 MHz ve 447.5 MHz frekansları için, göğsünü belirgin biçimde hareket ettirerek nefes alan bir katılımcının oluşturduğu genlik ve faz değişimleri yer almaktadır. Bu durumda, derin nefese ek olarak göğüs



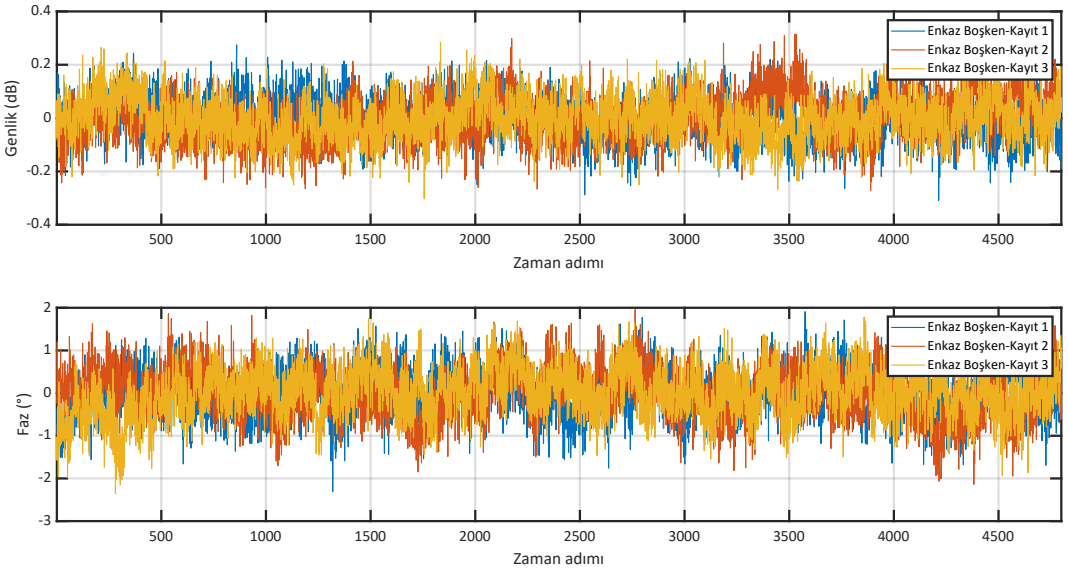
Şekil 3.23 Enkaz altı canlı tespiti için sahada (çift katlı enkaz) bulunan enkaza ait yükseltici kullanılarak elde edilen zayıflama analizi (antenler arası mesafe = 657 cm)



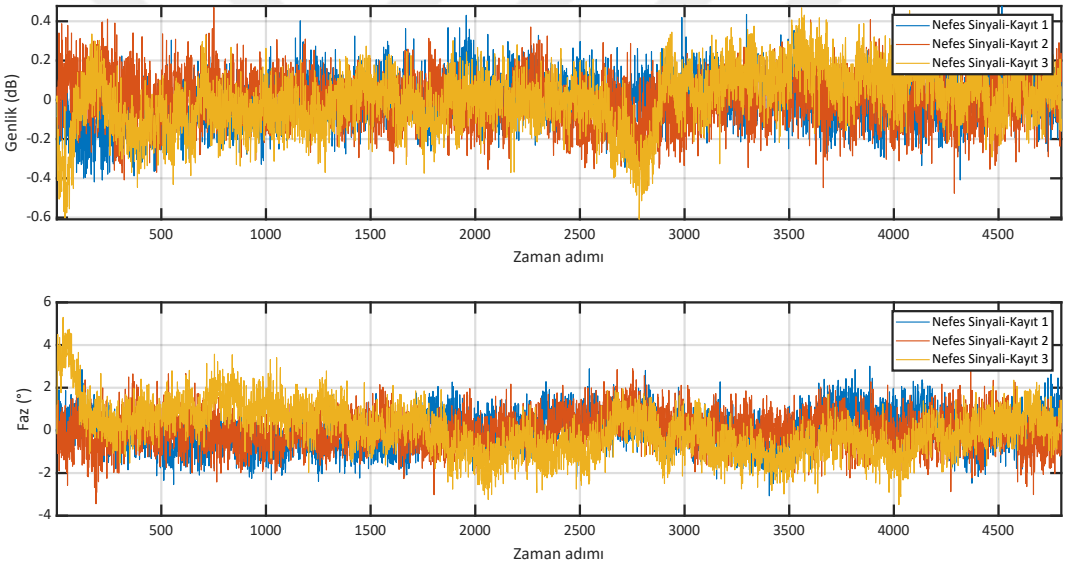
Şekil 3.24 Enkaz boşken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri

kafesindeki daha büyük hareket genlikte gözle görülür artışlar oluşturmakta ve faz kaymasında da daha belirgin dalgalanmalara yol açmaktadır.

Şekil 3.30 ve Şekil 3.31'de, 310 MHz ve 447.5 MHz frekansları için rastgele el ve/veya ayak hareketleri yapan bir katılımcının sinyal üzerindeki etkileri gösterilmektedir. Bu tür düzensiz ve ani hareketler, özellikle genlik sinyalinde daha



Şekil 3.25 Enkaz boşken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri

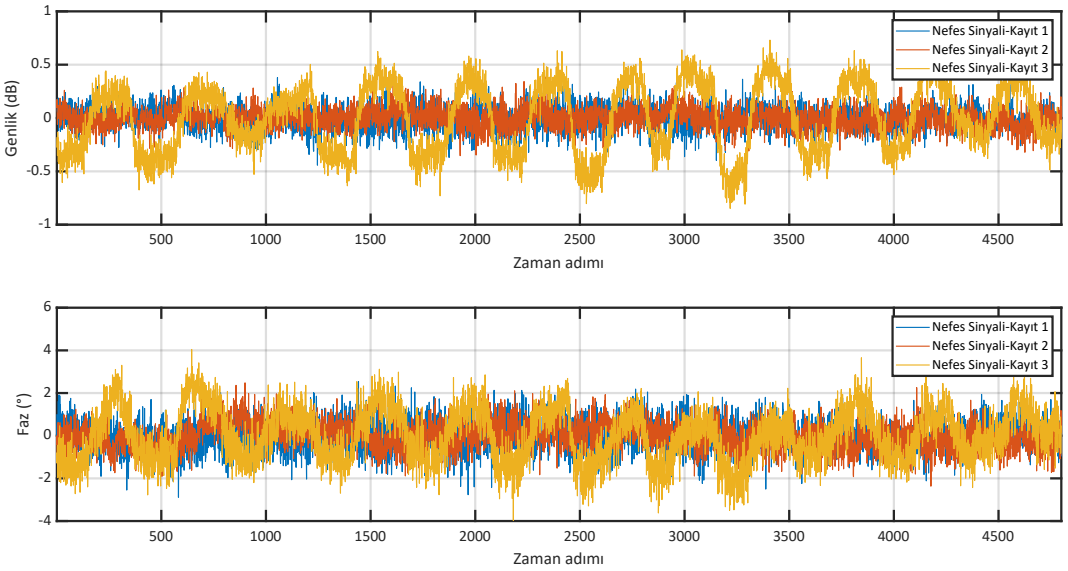


Şekil 3.26 Enkaz içinde derin nefes alan biri varken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri

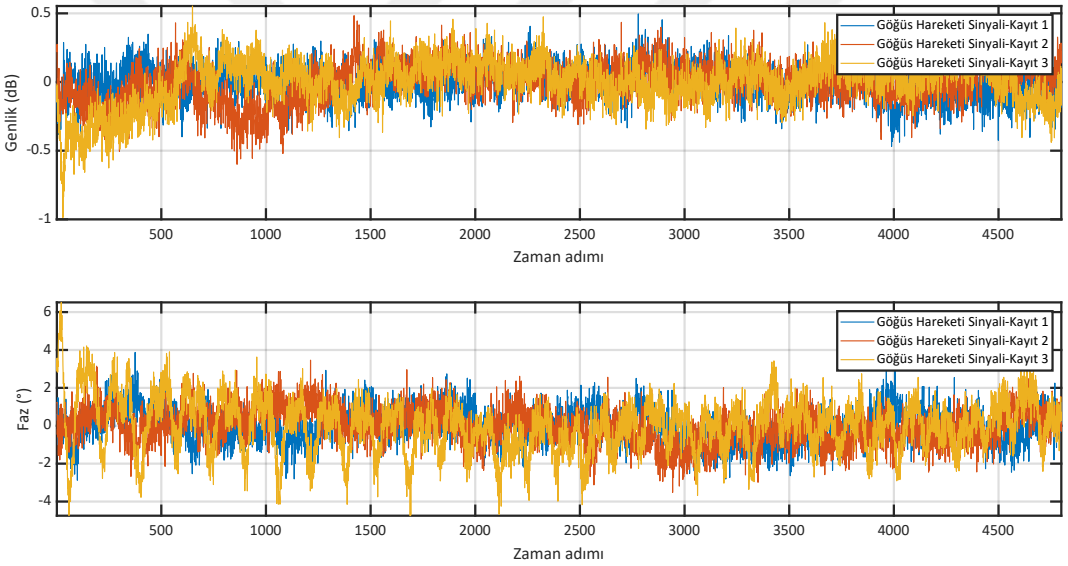
keskin sıçramalar ve fazda hızlı değişimler şeklinde ortaya çıkmaktadır.

Son olarak, Şekil 3.32 ve Şekil 3.33 enkaz içinde zaman zaman yakındaki bir duvara vuran ve sonrasında hareketsiz kalan bir katılımcının 310 MHz ve 447.5 MHz frekanslarında kaydedilen sinyallerini içermektedir. Duvara vurma hareketi, sinyalde kısa süreli yüksek genlikli tepe noktaları oluşturmakta, ardından katılımcının kıpırdamadığı zamanlarda genlik ve faz değişimlerinin nispeten durağan hale dönüştüğü görülmektedir.

Şekil 3.34'te, enkazın boş olduğu durumla birlikte nefes, göğüs hareketi, rastgele



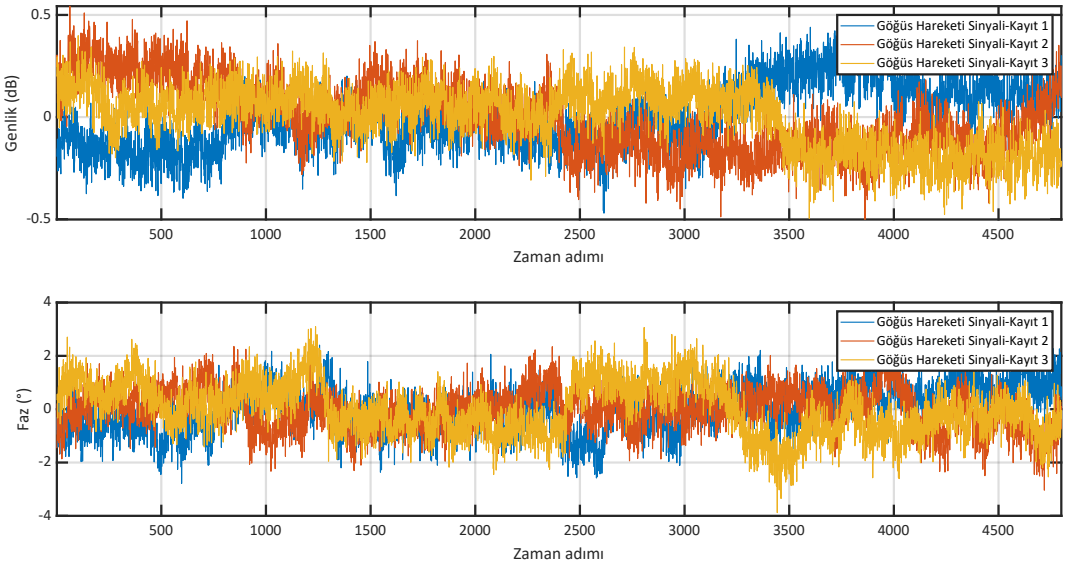
Şekil 3.27 Enkaz içinde derin nefes alan biri varken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri



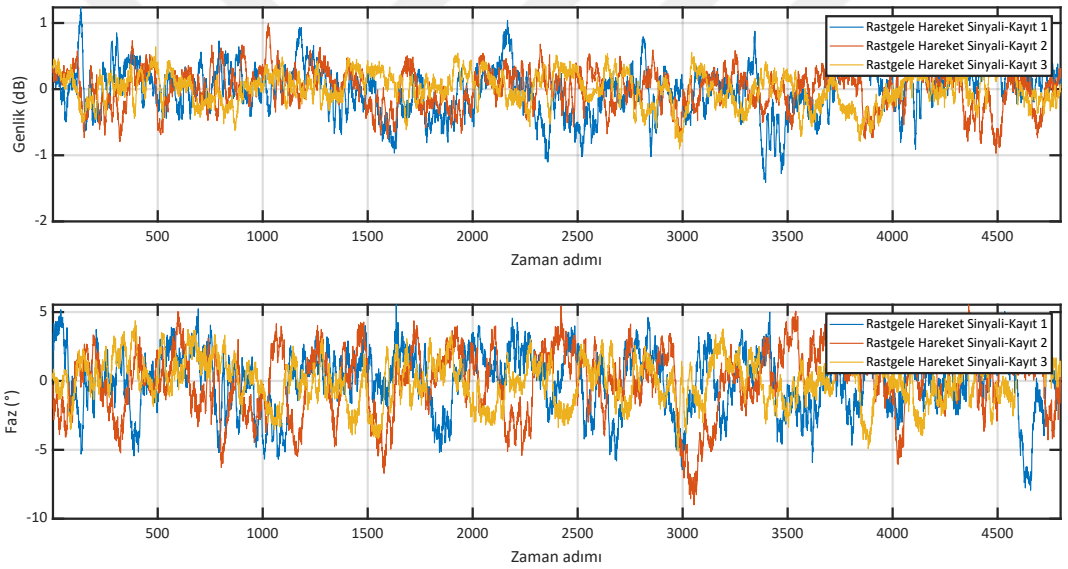
Şekil 3.28 Enkaz içinde göğsünü hareket ettiren biri varken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri

hareket ve duvara vurma senaryolarının farklı frekanslardaki genlik değişimleri bir arada sunulmaktadır. Böylece, çeşitli insan hareketlerinin ve solunum örüntülerinin genlik bileşenine olan etkisi karşılaştırmalı olarak incelenebilmekte, farklı frekanslarda ortaya çıkan değişimlerin benzerlik ve farklılıkları net biçimde görülebilmektedir.

