

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

AKUSTİK VE SİSMİK SİNYALLER KULLANILARAK
HAREKETLİ YER HEDEFLERİNİN SINIFLANDIRILMASI

İSMAİL CAN BÜYÜKTEPE

YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DR. ÖĞR. ÜYESİ ALİ KÖKSAL HOCAOĞLU

ŞUBAT 2025

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

AKUSTİK VE SİSMİK SİNYALLER KULLANILARAK
HAREKETLİ YER HEDEFLERİNİN
SINIFLANDIRILMASI

İSMAİL CAN BÜYÜKTEPE

YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DR. ÖĞR. ÜYESİ ALİ KÖKSAL HOCAOĞLU

ŞUBAT 2025

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL

CLASSIFICATION OF MOVING GROUND TARGET
USING ACOUSTIC AND SEISMIC SIGNALS

İSMAİL CAN BÜYÜKTEPE

A THESIS OF MASTER OF SCIENCE
DEPARTMENT OF ELECTRONICS ENGINEERING

ADVISOR: ASSIST. PROF. DR. ALİ KÖKSAL HOCAOĞLU

FEBRUARY 2025



YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun 03/02/2025 tarih ve 2025/08 sayılı kararıyla oluşturulan jüri tarafından 11/02/2025 tarihinde tez savunma sınavı yapılan İsmail Can BÜYÜKTEPE'nin tez çalışması Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) :Dr. Öğr. Üyesi Ali Köksal HOCAOĞLU

ÜYE

:Prof. Dr. Murat DOĞRUEL

ÜYE

:Prof. Dr. Koray KAYABOL

:

ONAY

Gebze Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun
...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Hareketli yer hedeflerinin tespiti ve sınıflandırılması sınır güvenliği ve özel bölgelerin korunması için önem arz etmektedir. Bu çalışmada sınır güvenliği için mikrofon ve ivme ölçer sensörleri kullanılarak insan araba ve boş ortam sınıflandırması yapabilen bir algoritmanın geliştirilmesi amaçlanmıştır. Hedeflerin zemin yüzeyinde oluşturdukları sismik dalgalar ve etrafa yaydıkları akustik sinyaller ivmeölçer ve mikrofon sensörleri aracılığı ile SAYKAL ELEKTRONİK firması tarafından geliştirilen veri toplama sistemi kullanılarak kayıt altına alınmış ve bilgisayar ortamına taşınmıştır. Elde edilen sinyaller üzerinden zaman uzayı ve frekans uzayı analizleri yapılmış ve öznitelik çıkartımı işlemi gerçekleştirilmiştir. Zaman uzayı öznitelikleri olarak sinyallerin istatistiksel özellikleri, enerji, entropi gibi bilgileri kullanılmıştır. Frekans uzayında ise sinyallerin güç spektral yoğunluğu ve MFCC gibi farklı öznitelikleri kullanılmıştır.

Sınıflandırma işlemini gerçekleştirmek amacıyla k-EYK, DVM ve XGBoosting algoritmaları kullanılmıştır. Çalışmanın başlangıç aşamasında, ivmeölçer ve mikrofon verileri üzerinde farklı modeller eğitilerek problemin çözümü üzerinde her bir sensör için başarı analizleri gerçekleştirilmiştir. Ancak, bu analizler sonucunda sınıflandırma performansının sınırlı kaldığı gözlemlenmiştir. Sonraki aşamada, ivmeölçer ve mikrofon sensörlerinden elde edilen veriler birleştirilmiş ve yeni bir model geliştirilmiştir. Bu kaynaştırılmış veri yaklaşımı ile sınıflandırma performansında belirgin bir iyileşme sağlanmıştır. Bununla birlikte, modelin sınıflandırma performansını daha da artırmak amacıyla alternatif bir yöntem önerilmiştir.

Önerilen yöntem, sınıflandırma işlemini iki aşamalı bir algoritma ile gerçekleştirmektedir. Algoritmanın ilk aşamasında, sensör verileri ayrı ayrı ele alınarak analiz edilmektedir. Sensörlerin farklı tepki verdiği örnekler kaynaştırılarak bir tespit iyileştirme modeli oluşturulmuştur. Bu yaklaşım, hareketli hedeflerin tespit performansını artırmayı sağlamaktadır. İkinci aşamada ise tespit edilen hareketli hedeflerin sınıflandırma işlemi gerçekleştirilmiştir. Yapılan testler sonucunda, önerilen yöntemin sınıflandırma başarımını artırdığı ve mevcut yaklaşımlara kıyasla daha yüksek bir performans sağladığı gösterilmiştir.

Anahtar Kelimeler: Sismik sinyal, Akustik sinyal, Makine öğrenmesi, Destek Vektör makinası, En yakın komşu, Karar ağacı

ABSTRACT

The detection and classification of moving ground targets are important for border security and protection of special areas. In this study, an algorithm was developed for border security that can classify human, vehicle and empty environment using microphones and accelerometer sensors. The seismic waves created by the targets on the ground surface and the acoustic signals they emit were recorded using a data collection system developed by SAYKAL Electronics company with accelerometers and microphone sensors and transferred to a computer environment. Time domain and frequency domain analyses were performed on the obtained signals. Feature extraction was performed. Statistical properties of signals, energy, entropy were used as time domain features. In frequency domain, different features of signals such as power spectral density and MFCC were used.

To perform the classification process, k-NN, SVM, and XGBoosting algorithms were used. In the initial phase of the study, different models were trained on accelerometer and microphone data, and performance analyses were conducted for each sensor to solve the problem. However, it was observed that the classification performance remained limited. In the subsequent phase, data from the accelerometer and microphone sensors were fused, and a new model was developed. This data fusion approach resulted in a significant improvement in classification performance. Nevertheless, to further enhance the classification performance of the model, an alternative method was proposed.

The proposed method performs the classification process using a two-stage algorithm. In the first stage, sensor data are analyzed separately. Examples that elicited different responses from the sensors were fused and passed through a detection improvement model. This approach enhanced the detection performance of moving targets. In the second stage, the classification process for the detected moving targets was carried out. Test results demonstrated that the proposed method improved classification performance and achieved higher accuracy compared to existing approaches.

Keywords: Seismic signal, Acoustic signal, Machine Learning, Support Vector Machine, Nearest neighbor, Decision tree

TEŞEKKÜR

Bu çalışmanın oluşmasında büyük emeği olan, her daim yanımda bulunarak tecrübesi, bilgisi ve özverisiyle bana rehberlik eden Dr. Öğr. Üyesi Köksal HOCAOĞLU hocama,

Çalışmalarım sürecinde beni cesaretlendiren ve deneyimini benimle paylaşan Dr. Kürşat İNCE' ye,

Bu günlere gelmemde desteklerini ve emeklerini üzerimden hiç esirgemeyen kıymetli annem Şengül BÜYÜKTEPE ve babam Abdullah BÜYÜKTEPE' ye teşekkürlerimi sunmak istiyorum.

İlerlememde ve hayallerime ulaşmam noktasında bu katkı ve emeklerin benim açımdan unutulmaz ve tarifsiz bir anlamı olduğunu vurgulamak istiyorum. İlginiz ve destekleriniz için minnettarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
ABSTRACT	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
TABLolar DİZİNİ	xii
1. GİRİŞ	1
1.1. Tezin Amacı ve Önemi	3
2. Literatür İncelemesi	6
2.1. Sismik Sinyaller	6
2.1.1. Yüzey Dalgaları	7
2.1.2. Cisim dalgaları	8
2.1.3. Sismik Sensörler	9
2.1.3.1. Jeofon	9
2.1.3.2. İvmeölçer	10
2.2. Akustik Sinyaller	10
2.3. Makine Öğrenmesi Tabanlı Çalışmalar	11
2.4. Derin Öğrenme Tabanlı Yöntemler	14
3. YÖNTEM	17
3.1. Veri Toplama	19
3.1.1. Veri Etiketleme	19
3.2. Öznitelik Çıkarımı	20
3.2.1. Zaman Uzayı Öznitelikleri	21
3.2.1.1. Basıklık (Kurtosis)	21
3.2.1.2. Çarpıklık (Skewness)	22
3.2.1.3. Sıfırı Geçiş Oranı (Zero-Cross Rate)	23
3.2.1.4. Enerji	23
3.2.2. Frekans Uzayı Öznitelikleri	23
3.2.2.1. Güç Spektral Kestirimi	24
3.2.2.2. Spektral Entropi	26
3.2.2.3. Spektral Merkez	26
3.2.2.4. Mel Frekansı Kepstrum Katsayıları (MFKK)	27
3.3. Öznitelik Normalizasyonu	28
3.4. Boyut Azaltma	29
3.4.1. Temel Bileşen Analizi (TBA)	29
3.4.2. Fisher'ın Doğrusal Ayırıcı Analizi (Fisher DAA)	30
3.5. Sınıflandırma	31
3.5.1. K-En Yakın Komşu Algoritması (K-EYK)	32
3.5.2. Destek Vektör Makinesi (DVM)	33
3.5.3. XGBoost Algoritması	34
3.5.4. Yapay Sinir Ağları (YSA)	34
3.6. Bölüm Özeti	35
4. TESTLER VE ANALİZ	37

4.1. Değerlendirme Yöntemleri	37
4.1.1. Doğruluk	37
4.1.2. Kesinlik	38
4.1.3. Duyarlılık	38
4.1.4. F-1 Skoru	38
4.2. Veri Seti Özellikleri	38
4.3. Kullanılan Öznitelikler	39
4.3.1. Zaman Uzayı Öznitelikleri	39
4.3.2. Frekans Uzayı Öznitelikleri	39
4.3.3. Öznitelik Seçimi ve Boyut Azaltımı	40
4.4. Testler ve Senaryolar	41
4.4.1. Test-1 Senaryoları ve Sonuçları	42
4.4.1.1. Titreşim Verileri Analiz ve Sonuçları	42
4.4.1.2. Mikrofon Verileri Analiz ve Sonuçları	48
4.4.2. Test Senaryosu-2	53
4.4.2.1. Birleştirilmiş Sensör Verileri Analiz ve Sonuçları	53
4.4.3. Test Senaryo-3	55
4.4.3.1. Önerilen Algoritmanın Analiz ve Sonuçları	55
4.5. Bölüm Özeti	59
5. SONUÇLAR	61
REFERANSLAR	63
ÖZGEÇMİŞ	65
TEZ ÇALIŞMASI KAPSAMINDAYAPILAN YAYINLAR	66

SİMGELER ve KISALTMALAR DİZİNİ

p_{xx}^{welch}	: Welch Güç Spektral kestirimi
r_{xx}	: Otokorelasyon fonksiyonu
P_{per}	: Periodogram
U	: Normalizasyon faktörü
C	: Toplam sınıf sayısı
C_i	: i. sınıfa ait örnekler
μ_i	: i. sınıfın ortalaması
S_w	: Sınıf içi dağılım matrisi
S_b	: Sınıflar arası ayrışım matrisi
μ	: Veri setinin ortalaması
N_i	: i. sınıfa ait veri sayısı
$J(\omega)$	: Projeksiyon matrisi
E_m	: Zaman uzayı sinyalin enerjisi
ω	: Projeksiyon vektörü
z	: Boyut azaltılmış veri noktası
x	: Orijinal boyuttaki veri noktası
ASD	: Analog Sayısal dönüştürücü
DAA	: Doğrusal ayırıcı analiz
DVVA	: Destek vektör veri açıklaması
DVM	: Destek vektör makinası
EWD	: Empirical Wavelet dönüşümü
ESA	: Evrimsel sinir ağları
GKM	: Gauss karışım modeli
K-EYK	: K-En yakın komşu
KZFD	: Kısa Zaman Fourier Dönüşümü
MFKK	: Mel Frekans Kepstrum Katsayıları
MEMS	: Mikroelektro-mekanik sistemler
PWVD	: Pseudo-Wigner-Ville Dağılımı
SYAH	: Sabit Yanlış Alarm Hızı
TBA	: Temel Bileşen Analizi
UKSB	: Uzun Kısa Süreli Bellek

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1: Sismik dalga türleri.	7
Şekil 3.1: Genel akış diyagramı.	17
Şekil 3.2: Detaylı algoritma akış diyagramı.	18
Şekil 3.3: Veri toplama sahası.	19
Şekil 3.4: Veri etiketleme arayüzü.	20
Şekil 3.5: MFKK yöntemi akış diyagramı.	28
Şekil 4.1: Titreşim verileri için öznitelik önem sonucu.	42
Şekil 4.2: Titreşim verileri öznitelik pearson korelasyon analizi.	43
Şekil 4.3: Ses veri seti için öznitelik önem sonucu.	48
Şekil 4.4: Ses verileri öznitelik pearson korelasyon analizi.	49
Şekil 4.5: Kaynaştırılmış veri seti için öznitelik önem sonucu.	53
Şekil 4.6: Birleştirilmiş veriler için öznitelik pearson korelasyon analizi.	54

TABLolar DİZİNİ

	Sayfa
Tablo 4.1: Toplam veri seti.	39
Tablo 4.2: Titreşim verisi eğitim veri kümesi bilgileri.	43
Tablo 4.3: Titreşim verisi test veri kümesi bilgileri.	43
Tablo 4.4: XGboost modelleri parametre tablosu.	44
Tablo 4.5: Titreşim verisi XGBoost_Model1 karmaşıklık matrisi.	44
Tablo 4.6: Titreşim verisi XGBoost_Model2 karmaşıklık matrisi.	44
Tablo 4.7: Titreşim verisi XGBoost_Model3 karmaşıklık matrisi.	44
Tablo 4.8: Titreşim verisi XGBoost_Model4 karmaşıklık matrisi.	45
Tablo 4.9: Titreşim verileri için XGBoost modellerinin performans sonuçları.	45
Tablo 4.10: DVM modelleri parametre tablosu.	45
Tablo 4.11: Titreşim verisi DVM_Model1 karmaşıklık matrisi.	46
Tablo 4.12: Titreşim verisi DVM_Model2 karmaşıklık matrisi.	46
Tablo 4.13: Titreşim verisi DVM_Model3 karmaşıklık matrisi.	46
Tablo 4.14: Titreşim verisi DVM_Model4 karmaşıklık matrisi.	46
Tablo 4.15: Titreşim verileri için DVM modellerinin performans sonuçları.	46
Tablo 4.16: K-EYK modelleri parametre tablosu.	47
Tablo 4.17: Titreşim verisi k-EYK_Model1 karmaşıklık matrisi.	47
Tablo 4.18: Titreşim verisi k-EYK_Model2 karmaşıklık matrisi.	47
Tablo 4.19: Titreşim verisi k-EYK_Model3 karmaşıklık matrisi.	47
Tablo 4.20: Titreşim verisi k-EYK_Model4 karmaşıklık matrisi.	47
Tablo 4.21: Titreşim verileri için k-EYK Modellerinin performans sonuçları.	48
Tablo 4.22: Ses verisi eğitim veri kümesi bilgileri.	49
Tablo 4.23: Ses verisi test veri kümesi bilgileri.	49
Tablo 4.24: Ses verisi XGBoost_Model1 karmaşıklık matrisi.	50
Tablo 4.25: Ses verisi XGBoost_Model2 karmaşıklık matrisi.	50
Tablo 4.26: Ses verisi XGBoost_Model3 karmaşıklık matrisi.	50
Tablo 4.27: Ses verisi XGBoost_Model4 karmaşıklık matrisi.	50
Tablo 4.28: Ses verileri için XGBoost modellerinin performans sonuçları.	50
Tablo 4.29: Ses veri seti DVM_Model1 karmaşıklık matrisi.	51
Tablo 4.30: Ses veri seti DVM_Model2 karmaşıklık matrisi.	51
Tablo 4.31: Ses Veri seti DVM_Model3 karmaşıklık matrisi.	51
Tablo 4.32: Ses veri seti DVM_Model4 karmaşıklık matrisi.	51
Tablo 4.33: Ses verileri için DVM modellerinin performans sonuçları.	51
Tablo 4.34: Ses veri seti k-EYK_Model1 karmaşıklık matrisi.	52
Tablo 4.35: Ses veri seti k-EYK_Model2 karmaşıklık matrisi.	52
Tablo 4.36: Ses veri seti k-EYK_Model3 karmaşıklık matrisi.	52
Tablo 4.37: Ses veri seti k-EYK_Model4 karmaşıklık matrisi.	52
Tablo 4.38: Ses verileri için k-EYK modellerinin performans sonuçları.	52
Tablo 4.39: Kaynaştırılmış veri seti XGBoost-Model2 karmaşıklık matrisi.	54
Tablo 4.40: Kaynaştırılmış veri seti DVM-Model1 karmaşıklık matrisi.	55
Tablo 4.41: Kaynaştırılmış veri seti k-EYK-Model2 karmaşıklık matrisi.	55
Tablo 4.42: Başarım sonuç tablosu.	55