Buna paralel olarak, Şekil 3.35'te aynı senaryoların faz bileşeni üzerinde yarattığı zamana bağlı değişimler gösterilmektedir. Faz kaymalarının genliğe göre daha hassas ve bazen daha belirgin izler sunması, özellikle hareketsiz duruşla ani hareket arasındaki geçişlerin tespitinde önemli bir farklılık sağlasa da diğer sinyaller

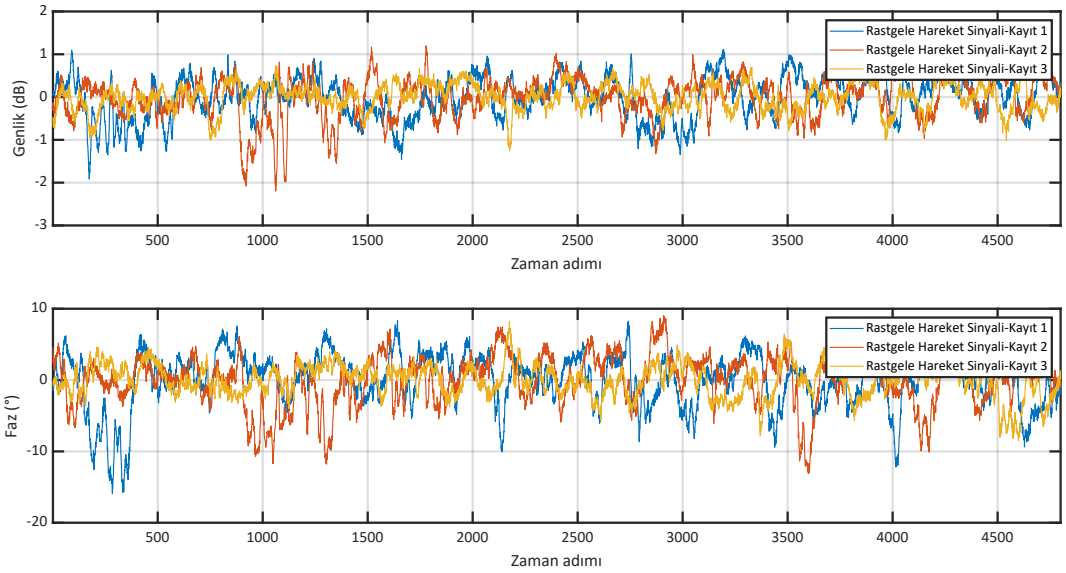


Şekil 3.29 Enkaz içinde göğsünü hareket ettiren biri varken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri

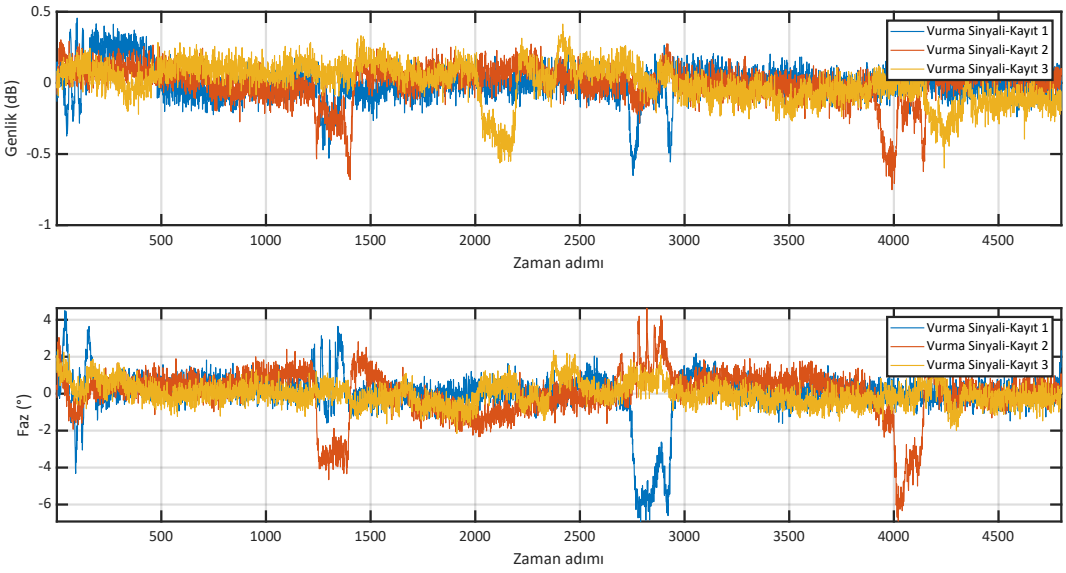


Şekil 3.30 Enkaz içinde rastgele hareket eden biri varken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri

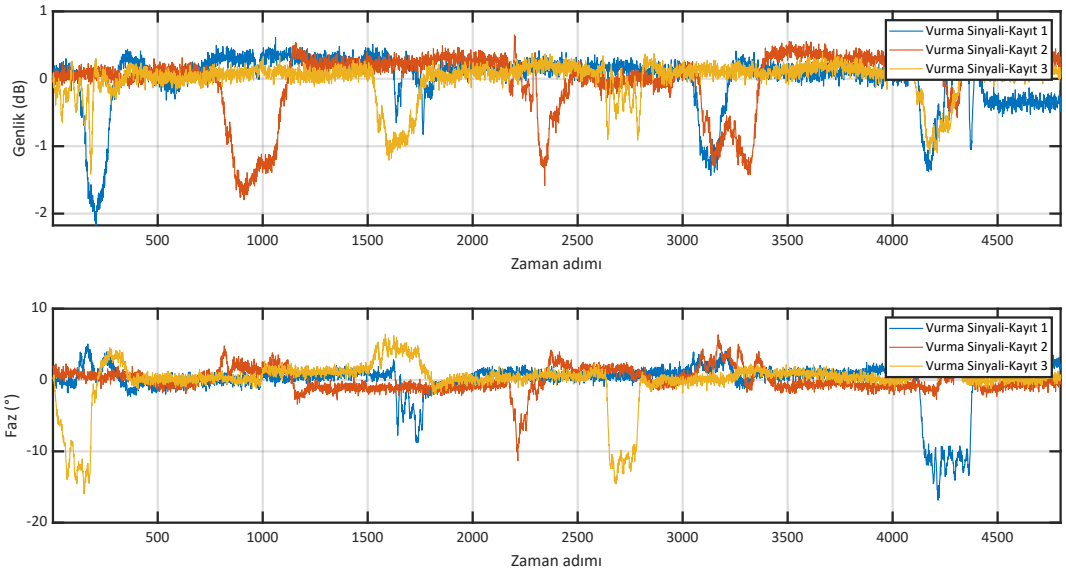
birbirine oldukça benzer olduğu görülmektedir.



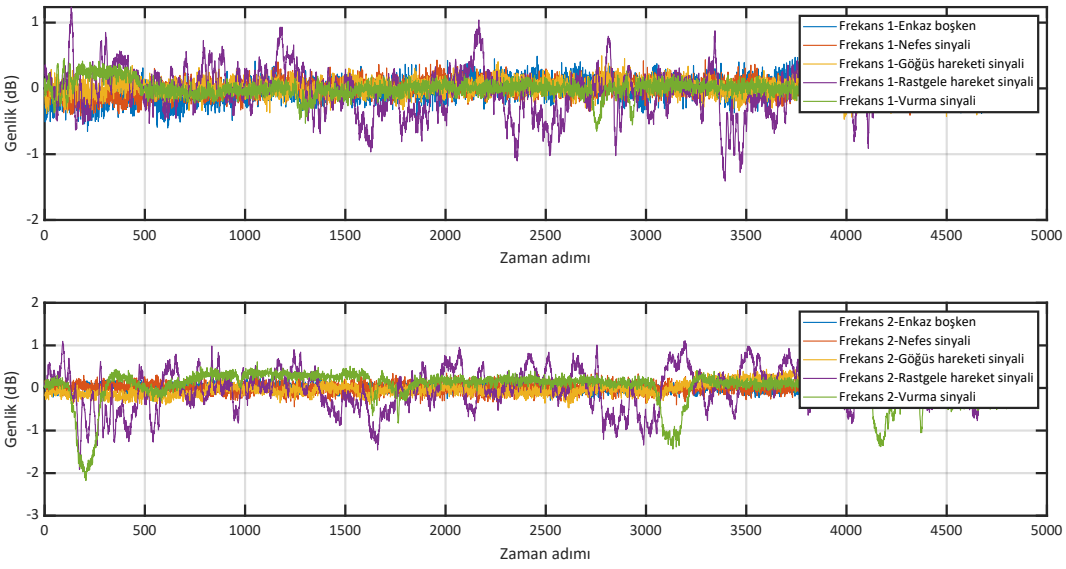
Şekil 3.31 Enkaz içinde rastgele hareket eden biri varken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri



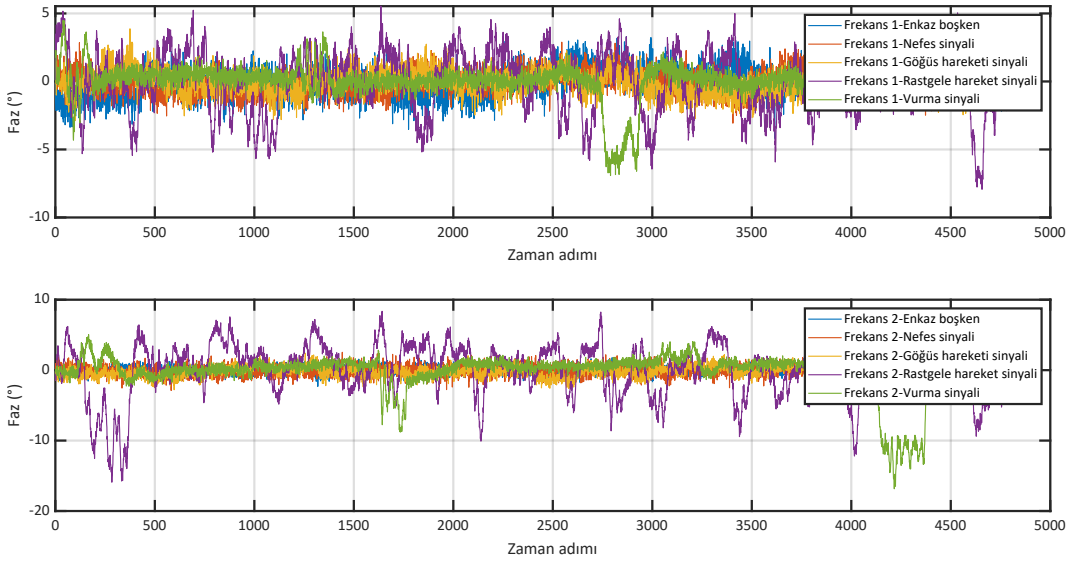
Şekil 3.32 Enkaz içinde ara sıra duvara vuran biri varken 310 MHz frekansında zamana bağlı genlik ve faz değişimleri



Şekil 3.33 Enkaz içinde ara sıra duvara vuran biri varken 447.5 MHz frekansında zamana bağlı genlik ve faz değişimleri



Şekil 3.34 Farklı frekanslarda genliğin zamana bağlı değişimi (enkaz boş, nefes sinyali, göğüs hareketi sinyali, rastgele hareket sinyali, vurma sinyali)



Şekil 3.35 Farklı frekanslarda fazın zamana bağlı değişimi (enkaz boş, nefes sinyali, göğüs hareketi sinyali, rastgele hareket sinyali, vurma sinyali)

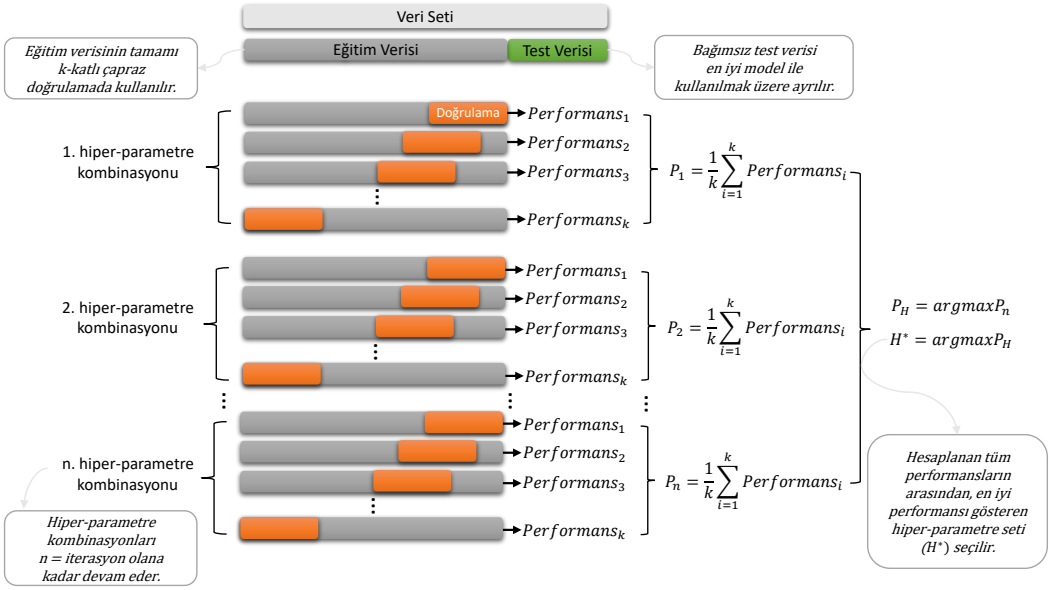
4
CANLI TESPİTİ

Bu bölümde, derin öğrenme tekniklerine dayalı enkaz altı canlı tespiti için yürütülen çalışmalar ayrıntılı biçimde ele alınmaktadır. Gerçek ortama ve farklı senaryolara uyarlama hedefi doğrultusunda, öncelikle benzetim ortamından elde edilen veriler üzerinde, ardından laboratuvar ortamından kurulan enkaz modelinden ölçülen veriler üzerinde ve son aşamada AFAD'ın arama kurtarma eğitim sahasındaki gerçek enkaz alanından ölçülen veriler üzerinde tespit çalışmaları gerçekleştirilmiştir.

4.1 Derin Öğrenmede Model Doğrulama

Derin öğrenme modellerinin enkaz altı canlı tespitine yönelik özelleştirilebilmesi amacıyla model doğrulama yapılırken, hiperparametre optimizasyonunda rastgele arama (*random search*) yöntemi ve eğitim sürecinde k-katlı çapraz doğrulama (k*-fold cross validation*) yaklaşımı bir arada kullanılmıştır. Şekil 4.1'de bu tez çalışmasında kullanılan model oluşturma yöntemine ait genel yapı gösterilmektedir. Hiperparametreler, bir yapay zeka modelinin performansını doğrudan etkileyen öğrenme oranı, katman sayısı ve filtre sayısı vb. gibi değerlerdir.