Tablo 4.43: Tespit aşaması eğitim kümesi veri özellikleri.	56
Tablo 4.44: Tespit aşaması test kümesi veri özellikleri.	56
Tablo 4.45: Titreşim verisi XGBoost-Model2 tespit sonucu.	56
Tablo 4.46: Titreşim verisi DVM-Model1 tespit sonucu.	56
Tablo 4.47: Ses verisi XGBoost-Model2 tespit sonucu.	57
Tablo 4.48: Ses verisi DVM-Model1 tespit sonucu.	57
Tablo 4.49: XGBoost-Model2 parametrelili model-3 tespit sonucu.	58
Tablo 4.50: Önerilen yöntemin tespit sonucu.	58
Tablo 4.51: Birleştirilmiş test verileri için tespit sonucu.	58
Tablo 4.52: Önerilen yöntemin sınıflandırma sonucu.	59
Tablo 4.53: Test senaryoları sonunda her sınıf için başarı sonuçları.	59

1. GİRİŞ

Sınır gibi geniş alanların korunması ve bu bölgelere izinsiz girişlerin tespit edilmesi oldukça zor bir süreçtir. Çünkü bölgenin büyüklüğüne göre yeterli sayıda güvenlik personelinin bulundurulması gerekmektedir. Yeterli sayıda personel bulundurulamaması güvenlik zafiyetlerinin oluşmasına sebep olmaktadır. Bu tür alanlar genellikle görsel olarak takip edilse de görülemeyen kör noktaların oluşması olası olabilir. Bu da sınır güvenliği için büyük bir problemdir. Bu noktalarda olası hedeflerin sınıra yaklaşılmadan tespit ve sınıflandırılması büyük önem arz etmektedir.

Sensör ve gömülü sistem teknolojilerinin gelişmesi, hareketli yer hedeflerinin tespiti ve sınıflandırılması konusunda yapılan çalışmaların artmasına neden olmuştur. Sınır güvenliği, özel bölgelerde yaşanan izinsiz girişler ve akıllı trafik sistemlerinde trafik yoğunluğu tespiti yapabilen sistemler geliştirilmiştir.

Yer hedefleri genellikle araç, insan veya hayvan gibi çeşitli nesneler olabilmektedir. Literatürde bu hedeflerin tespiti ve sınıflandırılması için aktif ve pasif tespit yöntemleri kullanılmaktadır. Aktif tespit yöntemleri, bir kaynaktan çevreye sinyal dalgalarının gönderilmesi ve geri dönen sinyallerin analiz edilmesine dayanır. Ancak bu yöntemin en büyük dezavantajı yayılan sistemlerin kolayca konumunun tespit edilebilmesidir. Ek olarak bu sistemlerin geliştirilmesi ve kurulması maliyetlidir. Bu sistemleri kullanabilecek eğitimli personellere ihtiyaç duyulmaktadır.

Pasif tespit yöntemleri ise çevredeki sinyallerin dinleyerek çalışmaktadır. Böylelikle sinyallerin analiz edilmesine olanak sağlar. Bu yöntemde termal kameralar, akustik sensörler, fiber optik sensörler, kızıl ötesi sensörler ve sismik sensörler sıkça kullanılır. Pasif sensör teknolojisinde yaşanan gelişmelerden dolayı insan, araç tespiti ve sınıflandırılması konusunda pasif sensör kullanımı artmıştır. Görüntü ve kızılötesi sinyallerin analizi daha kolay olduğundan dolayı hedef tespit ve sınıflandırma çalışmaları bu tip sensörlerden elde edilen sinyaller üzerine yoğunlaşmıştır. Bu tarz sistemlerin akustik ve sismik sensörlere göre daha maliyetli olması araştırmacıları akustik ve sismik sinyalleri analiz etmeye itmiştir.

Zemin titreşimleri temelli güvenlik sistemleri, sensörlerin yer altına veya kapalı bir alan içerisinde zemin yüzeyinde gizlenebilmesi sayesinde tespit edilmesi ve

durdurulması güç sistemler haline getirmektedir. Bununla birlikte çevre şartlarından çok az etkilenirler. Düşük pil tüketimlerinden dolayı bakım gerektirmeden uzun süreler kullanılabilir. Bu avantajlarına ek olarak titreşim sinyallerini kullanarak hedef tespiti yapmanın zor yanlarından birisi, hedefin hareketi sonucu oluşan titreşim sinyallerinin çevresel gürültülerden ayırt edilmesidir. Gürültü kaynakları genellikle periyodik değişim göstermemesine rağmen hedef ile sensör arası mesafe arttıkça sinyal-gürültü oranı azalır ve bu da tespit ve sınıflandırma işlemini güçleştirebilir.

Akustik temelli güvenlik sistemleri ise, düşük maliyetli oluşundan dolayı geniş alanlarda çoklu kullanıma uygundur. Bununla birlikte düşük güç tüketimine sahip olmaları uzun görev sürelerine erişmelerine katkı sağlar. Bu avantajlarının yanı sıra çevresel gürültülere duyarlı sistemlerdir. Yağmur, rüzgâr, hayvan sesleri gibi dış gürültülerden olumsuz etkilenebilirler.

Bu çalışmada sınır güvenliği için mikrofon ve ivme ölçer sensörleri kullanılarak insan araba ve boş ortam sınıflandırması yapabilen bir algoritmanın geliştirilmesi amaçlanmıştır. Hedeflerin zemin yüzeyinde oluşturdukları sismik dalgalar ve etrafa yaydıkları akustik sinyaller ivmeölçer ve mikrofon sensörleri aracılığı ile SAYKAL ELEKTRONİK firması tarafından geliştirilen veri toplama sistemi kullanılarak kayıt altına alınmış ve bilgisayar ortamına taşınmıştır. Elde edilen sinyaller üzerinden zaman uzayı ve frekans uzayı analizleri yapılmış ve öznitelik çıkartımı işlemi gerçekleştirilmiştir. Zaman uzayı öznitelikleri olarak sinyallerin istatistiksel özellikleri, enerji, entropi gibi bilgileri kullanılmıştır. Frekans uzayında ise sinyallerin güç spektral yoğunluğu ve MFKK (Mel Frekans Kepstrum Katsayıları) gibi farklı öznitelikleri kullanılmıştır.

Sınıflandırma problemini çözebilmek için tek bir sensör bilgisinin kullanılması yeterli olur mu? Sorusuna cevap aranmıştır. Bu kapsamda her bir sensör verisi için k-EYK (K-En Yakın Komşu), DVM (Destek Vektör Makinası) ve XGBoosting (Aşırı Gradyan Güçlendirme) algoritmaları kullanılarak başarımların analizi yapılmıştır. Yapılan analizler sonucunda başarımın sınırlı kaldığı gözlemlenmiştir. Çalışmanın ikinci adımında ise sensörlerin sahip oldukları farklı bilgilerin birleştirilmesi başarı artışını sağlayabilir mi? Sorusuna cevap aranmıştır. Gerçekleştirilen testler sonucunda sınıflandırma başarısında artış sağlanmıştır.

Fakat, sensör bilgilerinin hangi aşamada birleştirilmesi gerektiği, çoklu sensör kullanılan sistemlerde sistem performansı ve sınıflandırma başarısını doğrudan etkileyen bir faktör olarak öne çıkmaktadır. Bu bağlamda, çalışmada yenilikçi bir yaklaşım önerilmiştir. Önerilen model, iki aşamalı bir sınıflandırma sürecine dayanmaktadır. İlk aşamada, hareketli hedeflerin tespit edilmesi amaçlanmıştır. Bu aşamada, sensör verileri ayrı ayrı analiz edilmiş ve sensörlerin farklı cevaplar verdiği durumlarda sensör bilgileri birleştirilmiş ve tespit işlemine o şekilde karar verilmiştir. Bu süreç sonucunda elde edilen tespitlerden hareketli hedefler, sınıflandırılması için ikinci aşamaya aktarılmıştır. İkinci aşamada, hareketli hedeflerin sınıflandırılması gerçekleştirilmiştir.

Yapılan testler sonucunda önerilen yöntem ile gerçekleştirilen sınıflandırma işleminin sonucu, sensörlerin tekil olarak değerlendirilmesi ve birleştirilerek değerlendirilmesi senaryolarından daha başarılı bir sınıflandırma performansı ortaya koymaktadır.

1.1. Tezin Amacı ve Önemi

Sınır güvenliğinin sağlanması, ülkelerin milli güvenlik politikalarının temel unsurlarından biri haline gelmiştir. Özellikle sınır bölgelerinde hareketli yer hedeflerinin tespit edilmesi ve sınıflandırılması, mevcut güvenlik önlemlerinin etkinliğini arttırmak için kritik bir ihtiyaç olarak ortaya çıkmaktadır. Literatürde, bu tür hedeflerin tespiti ve sınıflandırılması genellikle sismik sinyal temelli yöntemlerle ele alınmaktadır. Ancak, bu yöntemlerde kullanılan jeofon sensörleri, analog bir yapıya sahip olmaları nedeniyle, topladıkları verilerin bilgisayar ortamına taşınması için güçlendirme devreleri, filtreler ve yüksek çözünürlüklü analog-dijital dönüştürücüler gerektirmektedir. Bu gereksinimler, sistem tasarımını karmaşıktırırken maliyetlerin artmasına da neden olmaktadır. Ayrıca bu tür sistemlerde veri işleme süreçlerinin yoğunluğu, düşük maliyetli ve dağıtık çözümler oluşturmayı zorlaştırmaktadır. Bu durum, sınır güvenliği için daha etkili, ekonomik ve pratik sistemlere olan ihtiyacı açık bir şekilde ortaya koymaktadır.

Son yıllarda pasif sensör teknolojilerindeki gelişmeler, düşük güç tüketimi sağlayan sensörlerin yaygınlaşması ve IoT (Nesnelerin İnterneti) teknolojisindeki ilerlemeler, alternatif güvenlik çözümlerinin geliştirilmesi için önemli fırsatlar sunmuştur. Bu bağlamda, dijital çıkış sağlayan hassas ivmeölçer sensörlerinin kullanımı, geleneksel

sismik veri toplama sistemlerine alternatif bir yaklaşım olarak öne çıkmaktadır. Mikrofon sensörleriyle elde edilen akustik verilerin değerlendirilmesi ise tespit ve sınıflandırma süreçlerine ek bir boyut kazandırmaktadır. Bu sensörlerin birlikte entegre edilmesi, sınır güvenliği açısından daha verimli, düşük maliyetli ve etkili çözümler geliştirilmesi potansiyeli taşımaktadır.

Bu çalışma kapsamında, sınır güvenliği için üç eksen ivmeölçer ve mikrofon sensörlerinin entegre kullanımı ile hareketli yer hedeflerinin insan, araba ve boş ortam tespit ve sınıflandırmasını gerçekleştirebilecek bir sistemin geliştirilmesi hedeflenmiştir. Bu sistemin geliştirilmesi mevcut optik çözümlere ek olarak akustik ve sismik sinyallerin de değerlendirilmesi, daha kapsamlı ve güvenilir bir sınıflandırma süreci sunacaktır. Böylece düşük maliyetli ve etkin bir güvenlik çözümüne ulaşılması amaçlanmaktadır.

Literatürde hareketli yer hedeflerinin tespiti ve sınıflandırılması üzerine farklı çalışmalar gerçekleştirilmiştir. Bu çalışmalar askeri alanda paletli askeri araçların sınıflandırılması, kaçakçılığı önlemek amacıyla insan ve at sınıflandırılması gibi bununla birlikte açık ve kapalı alanların güvenliği için adım algılama sistemleri üzerine iken sivil alanda ise trafik yoğunluğunun tespit ve sınıflandırılması üzerine çalışmalar yapılmıştır. Bu çalışmalar genellikle jeofon sensörü kullanılarak sismik temelli çalışmalar olarak karşımıza çıkmaktadır. Mikrofon sensörleri ile yapılan akustik sinyal temelli çalışmalar ise ortam gürültüsünden ve doğal olaylardan etkilendikleri için sınıflandırma performansları olumsuz etkilenebilmektedir. Diğer senaryolar üzerinde sınıflandırma performansları genellikle iyi sonuçlar vermektedir. İki sensörün birlikte kullanıldığı çalışmalarda ise tespit işlemi için sismik sinyaller kullanılırken hareketli hedeflerin sınıflandırılması için akustik sinyallerin kullanılması yolu genellikle kullanılan yöntem olarak kullanılmaktadır. Bu yönüyle tek tip sensör verileriyle sonuç elde edilmesi bu alanda yapılan çalışmaların sınırlı kalmasına sebep olmaktadır.

Bu tez çalışması, literatürdeki bu alandaki eksikliği gidermek amacıyla yeni bir yaklaşım önermektedir. İki farklı sensör tipinden elde edilen verileri kaynaştırarak, hareketli hedef tespiti ve sınıflandırması için çift aşamalı bir algoritma önermektedir. İlk aşamada, sensör verileri ayrı ayrı değerlendirilir ve hareketli hedef tespiti yapılır. Bu aşamada sensör sonuçları farklı olması durumunda sensör verileri kaynaştırılır ve tespit iyileştirme modeli ile yanlış tespit iyileştirilmesi sağlanır. İkinci aşamada ise

tespit edilen hareketli hedeflerin sınıflandırılma işlemi gerçekleştirilir. Böylece önerilen algoritma ile hareketli hedef tespiti ve sınıflandırması yapabilen algoritma önerilmiştir.

Bu yenilikçi yaklaşım, sismik ve akustik verilerinin birlikte değerlendirilmesiyle daha yüksek doğruluk oranlarına ulaşmayı hedeflemekte ve hareketli hedeflerin tespit ve sınıflandırılması alanında özgün bir çözüm sunmaktadır. Çalışmanın test sonuçları, önerilen sistemin başarı performansının direk olarak sensörlerin verdiği sınıflandırma sonuçlarından ve direk olarak birleştirilmiş veriden daha iyi sonuç verdiğini göstermektedir.