N_{toplam} adet örnekten oluşan veri seti, öncelikle eğitim *(training)* verisi ve test verisi olarak ikiye bölünür. Test verisi, herhangi bir hiperparametre seçimi sürecine dahil edilmez; yalnızca en iyi hiperparametreleri bulduktan sonra modelin gerçek başarımını ölçmek için kullanılır. Böylece geliştirilen modelin, eğitim sırasında hiç karşılaşmadığı örnekler üzerinde gösterdiği performans ortaya konmaktadır. Hiperparametre kombinasyonları veriye ve modele özgü olarak belirlenmiş olan aralığın içerisinden rastgele seçilir ve 1'den n'e kadar bu döngü devam eder. Bu döngünün her bir adımı içerisinde ise; eğitim verisi k eşit parçaya *(fold)* ayrılır. Her bir hiperparametre kombinasyonu için sırasıyla her bir parça, doğrulama *(validation)* için kullanılırken kalan $(k-1)$ parça eğitim için kullanılır. Seçilen hiperparametrelerle model, $(k-1)$ fold üzerinde eğitilir ve ayrılan bir fold üzerinde



Şekil 4.1 Derin öğrenme modellerini oluşturmaya yönelik genel yapı

performans metriği hesaplanır ve bu işlem tüm k fold için tekrarlanır. Her bir hiperparametre kombinasyonu için, tüm parçalarda elde edilen performanslar toplanarak ortalaması alınır. Hiperparametre kombinasyonlarının tümü (n'e kadar döngü) tamamlandığında, tüm kombinasyonlar arasından en yüksek ortalama performansa sahip olan kombinasyon seçilir. Seçilen en iyi hiperparametrelerle model, eğitim verisinin tamamı kullanılarak tekrar eğitilir. Ayrılmış test verisi bu modele sunulur ve modelin gerçek genelleme başarımı ölçülür. Sonuç olarak, rastgele arama yöntemi ile k-katlı çapraz doğrulamanın bir arada kullanılması, hiperparametrelerin veriye özgü biçimde optimize edilmesini ve derin öğrenme modelinin geliştirilmesini sağlar.

Tüm bu çalışmalar ve hesaplamalar, Intel XEON W-1250 4.7 GHz işlemci, 128 GB RAM, 512 GB SSD ve RTX A2000 GPU donanımına sahip bir Windows 10 Pro işletim sistemi yüklü iş istasyonunda gerçekleştirilmiştir.

4.2 Performans Metrikleri

Tez çalışmasında kullanılan performans metrikleri; doğruluk *(accuracy)*, kesinlik *(precision)*, duyarlılık *(recall)* ve F1-skoru gibi sınıflandırıcıları değerlendirmek için en sık kullanılan metriklerdir. Doğruluk, sınıflandırma görevlerinde temel bir ölçüt olarak, toplam örnekler arasındaki doğru sınıflandırılmış örneklerin oranını temsil etmektedir ve Denklem (4.1)'de verilmiştir [94]. Denklem (4.2)'te verilen kesinlik, bir sınıflandırıcının doğruluğunu ölçen bir metriktir ve pozitif olarak tahmin edilen tüm örnekler arasında gerçek pozitif tahminlerin oranını

yansıtır. Duyarlılık, sınıflandırıcının tamamlayıcılığını değerlendirir ve gerçek pozitif örneklerin tüm gerçek pozitifler içindeki oranını gösterir, Denklem (4.3)'te verilmiştir. F1-skoru, Denklem (4.4)'de verilmiştir.

$$\text{Doğruluk} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \tag{4.1}$$

$$\text{Kesinlik} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{4.2}$$

$$\text{Duyarlılık} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{4.3}$$

$$\text{F1-Skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \tag{4.4}$$

4.3 Solunum Sinyalleri ile Ön Çalışma

İlk olarak canlı tespitine yönelik temel çalışmalar Bölüm 3.2.1'de yer verilen ön çalışmaya ait veri seti ile yapılmıştır. Veri setinin $\%80$'i eğitim ve doğrulama için, kalan $\%20$'si ise nihai test kümesi olarak ayrılmıştır (N_{toplam} = 80). İkinci aşamada, eğitim ve doğrulama verileri üzerinde 4-katlı çapraz doğrulama uygulanarak, her modelin farklı veri alt kümelerinde eğitilmesi ve doğrulanması sağlanmıştır. LSTM modeli için, zamansal bağımlılıkları etkin bir şekilde öğrenebilmesi adına LSTM birim sayısı 50 ile 200 arasında rastgele seçilmiştir. Öğrenme oranı, 10^{-2} ile 10^{-4} arasında seçilmiştir. Ek olarak, eğitim sürecinin verimliliğini artırmak amacıyla mini-batch boyutu 2^3 ile 2^6 arasında, maksimum deneme sayısı ise 30 ile 100 arasında belirlenmiştir. Elde edilen modellerin performans metrikleri Tablo 4.1 ve Tablo 4.2 ile sunulmaktadır.

Tablo 4.1 Solunum sensörü verileri için farklı derin öğrenme modellerinin performans karşılaştırması (doğrulama ve test)

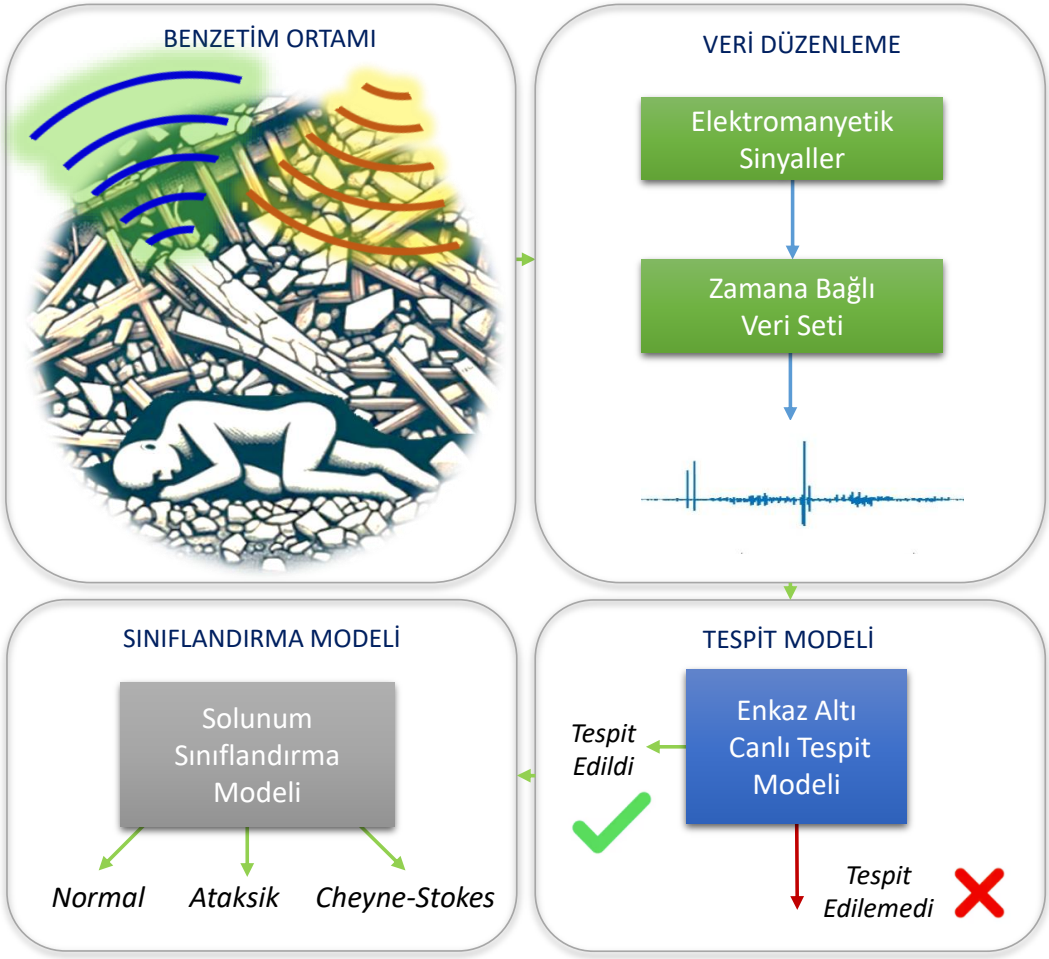
Model	**Doğruluk Oranı [%]**	
	Doğrulama	**Test**
1D-CNN	97.92	100
LSTM	75	81.25
TCN	100	93.75

Tablo 4.2 Solunum sensörü verileri için farklı derin öğrenme modellerinin performans metrikleri

Model	**Kesinlik**	**Duyarlılık**	**F1-Skoru**	**Doğruluk**
1D-CNN	1	1	1	1
LSTM	0.62	1	0.77	0.81
TCN	0.87	1	0.93	0.93

4.4 Benzetim Ortamında Oluşturulan Veriler ile Canlı Tespiti

Bölüm 3.2.2'de yer verilen benzetim verileri ile oluşturulan tespit modeline ait genel diyagram Şekil 4.2 ile verilmektedir. Benzetim ortamından elde edilen tespit modeli ve sınıflandırma modeline ait zamana bağlı veriler, TCN algoritması kullanılarak sınıflandırılmıştır. Tespit modeli ve sınıflandırma modelinde eşit sayıda örnek bulunmaktadır (N_{toplam} = 50). Veri seti %80 oranında eğitim verisine ve %20 oranında ise test verisine ayrılmıştır. n = 100 iterasyon boyunca Tablo 4.3 ile verilen hiperparametre aralığında, 5-katlı çapraz doğrulama yapılmıştır. Oluşturulan nihai model ile elde edilen performans sonuçları Tablo 4.4 ile verilmektedir [26].



Şekil 4.2 Benzetim ortamında oluşturulan veriler ile canlı tespit modeli

Tablo 4.3 TCN ağının hiperparametre aralığı

Genişleme Faktörü	Filtre Boyutu	Filtre Sayısı	Dropout Oranı	Mini Batch Boyutu	Optimizasyon Yöntemi
1-16	3-15	2-64	0.1-0.8	1-4	Adam

Tablo 4.4 Benzetim ortamında oluşturulan veriler ile canlı tespit modelinin sonuçları (TCN)

f	SNR	Başarım Oranı (TCN) [%]		
[MHz]	[dB]	En Düşük	En Yüksek	Ortalama
170	10	77.78	78.69	78.14
170	20	80.8	85.92	82.93
170	30	95.54	97.31	96.52
290	10	98.39	99.68	99.3
290	20	99.93	99.97	99.96
290	30	99.95	99.98	99.97
410	10	99.73	99.8	99.74
410	20	99.82	99.94	99.87
410	30	97.73	99.85	99.42
530	10	97.65	98.91	98.47
530	20	97.47	99.13	98.48
530	30	99.8	99.93	99.86
650	10	95.42	97.54	96.77
650	20	98.39	99.45	99.15
650	30	95.24	97.11	95.97

Tablo 4.5 Benzetim ortamında oluşturulan veriler ile solunum sınıflandırma modelinin sonuçları

f [MHz]	SNR	Başarım Oranı (MLP) [%]			Başarım Oranı (TCN) [%]		
[MHz]	[dB]	En Düşük	En Yüksek	Ortalama	En Düşük	En Yüksek	Ortalama
170	10	76.67	83.33	80.67	74.03	75.44	74.62
170	20	83.33	86.67	86.00	82.79	86.41	84.69
170	30	83.33	90.00	86.67	80.06	90.04	85.36
290	10	83.33	90.00	86.00	89.21	91.72	90.73
290	20	76.67	83.33	79.33	98.44	99.66	99.38
290	30	80.00	83.33	80.67	99.59	99.73	99.69
410	10	80.00	90.00	86.67	77.76	82.94	80.47
410	20	86.67	93.33	90.00	97.92	99.32	98.90
410	30	76.67	86.67	82.00	96.52	96.80	96.62
530	10	83.33	93.33	87.33	90.35	91.26	90.95
530	20	80.00	90.00	85.33	72.60	77.70	75.49
530	30	83.33	96.67	89.33	90.15	95.50	93.18
650	10	96.67	96.67	96.67	71.54	95.76	89.46
650	20	80.00	86.67	84.00	94.41	95.64	94.93
650	30	86.67	93.33	90.00	96.18	98.60	97.53

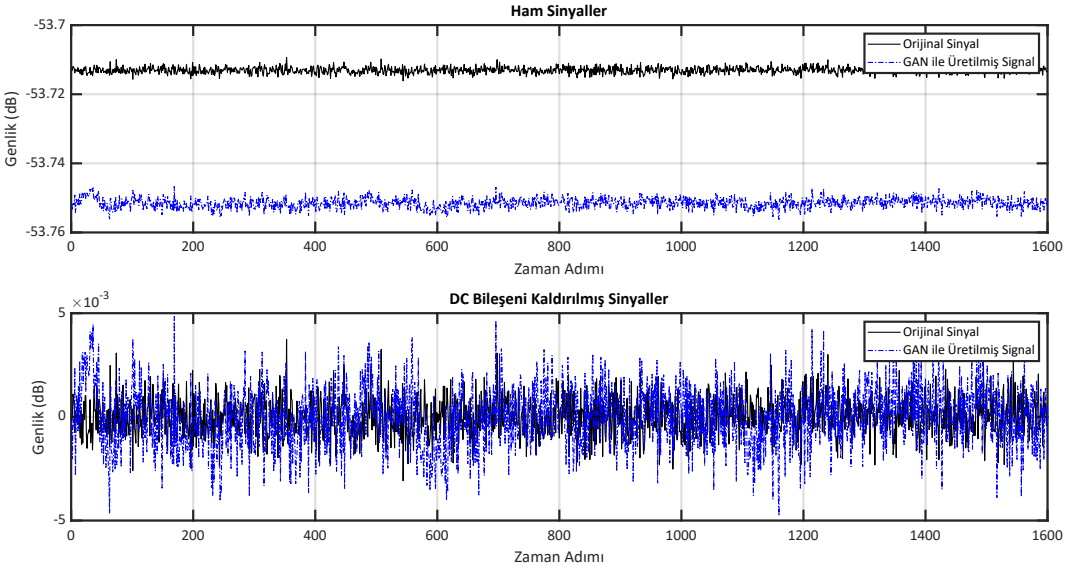
4.5 Laboratuvar Ortamında Toplanan Veriler ile Canlı Tespiti