Çalışmanın devamı şu şekilde organize edilmiştir: Bölüm 2’de literatür incelemesi anlatılmaktadır. Bölüm 3’ de önerilen algoritma ve kullanılan yöntemler anlatılmaktadır. Bölüm 4’te yapılan testler ve elde edilen sonuçlar sunulmaktadır. Bölüm 5’te ise çalışmanın sonuçları yorumlanarak çalışma tamamlanmıştır.


2. LİTERATÜR İNCELEMESİ

Bu bölümde, akustik ve sismik sinyallerin fiziksel özelliklerinden ve bu dalgaların çeşitlerinden hangi alanlarda kullanıldığından bahsedilerek başlanacaktır. Sonraki aşamada ise bu sinyallerin toplanması noktasında literatürde kullanılan sensörlerin açıklanması anlatılmıştır. Sistemlerin nasıl tasarlandığı anlatılmaya çalışıldıktan sonra hareketli yer hedeflerinin sınıflandırma konusunda literatürde yapılan çalışmalar anlatılmaya çalışılmıştır. Literatürde bu çalışmalara iki farklı yaklaşımla çözümler üretildiği görülmektedir. Birinci yaklaşım sinyal işleme teknikleri kullanılarak öznitelik çıkartımı işlemi gerçekleştirilip makine öğrenmesi algoritmaları ile tespit ve sınıflandırma yapılmaktadır. Başka bir yaklaşım ise yeterli örnek sayısına sahip olan çalışmalar ise derin öğrenme temelli yaklaşımlar ile problemi çözmeye çalışmıştır.

2.1. Sismik Sinyaller

Sismik dalgalar, zemindeki titreşimler tarafından oluşan ve zemin boyunca çeşitli yönlerde doğru yayılan dalga türleridir. Depremler, insan, araç ve hayvan hareketleri zemine etki eden dış kuvvetlerdendir ve sismik dalgaların oluşmasına neden olurlar. Yapılan akademik araştırmalar sismik sinyal kaynağı olarak depremleri incelemiştir. Son zamanlarda ise insan, araba ve hayvan gibi kaynakların çıkardıkları sismik işaretler kullanılarak tespit ve sınıflandırma yapabilen uygulamalar geliştirilmeye başlanmıştır.

Sismik dalgalar Şekil 2.1’de gösterildiği gibi iki ana kategoriye ayrılır: Yüzey dalgaları ve Cisim dalgaları. Bu dalgalar Rayleigh ve Love olarak da adlandırılmaktadır. Yer yüzeyine yakın ve paralel olarak ilerler. Diğer taraftan, P ve S adı verilen cisim dalgaları ise daha derinlere doğru inerek farklı yönlerde daha hızlı ilerler. Bu dalgalar 3 yönde ilerleme sergilerler.



Şekil 2.1: Sismik dalga türleri.

Yapılan çalışmaların gösterdiği sonuçlar şu şekildedir. Deprem, patlama ya da insan hareketi kaynaklı sismik hareketler, yüzeye yakın gerçekleştiği için enerjinin büyük kısmı yüzey dalgaları olarak yayılmaktadır. Oluşan sismik enerjinin yaklaşık %70'i Rayleigh dalgaları ile, geri kalan %30'u ise cisim dalgaları aracılığı ile zeminin derinliğine doğru iletilir. Bu sebepten dolayı insan, araç ve hayvan algılaması ve sınıflandırma işlemi için çoğunlukla yüzey dalgalarına, özellikle Rayleigh dalgalarına odaklanılmıştır [1].

2.1.1. Yüzey Dalgaları

Yüzey dalgaları, elastik bir ortamda meydana gelen ve bu ortamın yüzeyi boyunca yayılan sismik dalga türleridir. Bu dalgalar yeryüzüne paralel olarak hareket ettikleri için zemine yakın bölgelerde algılanır. Yüzey dalgaları genellikle iki ana türde sınıflandırılır. Rayleigh dalgaları ve Love dalgaları.

Rayleigh dalgaları, İngiliz fizikçi Lord Rayleigh tarafından teorik olarak öngörölmüş ve onun adıyla anılmıştır. Bu dalgalar hem dikey hem de yatay düzlemde eliptik bir yörünge boyunca hareket eden partiküller ile karakterize edilir. Yani, yer yüzeyine paralel ve dik bir doğrultuda aynı anda ilerleyerek, hem yukarı-aşağı hem de ileri-geri hareket oluşturur. Bu tür dalgalar, su dalgalarına benzer bir hareketle yeryüzünde yayılır. Cisim dalgalarına göre genellikle daha yavaş hareket ederler. Bu nedenle deprem sonrasında hissedilen son dalgalardan biridir. Enerji kayıpları düşük olduğundan dolayı uzun mesafelerde algılanabilirler. Yer yüzeyine daha yakın

kaynaklardan meydana gelen sismik olaylarda, bu dalgalar yüksek bir enerji taşıyarak binalara ve altyapılara önemli hasarlar verebilir [2].

Love dalgaları, İngiliz matematikçi Augustus Edward H. Love tarafından keşfedilmiş ve onun adıyla anılmıştır. Tamamen yatay düzlemde ilerleyen ve yüzeydeki yatay hareketten sorumlu olan dalgalardır. Love dalgalarında partiküller ilerledikleri doğrultuya dik yönde hareket eder, bu da saf yatay bir kayma oluşturur. Bu dalgalar sadece katmanlı ortamlarda ortaya çıkar ve genellikle enerji yoğunluğunun yüksek olduğu yerlerde etkili olur. Love dalgalarının hızı Rayleigh dalgalarına göre daha yüksektir. Ancak tahrip edici etkileri yatayda hareket ettikleri için daha bölgeseldir [2].

Yüzey dalgaları, sismik olayların anlaşılması ve yer altı yapısının incelenmesi açısından önemli dalgalardır.

2.1.2. Cisim dalgaları

Cisim dalgaları, yer kabuğunun iç bölgelerinde yayılan ve zeminin iç yapısında ilerleyen sismik dalgalardır. Sismik olaylar sırasında ortaya çıkan bu dalgalar, yer altındaki farklı yoğunluklara ve kayaç özelliklerine göre farklı hızlarda yayılır. Cisim dalgaları, genellikle yeryüzüne daha yakın yüzey dalgaları ile karşılaştırıldığında daha hızlı hareket eder ve enerjiyi yeryüzüne doğru taşıyan önemli bir bileşendir.

Cisim dalgaları iki ana türde incelenir. P dalgaları (Primer dalgalar) ve S dalgaları (Secunder dalgalar). Bu dalgalar, yer hareketlerini anlamak ve sismik olayları analiz etmek için temel veriler sağlar.

P dalgaları, birinci dalgalar olarak adlandırılır çünkü sismik olaylar sırasında en hızlı yayılan dalgalardır ve ilk algılanan sismik dalga türüdür. P dalgaları, boyuna dalgalar olarak da bilinir. Hareket yönüyle aynı doğrultuda sıkışma ve genleşme hareketi de oluşur. Yer içerisindeki kayaçlar ve sıvılarda ilerleyebilirler, bu da onları hem katı hem de sıvı ortamlarda yayılabilen tek sismik dalga türü yapmaktadır [3].

P dalgalarının yayılma hızı, yer kabuğunda yaklaşık 5-8 km/s arasındadır, bu da onları sismik olaylar esnasında ilk algılanan dalga türü yapmaktadır. Depremlerin erken uyarı sistemleri açısından büyük öneme sahiptirler. Çünkü diğer sismik dalgalardan önce yer yüzeyine ulaşırlar.