Bölüm 3.3.1'de sunulan veriler, üç farklı frekansta ve toplam 1 dakika süreyle kaydedilmiş olup, her biri 20 saniye süren ve 1600 zaman adımı içeren kayıtlardan oluşmaktadır. Verilerin mümkün olduğunca ham haliyle kullanılabilmesi için yalnızca gürültü giderme, π değerini aşan faz düzeltme ve DC bileşen kaldırma işlemleri uygulanmıştır. Ardından, sinyaller zamana bağlı olarak yeniden düzenlenerek 40 saniyelik vektörler oluşturulmuştur. Bu yapılandırmada, ilk 20 saniyelik bölümde enkazda herhangi bir kişi bulunmazken, sonraki 20 saniyelik bölümde tespit edilmek istenen durum (solunum veya hareket) mevcuttur. Genlik ve faz değişimlerini ayrı vektörler olarak ele alan bu ön çalışmada, frekansın etkisini değerlendirmek amacıyla farklı frekanslardaki veriler ayrı ayrı incelenmiştir. Enkaz boşken toplanan 20 adet ham veri bulunduğundan; sınıflarda eşit sayıda örnek olması için toplam 20 farklı kişiden, bir farklı pozisyonda alınan 20 adet sinyal kullanılmıştır. (N_{toplam} = 40). Veri seti $\%80$ oranında eğitim verisine ve $\%20$ oranında ise test verisine ayrılmıştır. $n = 10$ iterasyon boyunca, filtre sayısı $2 - 32$, mini-batch boyutu $1 - 8$, filtre boyutu $1 - 9$, dropout faktörü $0.1 - 0.8$, blok sayısı $1-5$ aralığında rastgele seçilerek 4-katlı çapraz doğrulama yapılmıştır. Tablo 4.6'da gösterildiği üzere, ön işleme yapılmadan zamana bağlı olarak alınan sinyallerle oluşturulan modellerde, hareket tespitinde $\%99.88$ gibi yüksek bir doğruluk oranına ulaşılmış olsa da nefes tespiti konusunda kayıplar meydana gelebileceği gözlemlenmiştir. Nefes tespitinde $\%55.03$ gibi düşük doğruluk oranlarının elde edilmesinin başlıca nedenleri arasında, nefes sinyali ile gürültü sinyalinin birbirine yakın olması ve veri setindeki toplam örnek sayısının (N_{toplam}) yetersiz olması yer almaktadır. *(Bu doğruluk oranları, sıralı veri kullanılarak tek çıktı tahmini yapılmasıyla elde edilmiştir.)*

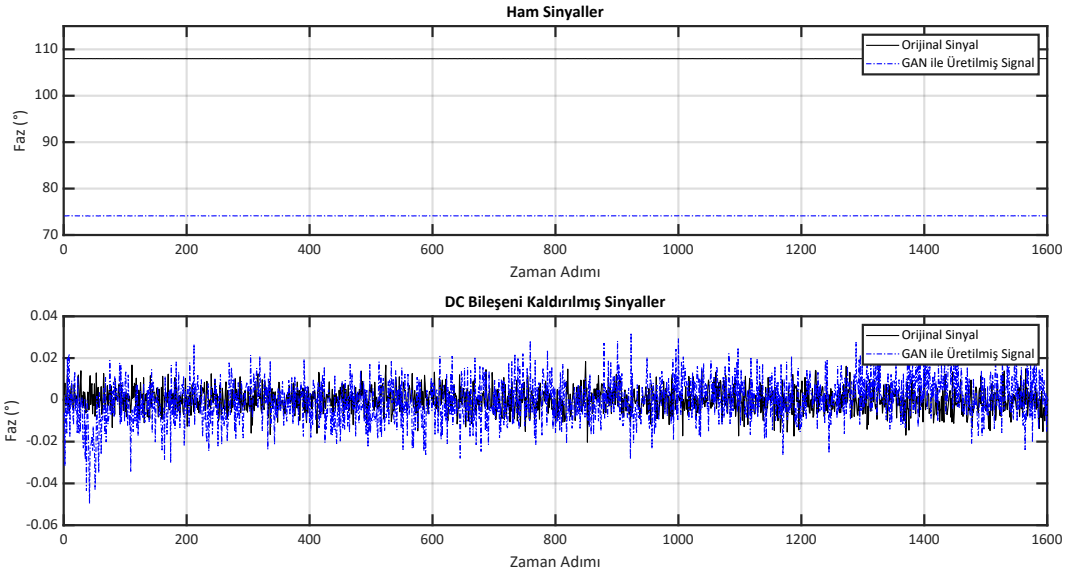
Tablo 4.6 Laboratuvar ortamında toplanan veriler ile tespit sonuçları (TCN)

Problem	**Sınıf 1**	**Sınıf 2**	f **[MHz]**	**D/T**	**Doğruluk Oranı [%]**
Nefes Tespiti	Boş Enkaz	Nefes	210	Doğrulama Test	63.62 55.03
Nefes Tespiti	Boş Enkaz	Nefes	332.5	Doğrulama Test	85.93 72.72
Nefes Tespiti	Boş Enkaz	Nefes	505	Doğrulama Test	85.85 85.35
Hareket Tespiti	Boş Enkaz	Hareket	210	Doğrulama Test	95.67 88.95
Hareket Tespiti	Boş Enkaz	Hareket	332.5	Doğrulama Test	99.06 99.75
Hareket Tespiti	Boş Enkaz	Hareket	505	Doğrulama Test	96.98 99.88

Böylece enkaz boşken yani ortamın gürültüsü varken toplanan veri sayısının artırılması gerekliliği ortaya konmuştur. Fakat laboratuvar ortamında enkaz içerisine insan yerleştirerek gerçekleştirilen veri toplama süreci oldukça zaman alıcı olduğu için enkaz boş iken alınan ölçümler de kısıtlı kalmıştır. Bu sorunu gidermek amacıyla, boş enkaz örneklerinin sayısı GAN kullanılarak beş kat artırılmış ve veri seti sentetik örneklerle genişletilmiştir. Bu genişletmenin eğitim sırasında, gerçek veriler $[-1, 1]$ aralığında normalize edilmiştir ve döngü sayısı 5000 olarak belirlenmiştir. Bu yöntem sayesinde, Şekil 4.3 ve Şekil 4.4'te gösterildiği gibi genlik ve faz değerlerinde veri artırımı gerçekleştirilmiştir.



Şekil 4.3 Orijinal sinyal ve GAN ile üretilmiş sinyal (genlik)



Şekil 4.4 Orijinal sinyal ve GAN ile üretilmiş sinyal (faz)

Toplam 20 farklı kişiden, 6 farklı pozisyonda alınan 120 adet sinyalin kombinasyonundan yararlanılarak Tablo 4.7 ile verilen kapsamlı sınıflandırma

problemleri belirlenmiştir. Nefes tespiti için boş enkaz verileri ile kişinin enkaz altında nefes aldığı veriler aynı problemde, hareket tespiti için ise boş enkaz verileri ile kişinin enkaz altında hareket ettiği veriler aynı problemde birleştirilmiştir. Bir kişinin enkaz altında nefes aldığı veya hareket ettiği önceden belirlenebilir bir durum olmadığı için boş enkazla birlikte canlının her iki durumunun varlığı da üç sınıftan oluşan problemde bir araya getirilmiştir.

Tablo 4.7 Laboratuvar ortamında toplanan veriler ile oluşturulan kapsamlı sınıflandırma problemleri

ID	Problem	Sınıf 1	Sınıf 2	Sınıf 3	N_{toplam}	f [MHz]
1	Nefes Tespiti	Boş Enkaz	Nefes	–	240	210
2	Hareket Tespiti	Boş Enkaz	Hareket	–	240	210
3	Canlı Tespiti	Boş Enkaz	Nefes	Hareket	360	210
4	Nefes Tespiti	Boş Enkaz	Nefes	–	240	332.5
5	Hareket Tespiti	Boş Enkaz	Hareket	–	240	332.5
6	Canlı Tespiti	Boş Enkaz	Nefes	Hareket	360	332.5
7	Nefes Tespiti	Boş Enkaz	Nefes	–	240	405
8	Hareket Tespiti	Boş Enkaz	Hareket	–	240	405
9	Canlı Tespiti	Boş Enkaz	Nefes	Hareket	360	405

Tablo 4.7'de verilen problemlere ait verilere frekans tabanlı dönüşümler (EMD, STFT ve CWT) uygulanarak oluşturulan alt veri setleri, proje ekibi tarafından hazırlanmıştır. EMD uygulanmış veri seti LSTM ve TCN modellerinde, STFT ve CWT dönüşümleriyle elde edilen veriler ise CNN modelinde kullanılmıştır. Tez çalışması kapsamında oluşturulan, CNN ağının hiperparametre aralığı Tablo 4.8 ile, LSTM ağının hiperparametre aralığı Tablo 4.9 ile, TCN ağının hiperparametre aralığı Tablo 4.10 ile verildiği gibidir. $n = 100$ iterasyon boyunca optimize edilen derin öğrenme modelleri oluşturulurken, alt kümeler $\%80$ eğitim, $\%10$ doğrulama ve $\%10$ test amaçlı olarak ayrılmıştır. Tablo 4.11 ve Tablo 4.12 verilen performans metrikleri ile laboratuvar ortamında toplanan veriler ile canlı tespiti probleminin sinyal işleme ile birleştirilen derin öğrenme modelleri ile çözüldüğü ortaya konmuştur [95].

Tablo 4.8 CNN ağının hiperparametre aralığı

Filtre Boyutu	Gizli Katman Birimleri	Öğrenme Oranı	Mini-Batch Boyutu
2, 4, 8, 16, 32, 64, 128	16, 32, 64, 128	0.001–0.1	1, 2, 4, 8

Tablo 4.9 LSTM ağının hiperparametre aralığı

Mini-Batch Boyutu	Gizli Katman Birimleri	Öğrenme Oranı
1, 2, 4, 8	16, 32, 64, 128	0.001-0.1

Tablo 4.10 TCN ağının hiperparametre aralığı

Genişleme Faktörü	Filtre Boyutu	Filtre Sayısı	Dropout Oranı	Mini-Batch Boyutu	Optimizasyon Yöntemi
1–16	2–16	2, 4, 8, 16, 32, 64	0.1–0.8	1, 2, 4, 8	Adam

Tablo 4.11 Farklı derin öğrenme modellerinin çeşitli problemler üzerindeki performans metrikleri

No	Problem	f [MHz]	Model	Kesinlik	Duyarlılık	F1-Skor	Doğruluk
1	- Enkaz Boş - Solunum	210	TCN	0.66	0.89	0.76	0.79
			LSTM	0.81	0.90	0.86	0.87
			CNN (STFT)	0.92	1.00	0.96	0.96
			CNN (CWT)	0.90	0.90	0.91	0.92
2	- Enkaz Boş - Hareket	210	TCN	1.00	0.89	0.94	0.96
			LSTM	1.00	1.00	1.00	1.00
			CNN (STFT)	1.00	0.92	0.96	0.96
			CNN (CWT)	1.00	1.00	1.00	1.00
3	- Enkaz Boş - Solunum - Hareket	210	TCN	0.89	0.89	0.89	0.89
			LSTM	0.84	0.83	0.83	0.86
			CNN (STFT)	*	*	*	*
			CNN (CWT)	*	*	*	*
4	- Enkaz Boş - Solunum	332.5	TCN	1.00	0.85	0.92	0.92
			LSTM	1.00	1.00	1.00	1.00
			CNN (STFT)	1.00	0.92	0.96	0.96
			CNN (CWT)	1.00	0.91	0.95	0.95
5	- Enkaz Boş - Hareket	332.5	TCN	1.00	1.00	1.00	1.00
			LSTM	0.90	0.91	0.91	0.92
			CNN (STFT)	1.00	1.00	1.00	1.00
			CNN (CWT)	1.00	1.00	1.00	1.00
6	- Enkaz Boş - Solunum - Hareket	332.5	TCN	0.90	0.92	0.90	0.92
			LSTM	0.74	0.80	0.74	0.75
			CNN (STFT)	*	*	*	*
			CNN (CWT)	*	*	*	*
7	- Enkaz Boş - Solunum	405	TCN	1.00	0.92	0.96	0.96
			LSTM	1.00	1.00	1.00	1.00
			CNN (STFT)	0.92	0.92	0.92	0.92
			CNN (CWT)	0.92	0.92	0.92	0.92
8	- Enkaz Boş - Hareket	405	TCN	1.00	1.00	1.00	1.00
			LSTM	1.00	1.00	1.00	1.00
			CNN (STFT)	1.00	1.00	1.00	1.00
			CNN (CWT)	1.00	1.00	1.00	1.00
9	- Enkaz Boş - Solunum - Hareket	405	TCN	0.97	0.97	0.97	0.97
			LSTM	0.84	0.75	0.76	0.78
			CNN (STFT)	*	*	*	*
			CNN (CWT)	*	*	*	*

* Yüksek bellek gereksinimi nedeniyle performans metrikleri hesaplanamamıştır.

Tablo 4.12 Derin öğrenme modelleri ile elde edilen tespit sonuçları (başarım oranı [%])

ID	Sınıf 1	Sınıf 2	Sınıf 3	N_{toplam}	f [MHz]	D/T	TCN(EMD)	LSTM(EMD)	CNN(STFT)	CNN(CWT)
1	Enkaz Boş	Solunum	–	240	210	Doğrulama	80.06	89.52	94.17	84.49
						Test	79.17	87.50	95.83	91.67
2	Enkaz Boş	Hareket	–	240	210	Doğrulama	72.98	97.12	100.00	100.00
						Test	95.83	100.00	95.83	100.00
3	Enkaz Boş	Solunum	Hareket	360	210	Doğrulama	87.50	74.44	*	*
						Test	88.89	86.11	*	*
4	Enkaz Boş	Solunum	–	240	332.5	Doğrulama	94.98	93.35	97.91	96.25
						Test	91.67	100.00	95.83	95.83
5	Enkaz Boş	Hareket	–	240	332.5	Doğrulama	82.51	97.53	100.00	99.59
						Test	100.00	91.67	100.00	100.00
6	Enkaz Boş	Solunum	Hareket	360	332.5	Doğrulama	91.39	75.28	*	*
						Test	91.67	75.00	*	*
7	Enkaz Boş	Solunum	–	240	405	Doğrulama	93.76	85.77	97.94	95.01
						Test	95.83	91.67	100.00	91.67
8	Enkaz Boş	Hareket	–	240	405	Doğrulama	100.00	100.00	100.00	100.00
						Test	100.00	100.00	100.00	100.00
9	Enkaz Boş	Solunum	Hareket	360	405	Doğrulama	90.56	68.33	*	*
						Test	97.22	77.78	*	*

* Yüksek bellek gereksinimi nedeniyle performans metrikleri hesaplanamamıştır.