S dalgaları, ikincil dalgalar olarak adlandırılır ve P dalgalarından sonra gelen daha yavaş dalgalardır. S dalgaları enine dalgalar olarak da bilinirler ve hareket yönüne dik doğrultuda titreşim oluştururlar. Bu özellikleri nedeniyle S dalgaları, yalnızca katı ortamlar boyunca yayılabilirler ve sıvılar üzerinden geçemez. Bu durum, S dalgalarının gezegenimizin iç yapısını anlamada önemli bir araç olmasını sağlar. Çünkü S dalgaları yer kabuğundaki sıvı ve katı bileşenler hakkında önemli bilgi verir. S dalgalarının yayılma hızı, P dalgalarına göre daha yavaştır ve genellikle 3-4 km/s civarındadır. S dalgaları, büyük yer hareketlerine neden olabilir ve yıkıcı etkileri artırır çünkü yüzeye yakın kayaların yanal hareketlerini tetikler [4].

2.1.3. Sismik Sensörler

Sismik sinyallerin kaydedilmesi için jeofon ve ivmeölçer adı verilen sensörler kullanılmaktadır. Bu sensörler, kütleyen etki eden hız veya ivme değerlerini ölçen cihazlardır. Jeofon ve ivmeölçer farklı zeminlerde farklı davranışlar sergileyen sensörler olup çevresel koşullara bağlı olarak birbirlerine göre çeşitli avantajlar ve dezavantajlar sunmaktadır. Bu çalışmada sismik sensör olarak ivmeölçer kullanılmıştır.

2.1.3.1. Jeofon

Jeofonlar, yer hareketlerini algılayarak bu titreşimleri elektriksel sinyallere çeviren sensörlerdir. Bu sensörler pasif analog sensörlerdir. Jeofon yapısı itibari ile bir spiral tel içerisinde hareket eden yay mekanizmalı manyetik bileşenden oluşur. Zemin titreşimleri, jeofon içerisindeki manyetik bileşeni hareket ettirir ve bu hareket elektriksel sinyale dönüştürülür. Jeofonların farklı zemin koşullarına göre ve titreşim kaynaklarına göre çeşitli türleri mevcuttur [5].

1. Bobin/Mıknatıs Jeofonlar: Bu jeofonların çalışması, elektromanyetik indüksiyon prensibine dayanır. Manyetik bir alan içerisindeki telin hareketi, bir elektrik akımı oluşturur. Bu elektrik sinyalinin şiddeti de yer hareketlerin hızına ve şiddetine bağlıdır.
2. MEMS Jeofonlar: MEMS jeofonlar, çok düşük ve yüksek frekanslı titreşimleri hassas bir şekilde algılayabilir ve ivme ile orantılı sinyal üretir. Ancak, bu

sensörler genellikle daha yüksek gürültü seviyesine sahiptir ve pahalı olabilirler.

2.1.3.2. İvmeölçer

Sismik çalışmalarda sıklıkla kullanılan bir diğer sensor türü ivmeölçerdir. İvmeölçerler, bir nesneye etki eden ivmeyi ölçebilen sensörlerdir. Hem bilimsel araştırmalarda hem de endüstriyel uygulamalarda geniş bir kullanım alanına sahiptirler. İvmeölçerler cep telefonları, fotoğraf makineleri, bilgisayarlar ve stabilizasyon sistemlerinde titreşimlerin olumsuz etkilerini azaltmak amacıyla kullanılmaktadır. Bunun yanında, daha gelişmiş ivmeölçerler, uçaklar, gemiler, insansız hava araçları, füzeler ve navigasyon sistemlerinde kritik bir rol oynarlar. Ayrıca ivmeölçerler atalet ölçüm birimlerinin (Inertial Measurement Unit, IMU) önemli bileşenlerindendir.

Sismik çalışmalarda ivmeölçerler, yer hareketlerini ölçmek amacıyla düşey ve yatay eksenlerdeki titreşimleri kaydeder. Bu sensörlerde, jeofonlarda olduğu gibi MEMS (Mikro elektromekanik Sistemler) teknolojisi ile üretilir. İvmeölçerlerin tek eksenli veya çok eksenli modelleri mevcuttur. İvmenin büyüklüğünü ve yönünü ölçerler. Ayrıca yönelim, titreşim, şok ve dirençli ortamlardaki düşme gibi dinamik olayları tespit etmek amacıyla da yaygın şekilde kullanılırlar [6].

Bu çalışmada titreşim verilerini ölçmek için ivmeölçer kullanılmıştır.

2.2. Akustik Sinyaller

Akustik sinyaller, bir kaynaktan yayılan ve bir ortamda titreşimler yoluyla iletilen ses dalgalarının oluşturduğu fiziksel olaylardır. Ses dalgaları gaz, sıvı veya katı ortamlar boyunca yayılır ve akustik sinyaller insan kulağıyla algılanır ya da özel sensörler tarafından kaydedilebilir.

Akustik sinyaller yayılım sırasında ses dalgaları oluştururlar. Bu dalgalar sıkışma ve genişleme hareketleri şeklinde ilerler. Akustik sinyallerin bazı temel özellikleri mevcuttur. Frekans, genlik, dalga boyu ve hız gibi bu bilgiler akustik sinyalleri tanımlamada kullanılabilecek özelliklerdir.

Akustik dalgalar, farklı ortam ve koşullarda bilgi taşıma kapasitesine sahip olup, geniş bir alanda kullanılabilir. Ancak bu sinyallerin işlenmesi sırasında bazı zorluklar ortaya çıkabilmektedir.

- Gürültü ve Parazitler: Ortamda bulunan başka sesler, akustik sinyaller üzerinde gürültü ve parazit oluşturabilir, bu da sinyalin analiz edilmesini zorlaştırmaktadır.
- Zaman-frekans Çözünürlüğü: Özellikle düşük frekanslı sinyallerin işlenmesi sırasında zaman ve frekans çözünürlüğü arasında denge kurmak zor olabilmektedir.

Buna rağmen, akustik sinyaller geniş uygulama yelpazesi ve taşınabilirliği, onları birçok araştırma ve mühendislik disiplinde vazgeçilmez kılmaktadır.

2.3. Makine Öğrenmesi Tabanlı Çalışmalar

Park ve arkadaşları tarafından 2009 yılında gerçekleştirilen “Cadence analysis of temporal gait patterns for seismic discrimination between human and quadruped footsteps” adlı çalışmada, yavaş bir hızda yürüyen, dört ayaklı canlının yürüyüş frekansı ile insanın yürüyüş frekansları benzerlik gösterebilmektedir. Bundan dolayı, sınıflandırma işlemlerinde düşük tanıma doğruluğu elde edilebilmektedir. Çalışma yürüyüş frekansının otomatik korelasyon fonksiyonu kullanılarak hesaplanan tempo ile birleştirilmesinin, sınıflandırma işlemlerinde karşılaşılan düşük başarı sorununun çözülmesinde etkili olacağını vurgulamışlardır. Ayrıca, sinyal-gürültü oranını (SNR) iyileştirmek için bir bant geçiren filtre uygulaması gerçekleştirmişlerdir. Sinyalin zarfını elde edebilmek için Hilbert dönüşümü ve düşük geçiren bir filtre kullandıktan sonra, GKM (Gauss Karışım Modeli) sınıflandırıcısı kullanmışlardır. Bu çalışmada bir at, bir köpek, birden fazla kişinin yürümesi/koşması ve tek bir kişinin yürümesi/koşması ayrımı yapılmaya çalışıldı. Geliştirdikleri yöntem ile %95 doğruluk oranı yakaladıklarını çalışmalarında rapor etmişlerdir [2].

E. Özgündüz ve arkadaşları “Vehicle Identification using Acoustic and Seismic Signals” adlı çalışmalarında, Amfibi Hücum aracı ile Dragon Wagon askeri tip araçların sınıflandırılması için bir algoritma geliştirmiştir. Akustik ve sismik sinyaller üzerinden MFKK yöntemini kullanarak öznelik çıkartımı işlemi gerçekleştirmiştir. Elde ettikleri öznelikleri kuantalama yöntemi ile azaltmışlardır. Boyut azaltma işlemi

yaptıktan sonra k-EYK ve DVM yöntemlerini kullanarak sınıflandırma işlemini gerçekleştirmiştir. Daha sonra sınıflandırma performansını karşılaştırmaya yönelik bir çalışma gerçekleştirmişlerdir. Bu çalışmada DVM kullanılarak %82'lik bir başarı elde edilmiştir [6].

Ghosh ve arkadaşları 2015'te yaptıkları "Time-frequency analysis based robust vehicle detection using seismic sensor" çalışmalarında araç tespiti için Pseudo-Wigner-Ville Dağılımı (PWVD) tabanlı zaman-frekans analizi yöntemine kullanmıştır. Bu dağılım üzerinden Renyi entropisi hesabı yaparak araç tespiti için bir yöntem önermişlerdir. Kullanmış oldukları PWVD zaman-frekans uzayında değişken sinyallerin enerji dağılımlarını sunar. Bu dağılım bir yoğunluk fonksiyonu olarak düşünülmüştür. Renyi entropi değeri ise enerjinin dağılımını ölçmek için kullanılmıştır. Yüksek entropi olası sismik olayın varlığını göstermektedir. Buldukları entropi değerleri üzerinden Sabit Yanlış Alarm (SYA) kullanmışlardır. Araç tespit işlemi gerçekleştirmişlerdir. Önerdikleri yöntemi klasik spectrogram yöntemi ile karşılaştırmışlardır. Belirgin şekilde yanlış alarm verme oranında azalma ve tespit oranında artış gözlemlemişlerdir [7].

Kalra ve arkadaşları 2018'de yaptıkları "Target Detection using Smooth Pseudo Wigner-Ville Distribution" SITEX02 açık kaynak veri setini kullanarak çalışmalarında zaman-frekans uzayı tabanlı SPWVD tekniğini kullanmışlardır. Bu dağılım üzerinden Renyi entropi değerini hesaplamışlardır. Daha sonra SYAH eşikleme yöntemini kullanarak hedef tespiti işlemini gerçekleştirmişler. Elde ettikleri sonuçları Gosh ve arkadaşlarının yapmış olduğu Pseudo WignerVille tabanlı çalışması ile karşılaştırmışlardır. Burada önerdikleri SPWVD tabanlı yöntem ile daha yüksek doğru pozitif tespit oranı yakalamışlardır, fakat PWVD yöntemine göre yanlış alarm oranı da yüksektir. Ama SPWVD yönteminin PWVD yöntemine kıyasla daha hızlı çalıştığını göstermişlerdir. Böylelikle daha hızlı hedef tespiti yapılabileceğini göstermişlerdir. Çalışmalarında kullandıkları askeri hedeflerin gerçekleştirdikleri çalışma için yanlış alarm oranına bağlı olarak sivil uygulamalarda hedef tespiti için kullanılmasının daha uygun olabileceğini belirtmişlerdir [8].

Bodhibrata ve arkadaşları 2018 yılında yaptıkları "Detection an Intruder and Prediction of His State of Motion by Using Seismic Sensor" adlı çalışmalarında zemin içerisine yerleştirdikleri jeofon ile yürüyüş, koşar adım yürüyüş ve koşan hedeflerin sınıflandırması yapmışlardır. Çalışmalarında 2 aşama izlemişlerdir. İlk aşamada tespit

işlemini yapmışlar ikinci adımda ise sınıflandırma işlemini gerçekleştirmişlerdir. Tespit işlemi için 4 farklı yaklaşımı birbirleri ile kıyaslamışlardır. Kullandıkları tespit teknikleri sırasıyla “Genlik Eşikleme”, “Basıklık Tabanlı Olay Tespiti”, “STA/LTA (Kısa süreli Ortalama/ Uzun Süreli Ortalama) Tabanlı Olay Tespiti”, “Değiştirilmiş Enerji Oranı Tabanlı Olay Tespiti” bu yöntemlerden her sınıf için gerçekleştirilen tespit başarı karşılaştırmaları yanlış alarm oranı üzerinden yapılmıştır. “Genlik Eşikleme” yöntemi ile yanlış alarm oranı sıfır olacak şekilde bir sonuç elde etmişlerdir. Olayı tespit ettikten sonra öznitelik çıkartımı işlemi gerçekleştirmişlerdir. Burada zaman ve frekans uzayı üzerinden öznitelik çıkartılmıştır. Zaman uzayı özneliği olarak ortalama, standart sapma, kurtosis (basıklık), skewness (çarpıklık), sıfır kesme oranı, tepe sayısı oranı kullanılmıştır. Frekans uzayı özneliği olarak olayın tespit edildiği sinyal parçasının 2048 noktalı fft’si hesaplanmıştır. Daha sonra 0-100Hz arası bölgenin ortalama, standart sapması ve sıfır kesme oranı öznitelik olarak kullanılmıştır. Sınıflandırıcı olarak DVM, YSA, k-EYK, DAA gibi sınıflandırıcılar kullanılmıştır. Doğruluk, kesinlik ve duyarlılık performans metrikleri kullanılarak sınıflandırma performansları karşılaştırılmıştır. DVM sınıflandırıcısı ile %81 gibi bir başarı yakalamışlardır [9].

Kalra ve arkadaşlarının 2020’de yaptıkları “Seismic Signal Analysis using Empirical Wavelet Transform for Moving Ground Target Detection and Classification” çalışmalarında sismik sinyal kullanarak hareketli yer hedeflerinin tespiti ve sınıflandırılması için Ampirik Dalgacık dönüşümünün (ADD) potansiyeli incelenmiştir. EWD, sismik sinyallerdeki bilgileri temel alarak adaptif dalgacık fonksiyonların oluşturan bir yöntem sunmaktadır. Çalışma kapsamında hareketli yer hedefi olarak otobüs ve traktörün sismik imzaları jeofon dizisi kullanılarak kaydedilmiştir. Bu şekilde oluşturdukları veri setinden EWD tabanlı zaman-frekans katsayılarını kullanarak ortalama, renyi entropi, enerji yoğunluğu, varyasyon katsayısı, kurtosis gibi öznitelikleri elde etmişlerdir. Bu öznitelikleri DVM ve k-EYK sınıflandırıcıları ile sınıflandırmışlardır. DVM sınıflandırıcısında çekirdek fonksiyonunu quadratic çekirdek fonksiyonu seçimi yapmışlardır. 5 kere çapraz doğrulama işlemi gerçekleştirmişlerdir. k-EYK sınıflandırıcı için 10 noktalı komşuluklarına bakılmış mesafe ölçütü olarak Öklid mesafesi kullanılmıştır. Performans metriği olarak F skoru ve ROC eğrisi altındaki alan (AUC) parametresi ile değerlendirilmiştir. EWD yöntemi ile bir başka zaman-frekans analizi yöntemi olan

Kısa Zamanlı Fourier Dönüşümü (KZFD) yöntemi ile performans karşılaştırılması yapılmıştır. EWD tekniği kullanılarak elde edilen her bir sınıf için elde edilen F skoru sonuçları otobüs, traktör ve gürültü için sırasıyla %78, %67, %86 olarak elde edilmiştir. KZFD yöntemi ile kıyaslandığı zaman ortalama olarak %8’lik bir iyileşme sağladıkları görülmektedir [10].

Okutan 2016 yılında gerçekleştirdiği “Sismik Sinyal işleme tabanlı hedef tespiti ve sınıflandırması” adlı tez çalışmasında insan ve hayvan yürüyüşlerini tespit etme ve sınıflandırma konusunu işlemiştir. At ve insan titreşimlerini oluşturdukları veri toplama istasyonu ve jeofon yardımı ile elde etmişlerdir. Sinyallerin sahip olduğu DC bileşenleri çıkarma işlemi ve gürültü giderme gibi ön işleme adımlarını uygulamıştır. Öznitelik çıkarımı için zaman-frekans analizi tabanlı KZFD yöntemini kullanmıştır. Elde ettiği 2 boyutlu sinyal üzerinden kurtosis özniteliği çıkartmıştır. DAA (Doğrusal Ayırıcı Analiz), DVM ve DVVA (Destek Vektör Veri Açıklaması) sınıflandırıcıları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Çalışmada en başarılı sonuç KZFD-DAA yöntemlerinin birlikte kullanılması ile elde edilmiştir [11].