4.6 Saha Ortamında Toplanan Veriler ile Canlı Tespiti

Bölüm 3.3.2'de sunulan veriler, enkaz altında kalmış bir kişinin derin nefes alması, göğüs hareketlerini belirginleştirmesi, enkaz içerisinde bir yere vurması ve rastgele el veya ayak hareketleri yapması gibi dört farklı senaryoya ait kayıtlardan oluşmaktadır. Enkaz altındaki hedefin tespit edilebilmesi ve boş enkaz durumundan ayırt edilebilmesi için, enkazda kimsenin bulunmadığı durumda da kayıtlar alınmıştır. Tablo 4.13'te, enkazdaki hareket durumlarına göre ayrı ayrı kaydedilen veri setleri ile bu veri setlerinin toplam kayıt süreleri sunulmaktadır.

Veri setlerinde yer alan enkazda canlı bulunması ve enkazın boş olması durumlarının ayırt edilebilirliğini değerlendirmek amacıyla, veri setlerinin genel istatistiki özellikleri incelenmiştir. Bu kapsamda, bir dakikalık ölçümlerden oluşan örnekler için minimum, maksimum, ortalama enerji yoğunluğu, ortalama varyans ve ortalama standart sapma değerleri hesaplanmıştır. Tablo 4.14'te verilen değerler, farklı durumlarda kaydedilen veri setlerinin istatistiki olarak birbirinden ayrılabilir olduğunu göstermektedir. Ancak, istatistiksel seviyelerde belirgin farklılıklar gözlemlenmiş olsa da, birçok sinyal birbirine oldukça benzerdir. Faz bilgisinin genlik bilgisine kıyasla daha belirgin ayırt ediciliğe sahip olduğu gözlemlenmiştir. Bu inceleme sonucunda, saha ortamında toplanan veriler ile oluşturulan tespit modelinde yalnızca faz bilgisi kullanılmıştır. Frekans bileşenlerinin dağılımına ve gürültü arındırma yöntemlerine ait detaylı incelemeler Ek B'de verilmiştir.

Tablo 4.13 Veri setlerindeki hareket durumları ve toplam kayıt süreleri

Durum	**Toplam Kayıt Süresi (dakika)**
Boş	40
Derin Nefes	40
Göğüs Hareket	40
Vurma	20
Rastgele Hareket	20

AFAD sahasındaki göçüklerden alınan ölçüm verileri ile elde edilmiş sinyaller ile derin öğrenme ile başarım oranlarını ortaya koymak üzere Tablo 4.15'te verildiği gibi dört farklı hedef tespit problemi belirlenmiştir. Her birindeki toplam veri sayısı toplam kayıt süresi kadardır.

Tablo 4.15'te verilen problemlere ait verilere, frekans tabanlı dönüşümler (EMD, VMD ve CWT) uygulanarak oluşturulan alt veri setleri, öncelikle tez çalışması kapsamında hazırlanmıştır. EMD ve VMD uygulanmış veri seti TCN modellerinde, STFT dönüşümüyle elde edilen veriler ise CNN modelinde kullanılmıştır. EMD yöntemi ile elde edilen toplam 8 IMF arasından, en anlamlı 3 IMF seçilerek

Tablo 4.14 Saha ortamında toplanan veri setinden elde edilen istatistiki özellikler

İşaret	Durum	Min	Max	Ortalama Enerji Yoğunluğu	Ortalama Varyans	Ortalama Standart Sapma
Faz	Enkaz Boş	-2.91	4.27	21.26	0.35	0.56
	Derin Nefes	-5.11	10.80	38.55	0.64	0.69
	Göğüs Hareket	-14.42	8.99	243.84	4.07	1.63
	Vurma	-15.86	10.42	164.41	2.74	1.42
	Rastgele Hareket	-18.84	15.54	813.51	13.56	3.36
Genlik	Enkaz Boş	-0.63	0.42	0.45	0.01	0.08
	Derin Nefes	-0.76	0.60	0.83	0.01	0.10
	Göğüs Hareket	-1.35	1.24	2.84	0.05	0.18
	Vurma	-2.01	1.67	4.86	0.08	0.25
	Rastgele Hareket	-3.55	2.46	19.90	0.33	0.50

Tablo 4.15 Saha ortamında toplanan veriler ile oluşturulan kapsamlı sınıflandırma problemleri

Problem	Sınıf 1	Sınıf 2	N_{toplam}	f [MHz]
Derin Nefes Tespiti	Enkaz Boş	Derin Nefes	80	310, 447.5
Göğüs Hareketi Tespiti	Enkaz Boş	Göğüs Hareketi	80	310, 447.5
Rastgele Hareket Tespiti	Enkaz Boş	Rastgele Hareket	40	310, 447.5
Vurma Tespiti	Enkaz Boş	Vurma	40	310, 447.5

kullanılmıştır. Benzer şekilde, VMD ile üretilen 5 mod arasından sinyalin en fazla bilgi içeren 3 bileşeni değerlendirmeye alınmıştır. STFT dönüşümünde ise Hamming pencereleme yöntemi, her aktivitenin karakteristik frekans bileşenlerini en iyi yansıtacak şekilde uygun pencere uzunluklarıyla seçilmiştir. Seçilen Hamming penceresinin boyutu hedef tespit problemlerinde incelenmek istenen verinin periyoduna göre seçilmiştir. FFT uzunluğu 512 ve FFT örtüşme değeri ise F_s/8 seçilmiştir. 60 saniye boyunca 4800 zaman adımında kaydedilen sinyallerin örnekleme frekansı 80'dir.

Tablo 4.18'de dört farklı probleme yönelik oluşturulan veri setlerine ait numaralandırmalar, sınıf bilgileri, veri setinde yer alan sinyallerin zaman uzunluğu, toplam örnek sayısı, uygulanan frekans tabanlı dönüşüm çeşidi ve bu dönüşüm sonrasında elde edilen sinyalin türü ile sinyal boyutu verilmektedir. Burada sinyal farklı zaman uzunluklarına bölünerek yeniden kullanılmış ve N_{toplam}'ın performans üzerindeki etkisi de incelenmiştir.

CNN ağının hiperparametre aralığı Tablo 4.16 ile, TCN ağının hiperparametre aralığı ise Tablo 4.17 ile verildiği gibidir. $n = 100$ iterasyon boyunca optimize edilen derin öğrenme modelleri oluşturulurken, veri setleri $\%75$ eğitim ve $\%25$ test

amaçlı olarak ayrılmıştır ve 4-katlı çapraz doğrulama yapılmıştır.

Tablo 4.18 ile verilen sonuçlara genel olarak bakıldığında, rastgele hareket ve vurma tespitinin (fiziksel olarak çok daha belirgin dalga biçimleri oluşturduğu için) hem uzun hem de kısa süreli sinyal verilerinde çoğu dönüşüm yönteminde yüksek doğrulama ve test başarı oranlarına ulaştığı; derin nefes ve göğüs hareketi gibi daha ince sinyallerde ise performansın genellikle düştüğü görülmektedir. STFT yöntemi, rastgele hareket ve vurma gibi belirgin olaylarda tutarlı şekilde yüksek performans sunmuştur. EMD ve VMD ise bazı senaryolarda daha iyi sonuçlar vermekle beraber, özellikle derin nefes ve göğüs hareketi gibi daha düşük farkların tespitine uygun değildir.

Tablo 4.16 CNN ağının hiperparametre aralığı

Filtre Boyutu	**Gizli Katman Birimleri**	**Öğrenme Oranı**	**Mini-Batch Boyutu**
16, 32, 64, 128	32, 64, 128, 256	0.001-0.1	2, 4, 8

Tablo 4.17 TCN ağının hiperparametre aralığı

Genişleme Faktörü	**Filtre Sayısı**	**Filtre Boyutu**	**Dropout Faktörü**	**Blok Oranı**
1, 2, 4, 8, 16	2, 4, 6, 8, 16, 32	1, 2, 4, 6	0.5, 0.2, 0.01	1, 2, 3, 4, 5

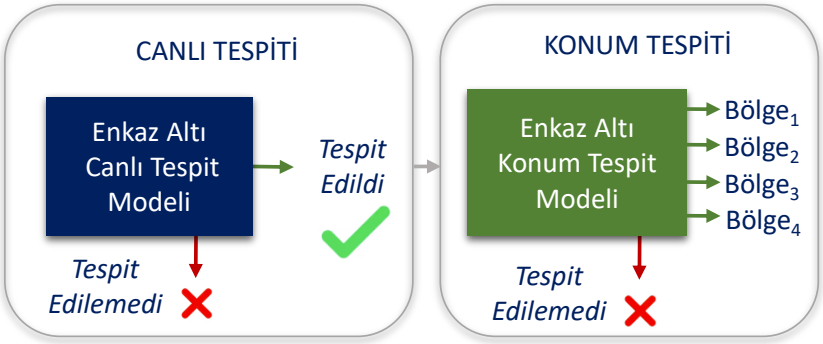
Saha ortamında oluşturulan tespit modelinin bazı durumlarda gösterdiği düşük performansı sebebiyle, Tablo 4.15'te verilen problemlere ait veriler daha sonra proje ekibi tarafından yeniden hazırlanmıştır.

Tablo 4.18 Saha ortamında toplanan veriler ile oluşturulan kapsamlı sınıflandırma problemleri ve tespit sonuçları

ID	Problem	Sınıf 1	Sınıf 2	Zaman [s]	N_{toplam}	Dönüşüm Çeşidi	IMF/ Pencere Boyutu	Sinyal Boyutu	Doğrulama Başarım Oranı [%]	Test Başarım Oranı [%]
1	Derin Nefes Tespiti	Enkaz Boş	Derin Nefes	60	80	EMD	8×4800	3×4800	75	52
2	Göğüs hareketi Tespiti	Enkaz Boş	Göğüs Hareketi	60	80	EMD	8×4800	3×4800	75	64
3	Rastgele hareket	Enkaz Boş	Rastgele Hareket	60	40	EMD	8×4800	3×4800	100	94
4	Vurma Tespiti	Enkaz Boş	Vurma	60	40	EMD	8×4800	3×4800	75	70
5	Derin Nefes Tespiti	Enkaz Boş	Derin Nefes	60	80	VMD	5×4800	3×4800	50	50
6	Göğüs hareketi Tespiti	Enkaz Boş	Göğüs Hareketi	60	80	VMD	5×4800	3×4800	93.75	72
7	Rastgele hareket	Enkaz Boş	Rastgele Hareket	60	40	VMD	5×4800	3×4800	100	90
8	Vurma Tespiti	Enkaz Boş	Vurma	60	40	VMD	5×4800	3×4800	87.5	72
9	Derin Nefes Tespiti	Enkaz Boş	Derin Nefes	60	80	STFT	$F_s \times 5$	$512 \times 24 \times 1$	87.5	58
10	Göğüs hareketi Tespiti	Enkaz Boş	Göğüs Hareketi	60	80	STFT	$F_s \times 5$	$512 \times 24 \times 1$	81.25	58
11	Rastgele hareket	Enkaz Boş	Rastgele Hareket	60	40	STFT	$F_s \times 1.5$	$512 \times 86 \times 1$	100	90
12	Vurma Tespiti	Enkaz Boş	Vurma	60	40	STFT	$F_s \times 1.5$	$512 \times 86 \times 1$	87.5	80
13	Derin Nefes Tespiti	Enkaz Boş	Derin Nefes	10	480	STFT	$F_s \times 1$	$512 \times 22 \times 1$	67.78	59.5
14	Göğüs hareketi Tespiti	Enkaz Boş	Göğüs Hareketi	10	480	STFT	$F_s \times 1$	$512 \times 22 \times 1$	76.67	67.5
15	Rastgele hareket	Enkaz Boş	Rastgele Hareket	10	240	STFT	$F_s \times 1$	$512 \times 22 \times 1$	100	87.33
16	Vurma Tespiti	Enkaz Boş	Vurma	20	120	STFT	$F_s \times 1$	$512 \times 20 \times 1$	73.91	59.33
17	Derin Nefes Tespiti	Enkaz Boş	Derin Nefes	10	960	STFT	$F_s \times 1$	$512 \times 22 \times 1$	75	64.83
18	Göğüs hareketi Tespiti	Enkaz Boş	Göğüs Hareketi	10	960	STFT	$F_s \times 1$	$512 \times 22 \times 1$	81.67	65.83
19	Rastgele hareket	Enkaz Boş	Rastgele Hareket	10	480	STFT	$F_s \times 1$	$512 \times 22 \times 1$	100	96
20	Vurma Tespiti	Enkaz Boş	Vurma	20	240	STFT	$F_s \times 1$	$512 \times 44 \times 1$	100	74.66

5
KONUM TESPİTİ

Afet durumlarında arama-kurtarma operasyonlarının etkinliği, enkaz altındaki canlıların tespiti ve konumlarının belirlenmesi ile doğrudan ilişkilidir. Canlı tespiti, kurtarma sürecinin ilk aşamasını oluştururken, tespit edilen kişinin konumunun belirlenmesi, müdahalenin başarısını artıran ikinci aşamayı oluşturmaktadır. Bu çalışmada oluşturulan konum tespit modelinin genel yapısı, Şekil 5.1 ile gösterildiği gibi sistematik bir ilerleyişe sahiptir. Eğer enkaz alanında canlı tespit edilirse tespit modeli bir sonraki aşamaya geçmekte, aksi takdirde işlem sonlandırılmaktadır. Canlı Tespit Edildikten sonra, hedefin bulunduğu konum belirlenmektedir. Bu model, çoklu anten yapısından yararlanarak canlının yerini hassas bir şekilde saptamayı amaçlamaktadır. Konumun başarıyla tespit edilmesi, hedefin bulunduğu bölgelerin (P_1, P_2, P_3, P_4) belirlenmesini sağlamaktadır.



Şekil 5.1 İki aşamalı tespit modeline ait gösterim

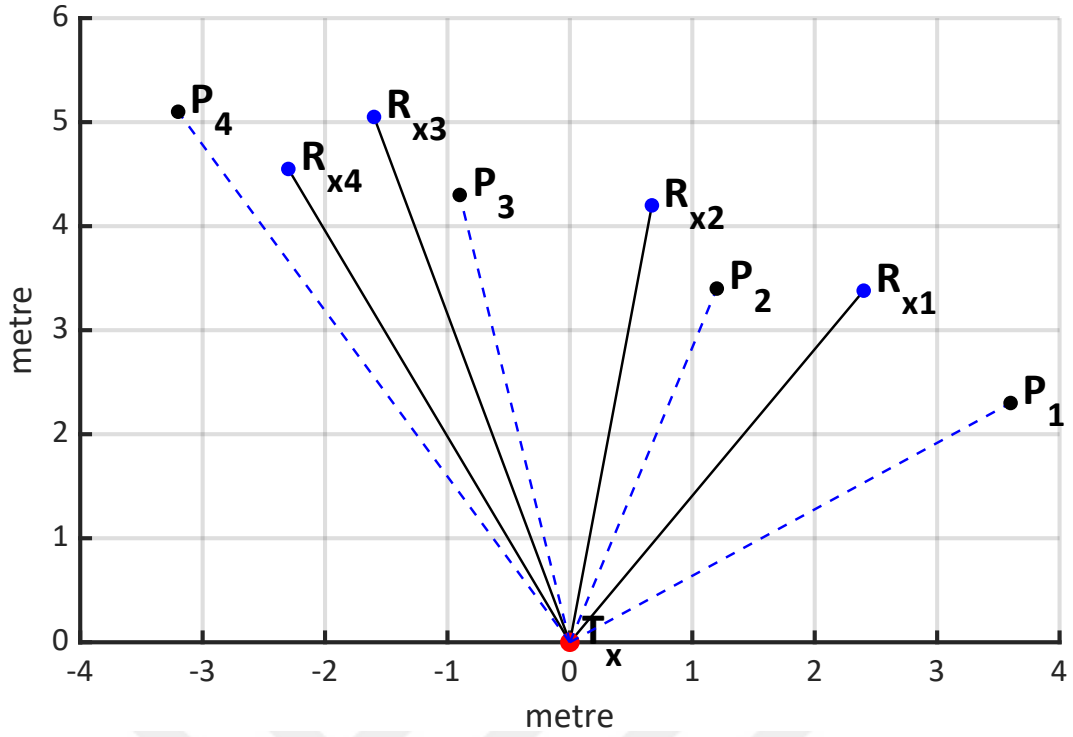
Gerçek enkazlardan oluşan AFAD sahasında, Şekil 5.2'de gösterilen enkaz alanında, çoklu anten sistemi kullanılarak dört farklı noktada ölçümler gerçekleştirilmiştir. Bu ölçümler, enkazın farklı bölgelerinde yer alan konumları kapsayacak şekilde alınmıştır. Şekil 5.3, Tablo 5.1 ve Tablo 5.2 ile hedef konumlandırma ölçümü sahası ve uygulama uzayıyla birlikte, konum tespit modeline ait sinyallere nasıl sınıf etiketi verildiği açıklanmaktadır. Ölçülen bir sinyalin alındığı alıcı anten ile hedefin bulunduğu konum aynı indise sahipse bu sinyal "*Hedef Tespit Edildi*" sınıfına aittir.

Enkaz altındaki bireylerin tespitine yönelik olarak, ortam kaybı en düşük üç farklı frekansta ve 30 saniyelik ikişer veri kaydı alınmıştır. Böylece, her bir konum için toplamda altı ölçüm elde edilmiştir. Hedef kişiler için toplam 24 ölçüm "*Hedef Tespit Edildi*" sınıfına atanmıştır. Buna ek olarak, kişinin bulunduğu nokta ile eşleşmeyen antenlerden alınan veriler arasından seçilen 24 ölçüm, "*Hedef Tespit Edilemedi*" sınıfına dahil edilmiştir. Tüm dört konum için toplamda 96 ölçüm "*Hedef Tespit Edildi*" sınıfına, 96 ölçüm ise "*Hedef Tespit Edilemedi*" sınıfına ait olup, toplam ölçüm sayısı $N_{\text{toplam}} = 192$ olarak belirlenmiştir. $n = 100$ iterasyon boyunca optimize edilen derin öğrenme modelleri oluşturulurken, veri setleri $\%80$ eğitim ve $\%20$ test amaçlı olarak ayrılmıştır ve 4-katlı çapraz doğrulama yapılmıştır. Derin öğrenme modellerinde kullanılan hiperparametre aralıkları Bölüm 4.5'de verilen modeller ile aynıdır.



Şekil 5.2 Konum tespit sistemi için kullanılan ölçüm alanı (AFAD sahası)

Çoklu antenler kullanılarak gerçekleştirilen iki aşamalı konum tespit modelinde, ikinci aşama, hedefin tespit edildiği anten bilgisine dayanarak spesifik konumun belirlenmesini sağlamaktadır. Hedefin varlığı tespit edildiğinde, verici-alıcı anten çiftleri (T_x-R_{x1}, T_x-R_{x2}, T_x-R_{x3} ve T_x-R_{x4}) aracılığıyla yapılan ölçümler doğrultusunda konum belirleme işlemi gerçekleştirilmiştir. (*Saha ortamında oluşturulan konum verilerine ait frekans tabanlı dönüşümler proje ekibi tarafından hazırlanmıştır.*)



Şekil 5.3 Hedef konumlandırma ölçüm sahasında kullanılan uygulama uzayı

Bu model, enkaz altındaki bireylerin hem varlığını hem de konumunu yüksek doğrulukla tespit etmek üzere tasarlanmıştır. İkinci aşama, tespit edilen hedefi ilgili anten bilgisiyle eşleştirerek doğrusal bir tespit süreci sunmaktadır. Tablo 5.3'te gösterildiği üzere, AFAD sahasında enkazlardan elde edilen ölçüm verileri kullanılarak derin öğrenme modelleri ile konum tespiti $\%94.74$ doğruluk oranı ile gerçekleştirilmiştir.

Tablo 5.1 Kişinin bulunduğu konum ve anten bilgisine göre ilk aşamanın cevabı

Kişinin Bulunduğu Konum	**Verici-Alıcı Anten**	**İlk Aşamanın Cevabı**
P_1	T_x-R_{x1}	Hedef Tespit Edildi
P_1	T_x-R_{x2}	Hedef Tespit Edilmedi
P_1	T_x-R_{x3}	Hedef Tespit Edilmedi
P_1	T_x-R_{x4}	Hedef Tespit Edilmedi
P_2	T_x-R_{x1}	Hedef Tespit Edilmedi
P_2	T_x-R_{x2}	Hedef Tespit Edildi
P_2	T_x-R_{x3}	Hedef Tespit Edilmedi
P_2	T_x-R_{x4}	Hedef Tespit Edilmedi

Tablo 5.2 Kişinin bulunduğu konum ve anten bilgisine göre ikinci aşamanın cevabı

İlk Aşamanın Cevabı	**Kişinin Bulunduğu Konum**	**Verici-Alıcı Anten**	**İkinci Aşamanın Cevabı**
Hedef Tespit Edildi	P_1	T_x-R_{x1}	Hedef 1. bölgede
Hedef Tespit Edildi	P_2	T_x-R_{x2}	Hedef 2. bölgede
Hedef Tespit Edildi	P_3	T_x-R_{x3}	Hedef 3. bölgede
Hedef Tespit Edildi	P_4	T_x-R_{x4}	Hedef 4. bölgede
Hedef tespit edilmedi	P_1 P_2 P_3	T_x-R_{x2} T_x-R_{x3} T_x-R_{x4}	Bölgede hedef mevcut değil, ikinci aşamaya geçilmedi.

Tablo 5.3 Konuma bağlı hedef tespit modellerinin performans metrikleri

Dönüşüm Çeşidi	**Model**	**Kesinlik**	**Duyarlılık**	**F1-Skor**	**Doğruluk Oranı [%] (Test)**	**Doğruluk Oranı [%] (Doğrulama)**
CWT	CNN	1.00	0.89	0.94	91.67	94.74
STFT	CNN	0.95	0.87	0.91	80.21	89.47
EMD	LSTM	0.87	0.87	0.87	80.73	89.47
EMD	TCN	1.00	0.55	0.71	53.12	55.26

6
SONUÇ

Bu tez çalışmasında, enkaz altında hayatta kalan bireylerin solunum sinyallerinin tespiti için derin öğrenme tekniklerine dayalı modeller geliştirilmiştir. Üç ayrı aşamada ele alınarak kavram kanıtını adım adım ilerleyerek ortaya koyan yaklaşım, 150–650 MHz bandında ölçülmüş radar sinyallerini kullanarak, sinyal işlemeye dair çeşitli zaman–frekans dönüşümleri (EMD, VMD, STFT, CWT) ile derin öğrenme modellerinin (CNN, LSTM, TCN) birleştirmeyi hedeflemiştir. Amaç, nefes ve hareket kaynaklı sinyalleri mümkün olan en yüksek doğrulukla birbirinden ayırarak, enkaz altındaki canlıların erken ve etkin şekilde tespitine katkıda bulunmaktır.

- Derin öğrenme tabanlı modeller, yüksek doğruluk oranlarına ulaşarak solunum, hareket, vurma vb. sinyallerin enkaz ortamında tespit edebilmiştir.
- EMD, VMD, STFT, CWT gibi sinyal işleme yöntemlerinin derin ağlarla beraber kullanılması, farklı enkaz senaryolarında solunum sinyallerini ayırt etmede önemli ölçüde katkı sağlamıştır.
- Özellikle CNN modeli ile kullanılan STFT dönüşümlerinin tez dahilinde kullanılan senaryolarda yüksek başarı gösterdiği gözlemlenmiştir.

Bu proje ve tez çalışmasının literatüre en büyük katkılarından biri, bi-statik antenler kullanarak gerçek enkaz ortamlarında kaydedilen ölçümlere özgü derin öğrenme modelleri oluşturmasıdır.

- Benzetim ortamında, gerçek hayatta oluşturulması uzun yıllar sürebilecek kadar çeşitli senaryolara ve gerçek elektriksel değerlere sahip fantomlar kullanılarak modellenmiş veriler kaydedilmiştir.
- Laboratuvar ortamında, gerçek yapı malzemeleri kullanılarak oluşturulan kontrollü enkaz modeli üzerinde ölçümler yapılmıştır.

- Gerçek arama-kurtarma sahalarında (AFAD), kapsamlı ölçümler gerçekleştirilmiştir.
- Farklı açılar, bireyler, konumlar, hareket türleri ve gürültü koşulları altında kaydedilen sinyallerden oluşturulan veri setleri, literatürde geniş bir yelpazede kullanılabilecek kapsamlı örnekler sunmaktadır.

Çalışmanın sınırlılıkları arasında, enkaz ortamında uzun süre kapalı alanda ölçüm yapılması, gönüllü katılımcı sayısının yetersiz olması, ortamda istenmeyen gürültü etmenlerinin bulunması ve operatör müdahalesi ile kablolu iletimin ölçümleri olumsuz etkilemesi yer almaktadır. Ayrıca, derin öğrenme mimarilerinin yüksek bellek ve işlem gücü gereksinimi, özellikle CNN gibi ağların çok sınıflı senaryolarda artan hesaplama yüküyle birlikte önemli bir sınırlayıcı etken olarak öne çıkmaktadır.

Tüm bu sınırlayıcı etkilere rağmen, tez çalışmasında önerilen yöntem ve elde edilen veri seti, arama-kurtarma operasyonlarında enkaz altındaki canlıları tespit etmek, acil durum yönetimi yazılım ve donanımlarına entegre çözümler üretmek gibi alanlarda uygulanabilir. İnsanın algılayamayacağı sinyalleri yapay zeka tabanlı yöntemlerle birleştiren bu sistem, ilk müdahale ekiplerinin zaman ve kaynak kullanımını optimize etmesine yardımcı olabilir.

Gelecek çalışmalar, proje ile tez çalışmasını birleştiren bir cihaz haline getirerek pratik kullanıma sunulmasını içerebilir. Bu tez çalışması, enkaz altındaki bireylerin yaşamsal aktivitelerinin—özellikle solunum ve hareketlerinin—tespitine yönelik derin öğrenme tekniklerine dayalı bir yöntemle gerçekleştirilebileceği hipotezini doğrulamaktadır. Hipotez, kapsamlı veri setlerine özgü olarak geliştirilen derin öğrenme modelleri ile desteklenmiş ve çoklu anten kurgusunun entegrasyonu sayesinde konum tespiti mümkün hale getirilmiştir. Sonuç olarak, çalışmaya ait özetleyici bilgiler, Tablo 1.1'in devamı niteliğinde Tablo 6.1 ile sunulmuştur.

Tablo 6.1 Tez çalışmasında kullanılan modeller, teknolojiler, veri enstrümantasyonu ve sonuçlar

Referans	**Yıl**	**Problem**	**Radar Teknolojisi**	**Veri Setinin Elde Edilme Yöntemi**	**Modeller**	**Verilen Skor**
[26]*	2024	Enkaz altı canlı tespiti ve solunum sınıflandırılması	Düzlem dalga uyarımı	Veriler, benzetim ortamında elde edilmiştir.	MLP, TCN	Doğruluk: % 99.97
[95]*	2025	Enkaz altı canlı tespiti	Bi-statik anten konfigürasyonu	Veriler, laboratuvar ortamında ölçülmüştür.	CNN, LSTM, TCN	Doğruluk: % 100
**	2025	Enkaz altı canlı tespiti	Bi-statik anten konfigürasyonu	Veriler, saha ortamında ölçülmüştür.	CNN, LSTM, TCN	Doğruluk: % 100
**	2025	Enkaz altı konum tespiti	Bi-statik anten konfigürasyonu	Veriler, saha ortamında ölçülmüştür.	CNN, LSTM, TCN	Doğruluk: % 94.74

**İlgili yayınlar tezden üretilen özgün yayınlardır.*

***Bu çalışmalara dair yayınlar, tezin sunulduğu tarihte yazım ve yükleme sürecindedir.*

KAYNAKÇA

[1] E. Altunsu, O. Güneş, S. Öztürk, S. Sorosh, A. Sarı S. Toker Beeson, "Investigating the structural damage in Hatay province after Kahramanmaraş-Türkiye earthquake sequences," *Engineering Failure Analysis*, c. 157, s. 107 857, 2024.

[2] *Kahramanmaraş depremi: 296'ıncı saatte enkazdan kurtuluş*. erişim adresi: `https://www.bbc.com/turkce/articles/c6p7wq99lreo` (erişim tarihi 13/11/2024).

[3] L. Crocco V. Ferrara, "A review on ground penetrating radar technology for the detection of buried or trapped victims," *2014 International Conference on Collaboration Technologies and Systems (CTS)*, 2014, ss. 535–540.

[4] Materpal, R. Garg S. Kumar, "Microwave doppler radar technology for non-contact trapped victim detection and vital monitoring: a review," *International Journal For Technological Research In Engineering*, c. 4, ss. 71–77, 2016.

[5] Nanzer Jeffrey, "A review of microwave wireless techniques for human presence detection and classification," *IEEE Transactions on Microwave Theory and Techniques*, c. 65, ss. 1780–1794, 2017.

[6] S. Ahmed, A. Joret, N. Katiran M. Suhaimi Sulong, "Human detection techniques for search and rescue of trapped victims under debris: a review," *Evolution of Information, Communication and Computing System*, 2022, ss. 54–65.

[7] D. Uzunidis, S. A. Mitilineos, C. Ponti, G. Schettini C. Z. Patrikakis, "Detection of trapped victims behind large obstacles using radar sensors: a review on available technologies and candidate solutions," *2023 IEEE Conference on Antenna Measurements and Applications (CAMA)*, 2023, ss. 1025–1030.

[8] S. Ahmed, F. S. Khan, A. Ahmed, I. K. Keerio S. Qutaba, "Emergent technologies in human detection for disaster response: a critical review," *Sukkur IBA Journal of Emerging Technologies*, c. 7, ss. 56–78, 2024.

[9] Z. Yang, J. Cheng, Q. Qi, X. Li Y. Wang, "A method of UWB radar vital detection based on P time extraction of strong vital signs," *Journal of Sensors*, c. 2021, 2021.

[10] B. Rao, P. Hu J. Liu, "Human movement tracking and fall detection using UWB impulse radar," *2021 CIE International Conference on Radar (Radar)*, 2021, ss. 1219–1224.

[11] M. Esmaeilishahir, A. Shakfa S. Karamzadeh, “Experimental study of non-contact detection of vital signs using IR-UWB radar,” *2023 Workshop on Microwave Theory and Technology in Wireless Communications (MTTW)*, 2023, ss. 84–88.

[12] A. Shakfa, M. Esmaeilishahir S. Karamzadeh, “Detection of human respiratory and range by IR-UWB radar,” *2023 31st Signal Processing and Communications Applications Conference (SIU)*, 2023, ss. 1–4.

[13] K.-M. Chen, D. Misra, H. Wang, H.-R. Chuang E. Postow, “An X-band microwave life-detection system,” *IEEE Transactions on Biomedical Engineering*, c. BME-33, ss. 697–701, 1986.

[14] H.-R. Chuang, Y. Chen K.-M. Chen, “Automatic clutter-canceler for microwave life-detection systems,” *IEEE Transactions on Instrumentation and Measurement*, c. 40, ss. 747–750, 1991.

[15] K.-M. Chen, Y. Huang, J. Zhang A. Norman, “Microwave life-detection systems for searching human subjects under earthquake rubble or behind barrier,” *IEEE Transactions on Biomedical Engineering*, c. 47, ss. 105–114, 2000.

[16] G. Madhavan, J. Anish Kumar L. Manimegalai, *An UWB radar for trapped human detection and vital sign extraction*, 2015.

[17] A. Sarkar D. Ghosh, “Through-wall heartbeat frequency detection using ultra-wideband impulse radar,” *2019 International Conference on Range Technology (ICORT)*, 2019, ss. 1–5.

[18] J. Yan, H. Zhao, Y. Li, L. Sun, H. Hong X. Zhu, “Through-the-wall human respiration detection using impulse ultra-wide-band radar,” *2016 IEEE Topical Conference on Biomedical Wireless Technologies, Networks, and Sensing Systems (BioWireleSS)*, 2016, ss. 94–96.

[19] X. Liang H. Zhang, “Remotely detectable signs of life based on impulse UWB radar,” *Multimed Tools and Applications*, c. 78, ss. 10 583–10 599, 2019.

[20] X. Liang H. Zhang, “Experimental study of through-the-wall respiration sign detection using ultra-wideband impulse radar,” *Preprint*, 2019.

[21] H. Lv, T. Jiao, Y. Zhang, F. Liang, F. Qi J. Wang, “A Novel Method for Breath Detection via Stepped-Frequency Continuous Wave Ultra-Wideband (SFCW UWB) Radars Based on Operational Bandwidth Segmentation,” *Sensors*, c. 18, s. 3873, 2018.

[22] J. Li, Z. Zeng, J. Sun F. Liu, “Through-wall detection of human being’s movement by UWB radar,” *IEEE Geoscience and Remote Sensing Letters*, c. 9, ss. 1079–1083, 2012.

[23] Z. Li, W. Li, H. Lv, Y. Zhang, X. Jing J. Wang, “A novel method for respiration-like clutter cancellation in life detection by dual-frequency IR-UWB radar,” *IEEE Transactions on Microwave Theory and Techniques*, c. 61, no. 5, ss. 2086–2092, 2013.

[24] S. Karamzadeh M. Kartal, "Detection improvement of hidden human's respiratory using remote measurement methods with UWB radar," *In Proceedings of the Second International Conference on Telecommunications and Remote Sensing (ICTRS 2013)*, 2013, ss. 104–108.

[25] A. Sarkar D. Ghosh, "Detection of human target location under simulated randomized rubble using global fresnel's reflection coefficient," *2021 Sensor Signal Processing for Defence Conference (SSPD)*, 2021, ss. 1–5.

[26] Ö. Niyaz, T. Tüylü, P. Mahouti, B. Erkmen N. Türker Tokan, "Detection and classification of human respiration under building debris model using VHF/UHF waves," *Neural Computing and Applications*, c. 36, ss. 14 709–14 725, 2024.

[27] B. P. A. Rohman, M. B. Andra M. Nishimoto, "Through-the-wall human respiration detection using UWB impulse radar on hovering drone," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, c. 14, ss. 6572–6584, 2021.

[28] E. Zaikov, "UWB radar for detection and localization of trapped people," *11th International Radar Symposium*, 2010, ss. 1–4.

[29] Y. Zhang ve diğ., "Detection and identification of multiple stationary human targets via bio-radar based on the cross-correlation method," *Sensors*, c. 16, s. 1793, 2016.

[30] M. Teng, Q. Fugui, Y. Xiao, J. Teng, L. Hao W. Jianqi, "Study on the environmental effect on human being detection using the UWB bio-radar," *Frontiers in Earth Science*, c. 11, 2023.

[31] E. Zaikov, J. Sachs, M. Aftanas J. Rovnakova, "Detection of trapped people by UWB radar," *German Microwave Conference*, 2008, ss. 1–4.

[32] Z. Li ve diğ., "Detection of trapped survivors using 270/400 MHz dual-frequency IR-UWB radar based on time division multiplexing," *2014 IEEE Topical Conference on Biomedical Wireless Technologies, Networks, and Sensing Systems (BioWireleSS)*, 2014, ss. 31–33.

[33] Z. Li ve diğ., "Detection of people trapped under the ruins using dual-frequency IR-UWB radar," *2018 15th European Radar Conference (EuRAD)*, 2018, ss. 83–86.

[34] K. Yan, S. Wu G. Fang, "Detection of quasi-static trapped human being using mono-static UWB life-detection radar," *Applied Sciences*, c. 11, s. 3219, 2021.

[35] S. Wu, K. Tan, Z. Xia, J. Chen, S. Meng F. Guangyou, "Improved human respiration detection method via ultra-wideband radar in through-wall or other similar conditions," *IET Radar, Sonar Navigation*, c. 10, ss. 468–476, 2016.

[36] X. Liang, T. Lv, H. Zhang, Y. Gao G. Fang, "Through-wall human being detection using UWB impulse radar," *EURASIP Journal on Wireless Communications and Networking volume*, c. 46, 2018.

[37] X. Liang, H. Zhang, S. Ye, G. Fang A. Gulliver, "Improved denoising method for through-wall vital sign detection using UWB impulse radar," *Digital Signal Processing*, c. 74, ss. 72–93, 2018.

[38] R. M. Narayanan, "Earthquake survivor detection using life signals from radar micro-Doppler," *Proceedings of the 1st International Conference on Wireless Technologies for Humanitarian Relief*, 2011.

[39] A. Qiang ve diğ., "Wavelet based human target detection in complex ruins using a low center frequency UWB radar," *2016 Progress in Electromagnetic Research Symposium (PIERS)*, 2016, ss. 1744–1747.

[40] X. Liang, H. Zhang, T. Lyu, L. Xu, C. Cao T. A. Gulliver, "Ultra-wide band impulse radar for life detection using wavelet packet decomposition," *Physical Communication*, c. 29, ss. 31–47, 2018.

[41] S. Liu, Q. Qi, H. Cheng, L. Sun, Y. Zhao J. Chai, "A vital signs fast detection and eExtraction method of UWB impulse radar based on SVD," *Sensors*, c. 22, s. 1177, 2022.

[42] X. Liang Y. Jiang, "Detection of breathing rates in through-wall UWB radar utilizing JTFA," *KSII Transactions on Internet and Information Systems*, c. 13, ss. 5527–5545, 2019.

[43] M. Dou W. Zhang, "Improved ranging method for life detection using ultra-wide band impulse radar," *The Journal of Engineering*, c. 10, ss. 1375–1383, 2018.

[44] C. Shi, N. Zhi-Kang, J. Pan, Z. Zheng, S. Ye G. Fang, "A method for reducing timing jitter's impact in through-wall human detection by ultra-wideband impulse radar," *Remote Sensing*, c. 13, s. 3577, 2021.

[45] A. Nezirovic, A. G. Yarovoy L. P. Ligthart, "Signal processing for improved detection of trapped victims using UWB radar," *IEEE Transactions on Geoscience and Remote Sensing*, c. 48, ss. 2005–2014, 2010.

[46] M. Donelli, "A rescue radar system for the detection of victims trapped under rubble based on the independent component analysis algorithm," *Progress In Electromagnetics Research*, c. 19, ss. 173–181, 2011.

[47] C. Guo, Z. G. Hou Z. Zeng, "Human detection algorithm based on bispectrum analysis for IR-UWB radar," *Advances in Neural Networks*, 2013.

[48] X. Li, D. Qiao, Y. Li H. Dai, "A novel through-wall respiration detection algorithm using UWB radar," *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2013, ss. 1013–1016.

[49] H. Lv ve diğ., "Characterization and identification of IR-UWB respiratory-motion response of trapped victims," *IEEE Transactions on Geoscience and Remote Sensing*, c. 52, ss. 7195–7204, 2014.

[50] S. M. A. Tayaranian Hosseini, H. Amindavar M. Amirmazlaghani, "A new robust vital sign detection in complex environments using ultrawideband radar," *IEEE Transactions on Geoscience and Remote Sensing*, c. 54, ss. 6771–6782, 2016.

[51] X. Liang, Y. Wang, S. Wu T. Aaron Gulliver, "Experimental study of wireless monitoring of human respiratory movements using UWB impulse radar systems," *Sensors*, c. 18, s. 3065, 2018.

[52] L. Zhao ve diğ., "UWB radar features for distinguishing humans from animals in an actual post-disaster trapped scenario," *IEEE Access*, c. 9, ss. 154 347–154 354, 2021.

[53] D. Uzunidis, E. Margaritis, C. Chatzigeorgiou, C. Z. Patrikakis S. A. Mitilineos, "A dataset for aftermath victim detection behind walls or obstacles using an UWB radar sensor," *2023 12th International Conference on Modern Circuits and Systems Technologies (MOCAST)*, 2023, ss. 1–5.

[54] D. Uzunidis, P. Kasnesis, F. G. Papadopoulos, E. N. Paliodimos, C. Z. Patrikakis S. A. Mitilineos, "Breathing rate estimation behind walls exploiting a UWB radar sensor," *2024 13th International Conference on Modern Circuits and Systems Technologies (MOCAST)*, 2024, ss. 1–4.

[55] A. Sarkar D. Ghosh, "Detection of multiple humans equidistant from IR-UWB SISO radar using machine learning," *IEEE Sensors Letters*, c. 4, no. 1, ss. 1–4, 2020.

[56] E. N. Paliodimos, F. G. Papadopoulos, D. Uzunidis, C. Z. Patrikakis S. A. Mitilineos, "A UWB radar and machine learning-based tool for detecting victims through foliage in search and rescue operations," *2024 13th International Conference on Modern Circuits and Systems Technologies (MOCAST)*, 2024, ss. 1–5.

[57] G. Seeja, A. S. A. Doss V. B. Hency, "A novel approach for disaster victim detection under debris environments using decision tree algorithms with deep learning features," *IEEE Access*, c. 11, ss. 54 760–54 772, 2023.

[58] D. Shi ve diğ., "A novel non-contact detection and identification method for the post-disaster compression state of injured individuals using UWB bio-radar," *Bioengineering*, c. 10, s. 8, 2023.

[59] R. Jadeja, T. Trivedi J. Surve, "Survivor detection approach for post-earthquake search and rescue missions based on deep learning inspired algorithms," *Scientific Reports*, c. 14, s. 25 047, 2024.

[60] Z. Zhu, D. Yang, J. Zhang F. Tong, "Dataset of human motion status using IR-UWB through-wall radar," *Journal of Systems Engineering and Electronics*, c. 32, ss. 1083–1096, 2021.

[61] A. Sarkar D. Ghosh, "Accurate sensing of multiple humans buried under rubble using IR-UWB SISO radar during search and rescue," *Sensors and Actuators A: Physical*, c. 348, s. 113 975, 2022.

[62] S.-H. Kim, Z. Woo Geem G.-T. Han, "A novel human respiration pattern recognition using signals of ultra-wideband radar sensor," *Sensors*, c. 30, s. 3340, 2019.

[63] A. Kılıç, İ. Babaoğlu, A. Babalık A. Arslan, "Through-wall radar classification of human posture using convolutional neural networks," *International Journal of Antennas and Propagation*, c. 1, 2019.

[64] A. Bhattacharya R. Vaughan, "Deep learning radar design for breathing and fall detection," *IEEE Sensors Journal*, c. 20, ss. 5072–5085, 2020.

[65] U. Saeed ve diğ., "Wireless channel modelling for identifying six types of respiratory patterns with SDR sensing and deep multilayer perceptron," *IEEE Sensors Journal*, c. 21, ss. 20 833–20 840, 2021.

[66] K. Gupta, S. M. B., S. J, O. J. Pandey L. R. Cenkeramaddi, "Automatic contact-less monitoring of breathing rate and heart rate utilizing the fusion of mmWave radar and camera steering system," *IEEE Sensors Journal*, c. 22, ss. 22 179–22 191, 2022.

[67] T. Han-Trong H. N. Viet, "An efficient heart rate measurement system using medical radar and LSTM neural network," *Journal of Electrical and Computer Engineering*, c. 1, 2022.

[68] U. Saeed ve diğ., "Multiple stationary human targets detection in through-wall UWB radar based on convolutional neural network," *IEEE Sensors Journal*, c. 21, 2021.

[69] H. S. Choi H. Yoon, "Convolutional neural networks for the real-time monitoring of vital signs based on impulse radio yltrawide-band radar during sleep," *Sensors*, c. 23, s. 3116, 2023.

[70] Q. Pan, L. Zhang, G. Dai H. Zhang, "Two denoising methods by wavelet transform," *IEEE Transactions on Signal Processing*, c. 47, ss. 3401–3406, 1999.

[71] C. Chesneau, J. Fadili J. L. Starck, "Stein block thresholding for image denoising," *Applied and Computational Harmonic Analysis*, c. 28, ss. 67–88, 2010.

[72] D. L. Donoho I. M. Johnstone, "Ideal spatial adaptation by wavelet shrinkage," *Biometrika*, c. 81, ss. 425–455, 1994.

[73] D. Griffin J. Lim, "Signal estimation from modified short-time Fourier transform," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, c. 32, ss. 236–243, 1984.

[74] G. Rilling, P. Flandrin, P. Goncalves ve diğ., "On empirical mode decomposition and its algorithms," *IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing*, c. 3, 2003, ss. 8–11.

[75] K. Dragomiretskiy D. Zosso, "Variational mode decomposition," *IEEE Transactions on Signal Processing*, c. 62, ss. 531–544, 2013.

[76] I. Goodfellow ve diğ., "Generative adversarial networks," *Advances in Neural Information Processing Systems*, c. 3, s. 1145, 2014.

[77] R. Denton, S. Gross R. Fergus, "Semi-supervised learning with context-conditional generative adversarial networks," *Preprint*, 2016.

[78] S. Hochreiter J. Schmidhuber, "Long short-term Memory," *Neural Computation*, c. 9, ss. 1735–1780, 1997.

[79] A. Graves, *Supervised Sequence Labelling with Recurrent Neural Networks*. Springer Berlin, 2012.

[80] Z. Li, F. Liu, W. Yang, S. Peng J. Zhou, "A survey of convolutional neural networks: analysis, applications, and prospects," *IEEE Transactions on Neural Networks and Learning Systems*, c. 33, ss. 6999–7019, 2022.

[81] D. K. Cheng, *Fundamentals of Engineering Electromagnetics*. Addison–Wesley, 1993.

[82] C. Gabriel, “Compilation of the dielectric properties of body tissues at RF and microwave frequencies,” *Occupational and Environmental Health Directorate, Radiofrequency Radiation Division, Brooks Air Force Base, Texas (USA)*, c. 10, s. 21, 1996.

[83] D. Doran B. Cather, *Construction Materials: Reference Book*. Elsevier, 2013.

[84] S. He, Z. Han, C. Iglesias, V. Mehta M. Bolic, “A real-time respiration monitoring and classification system using a depth camera and radars,” *Frontiers Physiology*, c. 13, 2022.

[85] A. R. Fekr, M. Janidarmian, K. Radecka Z. Zilic, “Respiration disorders classification With informative features for m-health applications,” *IEEE Journal of Biomedical and Health Informatics*, c. 20, ss. 733–747, 2016.

[86] R. A. Hameed, M. K. Sabir, M. A. Fadhel, O. Al-Shamma L. Alzubaidi, “Human emotion classification based on respiration signal,” *Proceedings of the International Conference on Information and Communication Technology*, 2019.

[87] J.-W. Hong, K. Seong-Hoon H. Gi-Tae, “Detection of multiple respiration patterns based on 1D SNN from continuous human breathing signals and the range classification method for each respiration pattern,” *Sensors*, c. 23, 2023.

[88] C. Avcı A. Akbaş, “Sleep apnea classification based on respiration signals by using ensemble methods,” *Biomedical Material Engineering*, c. 26, ss. 1703–1710, 2015.

[89] Y. S. Lee, P. N. Pathirana, C. L. Steinfort T. Caelli, “Monitoring and analysis of respiratory patterns using microwave doppler radar,” *IEEE Journal of Translational Engineering in Health and Medicine*, c. 2, ss. 1–12, 2014.

[90] G. Benchetrit, “Breathing pattern in humans: diversity and individuality,” *Respiration Physiology*, c. 122, 2000.

[91] A. Singh, S. U. Rehman, S. Yongchareon P. H. J. C. Chong, “Modelling of chest wall motion for cardiorespiratory activity for radar-based NCVS systems,” *Sensors*, c. 20, s. 5094, 2020.

[92] G. Yuan, N. A. Drost R. A. McIvor, “Respiratory rate and breathing pattern,” *Clinical Review*, c. 10, ss. 23–25, 2013.

[93] S. R. Braun, *Respiratory Rate and Pattern*. Butterworth Publishers, 1990.

[94] B. Akila J. J. V. Nayahi, “Parkinson classification neural network with mass algorithm for processing speech signals,” *Neural Computing and Applications*, c. 36, ss. 10 165–10 181, 2024.

[95] Ö. Niyaz, M. Z. Erenoğlu, A. S. Türk, S. A. Colak, B. Erkmen N. Türker Tokan, “Human Respiration and Motion Detection Based on Deep Learning and Signal Processing Techniques to Support Search and Rescue Teams,” *Applied Sciences*, c. 15, s. 2097, 2025.

A
ETİK KURUL KARARLARI

YILDIZ TEKNİK ÜNİVERSİTESİ
Sosyal ve Beşeri Bilimler Araştırmaları Etik Kurulu

Toplantı Tarihi: 15.10.2021 **Toplantı No:2021/08**

SOSYAL VE BEŞERİ BİLİMLER ARAŞTIRMALARI ETİK KURULU TOPLANTI KARARI

Yürütücülüğünü Elektrik ve Elektronik Fakültesi öğretim üyelerinden Prof. Dr. Nurhan TÜRKER TOKAN'ın yapacağı **"Deprem Sonrası Göçük Altı Canlı Tespiti İçin Yapay Zekâ Tabanlı Frekans-Adımlı Multistatik Geniş Bantlı Radar Yaklaşımı"** adlı çalışmaya ilişkin bilgilerde etiğe aykırı herhangi bir bulguya rastlanmamıştır.

Etik Kurul Üyeleri

Prof. Dr. Murat DONDURAN
Başkan

Prof. Dr. Ali ERYILMAZ
Üye

Prof. Dr. Gülhayat GÖLBAŞI ŞİMŞEK
Üye

Doç. Dr. Mehmet Emin KAHRAMAN
Üye

Doç. Dr. Senay OĞUZTİMUR
Üye

Doç. Dr. Yasin ŞEHİTOĞLU
Üye

Dr. Öğr. Üyesi Güzin AKYILDIZ
Üye

Taşbina A-2013 Oda Davutpaşa Kampüsü Esenler /İstanbul **Tel:** (0212) 383 31 18
E-posta: sbemdr@yildiz.edu.tr **Web:** http://www.sbe.yildiz.edu.tr

YILDIZ TEKNİK ÜNİVERSİTESİ
Sosyal ve Beşeri Bilimler Araştırmaları Etik Kurulu

Toplantı Tarihi: 06.06.2024 **Toplantı No: 2024.06**

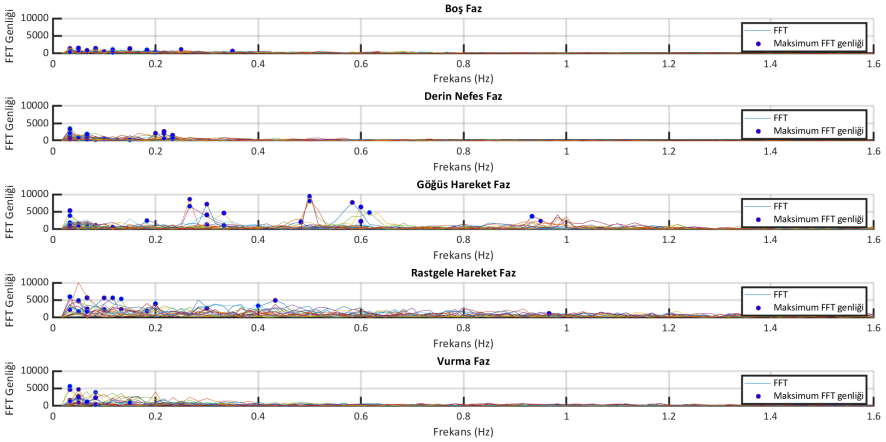
SOSYAL VE BEŞERİ BİLİMLER ARAŞTIRMALARI ETİK KURULU TOPLANTI KARARI

Yürütücülüğünü Üniversitemiz ELEKTRİK-ELEKTRONİK FAKÜLTESİ öğretim üyelerinden Prof. Dr. Burcu ERKMEN danışmanlığında lisansüstü öğrencisi Özden NİYAZ tarafından yapılacak olan "AFET DURUMLARINDA CANLI TESPİTİ İÇİN YAPAY ZEKA TEKNİKLERİ" adlı çalışma ve bu çalışmada kullanılacak veri toplama araçları ve yöntemlerine ilişkin bilgilerde etiğe aykırı herhangi bir bulguya rastlanmamıştır.

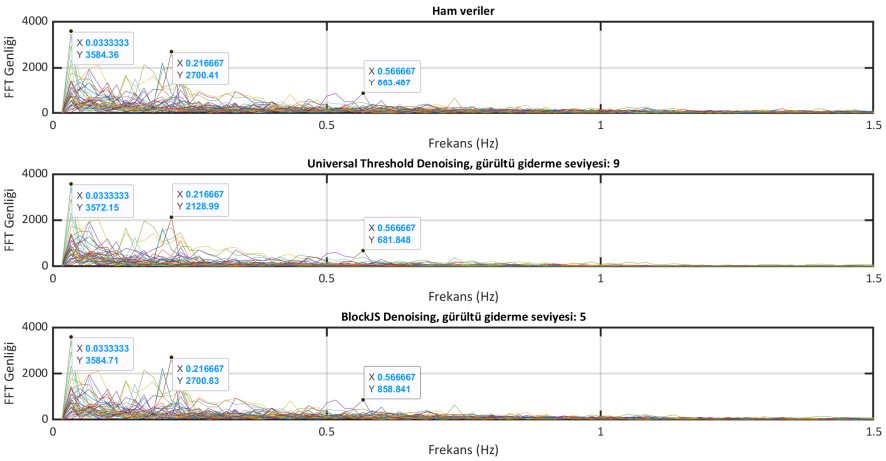
Etik Kurul Üyeleri

Prof. Dr. Murat DÖNDÜREN
Başkan

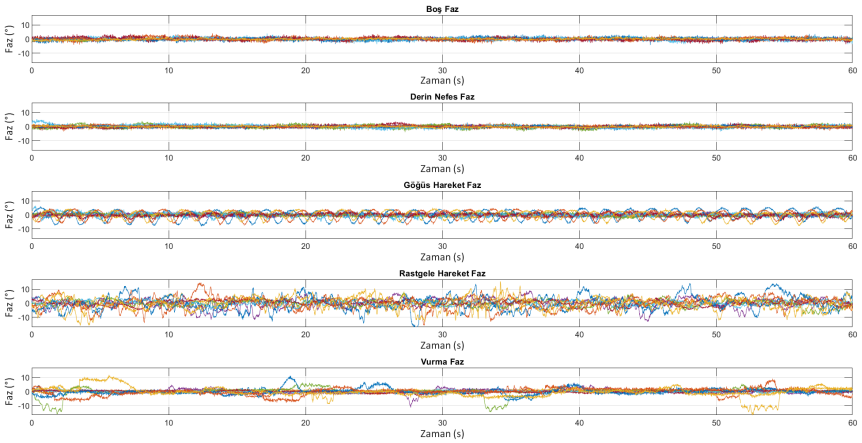
B
EK ÇALIŞMALAR



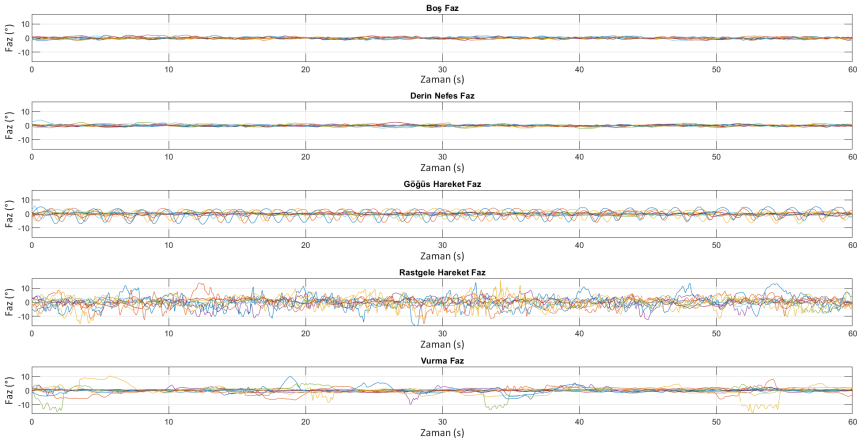
Şekil B.1 Saha ortamında toplanan verilerin maksimum FFT genliklerinin incelenmesi



Şekil B.2 Saha ortamında toplanan veriler üzerinde uygulanan farklı gürültü giderme yöntemlerinin frekans dağılımına etkisi



Şekil B.3 Saha ortamında toplanan ham veriler



Şekil B.4 Saha ortamında toplanan verilere gürültü giderme işlemi uygulanması

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. Niyaz, Ö., Tüylü, T., Mahouti, P., Erkmen, B., ve Türker Tokan, N., "Detection and classification of human respiration under building debris model using VHF/UHF waves", Neural Computing and Applications, vol. 36, pp. 14709–14725, 2024. DOI: [10.1007/s00521-024-09848-y].

2. Niyaz, Ö., Erenoğlu, M.Z., Türk, A.S., Aldirmaz Colak, S., Erkmen B, Türker Tokan, N. "Human Respiration and Motion Detection Based on Deep Learning and Signal Processing Techniques to Support Search and Rescue Teams", Applied Sciences, vol. 15(4), 2097, 2025. DOI: [10.3390/app15042097].

Konferans Bildirisi

1. Ö. Niyaz, P. Mahouti, ve B. Erkmen, "Detection of Human Respiration under Building Debris Model using Temporal Convolutional Networks," Grad Colloquium'24 Artificial Intelligence, İstanbul, Türkiye, 4 Haziran 2024, pp. 20.

Proje

1. "Deprem Sonrası Göçük Altı Canlı Tespiti İçin Yapay Zeka Tabanlı Frekans-Adımlı Multistatik Geniş Bantlı Radar Yaklaşımı" TUBITAK Destekli Projeler (1001). Proje No: 121E409.