Pucci ve arkadaşları 2020 yılında gerçekleştirdikleri “Human activities classification using biaxial seismic sensors” adlı çalışmalarında hangi tür sismik sensör (yatay mı, dikey mi) hangi tür sismik aktiviteyi tanımlamak için daha uygundur? Sorusuna yanıt arayan bir çalışma gerçekleştirmişlerdir. Araştırmalarında, dikey sismik sensörlerin insan aktivitelerini (örneğin koşma ve yürüme) tanımlamada daha iyi olduğunu, yatay sismik sensörlerin ise araç hareketlerini tanımlamada daha başarılı olduğunu buldular. Hedef aktivitelerinin güç spektral yoğunluğunu hesapladılar. Ardından elde edilen özellikler üzerinden boyut azaltımı için Temel Bileşen Analizi (TBA) uyguladılar. DVM sınıflandırıcısı kullanarak %98.00 ortalama doğruluk elde ettiler [12].

2.4. Derin Öğrenme Tabanlı Yöntemler

Wang ve arkadaşları 2019 yılında gerçekleştirdikleri “Convolutional neural network based moving ground target classification using raw seismic waveform as input” adlı çalışmalarında sismik sinyallerin doğasının konuma göre değişiklik göstereceğini belirtmişlerdir. Sinyaldeki bu farklılıklar, aktivitelerin tanımlanmasını zorlaştırmaktadır. Bu sorunu çözmek amacıyla, özellik çıkarım sürecini otomatikleştiren 1-D ESA (Evrişimli Sinir Ağları) tabanlı bir çerçeve olan VibESA’yı

önermişlerdir. Önerilen modelin performansını değerlendirmek için farklı jeofizik koşullara sahip arazilerde, yayalar ve çeşitli tekerlekli ve paletli araçlar kullanarak veri toplama işlemini gerçekleştirmişlerdir. VibESA modeli, üç sınıflı bir sınıflandırma probleminde %95,49 doğruluk oranı yakalamıştır. Önerilen modelin performansını geleneksel makine öğrenmesi algoritmalarından olan DVM, k-EYK, GKM ve YSA yöntemleri ile karşılaştırmışlardır. Geleneksel yöntemlerin performansı VibESA'nın performansına ulaşamamıştır [13].

Qian ve arkadaşları 2023 yılında yaptıkları “Target Classification in Unattended Ground Sensors with a Two-Stream Convolutional Network” adlı çalışmada saha hedeflerinin sınıflandırması için bir çalışma gerçekleştirmişlerdir. Bu çalışmada saha hedefi olarak insan, paletli ve tekerlekli araçların sınıflandırılması amaçlanmıştır. Çalışmayı gerçekleştirmek 2 akışlı ESA tabanlı bir ağ tasarımı önerilmektedir. Ham ses verisi ve sismik veriyi kullanan WaveNet ve log mel spektogramına dayalı LMNet olmak üzere 2 farklı ağ tasarlanmıştır. Önerilen ağ, dört kanallı akustik sinyalin ve tek kanallı sismik sinyalin derin özelliklerini çıkartarak birleştirmekte ve nihai hedef sınıflandırma sonuçlarını elde etmektedir. Ayrıca sınırlı eğitim verisinin oluşturacağı aşırı öğrenme sorununu çözmek için veri arttırımı yöntemi de anlatılmıştır. Çalışmada oluşturulan model sismik, akustik ve akustik-sismik veri kümelerinde sırasıyla %86,0, %92,5, %98,0 başarı skorlarını elde etmiştir [14].


Sun ve arkadaşlarının 2023 yılında yaptıkları “Vehicle Acoustic and Seismic Synchronization Signal Classification Using Long-term Features” adlı çalışmada hafif tekerli, ağır vasıtalı araç ve binek araç sınıflandırması gerçekleştirebilen bir algoritma önerilmiştir. Akustik sensör olarak ICS-40720 mikrofonu kullanılmıştır. Sismik sensör olarak OMNI-2400 jeofonu kullanılmıştır. Mikrofonun örnekleme frekansı 8192 Hz. olarak jeofon verileri ise 1024 Hz. olarak toplanmıştır. Elde edilen sinyaller üzerinden öznitelik çıkarımı işlemi LTCFN (Long-term correlation feature network) modeli önerilmiştir. Model AlexNet tipi bir öznitelik çıkarıcı ve UKSB ağı ile uygulanan genel bir sınıflandırıcı modeli içermektedir. LTCFN modeli ilk aşamada sinyallere pencereleme işlemi uygular. Küçük parçalara ayrılmış Akustik ve sismik sinyaller ESA tabanlı oluşturulan AlexNet modeli ile öznitelik çıkarımı işlemi gerçekleştirilir. Daha sonra öznitelik kaynaştırma işlemi gerçekleştirilir. UKSB modeli kullanılarak sınıflandırma işlemi tamamlanmıştır. Çalışmada ek olarak AlexNet öznitelikleri, MFKK ve Wavelet katsayıları ile öznitelikler hesaplanmış ve UKSB ağı ile

sınıflandırılmıştır. AlexNet ile elde edilen sonuçlar daha başarılı çıkmıştır. Sınıflandırıcı performansını karşılaştırmak UKSB ile DVM sınıflandırıcısı karşılaştırılmıştır. Çalışmanın sonucu olarak önerilen LTCFN modeli ile %96 başarı elde edilmiştir [15].

Bundan sonraki bölümde kullanılan sinyallerin fiziksel özelliklerinden ve kullanılan yöntemlerin teorik alt yapılarından bahsedilecektir.


3. YÖNTEM

Bu tez çalışmasında sınır güvenliğini sağlamak amacıyla mikrofon ve yol yüzeyine yerleştirilmiş 3 eksen ivme ölçer ile insan, araba ve boş ortam sınıflandırmasının yapılması amaçlanmıştır. Ortamdaki akustik ve sismik sinyallerin insan mı araba mı olup olmadığının belirlenmesi literatürde sınıflandırma problemi olarak ele alınmaktadır. Birden çok sensörün birlikte kullanıldığı çalışmalarda problemin çözümü için iki sensör verisinin birleştirilmesi yaklaşımları sıklıkla kullanımına başvurulmuş bir çözüm yoludur. Fakat, sensör bilgilerinin hangi aşamada birleştirilmesi gerektiği, çoklu sensör kullanılan sistemlerde sistem performansı ve sınıflandırma başarısını doğrudan etkileyen bir faktör olarak öne çıkmaktadır. Bu bağlamda, çalışmada yenilikçi bir yaklaşım önerilmiştir. Önerilen model, iki aşamalı bir sınıflandırma sürecine dayanmaktadır. İlk aşamada, hareketli hedeflerin tespit edilmesi amaçlanmıştır. Bu aşamada, sensör verileri ayrı ayrı analiz edilmiş ve sensörlerin farklı cevaplar verdiği durumlarda sensör bilgileri birleştirilmiş ve tespit işlemine o şekilde karar verilmiştir. Bu süreç sonucunda elde edilen tespitlerden hareketli hedefler, sınıflandırılması için ikinci aşamaya aktarılmıştır. İkinci aşamada, hareketli hedeflerin sınıflandırılması gerçekleştirilmiştir.



Şekil 3.1: Genel akış diyagramı.

Çalışmada gerçekleştirilen adımlar Şekil 3.1’te genel olarak gösterilmiştir. Önerilen algoritma ise Şekil 3.1’te gösterilen Sınıflandırma adımı içerisinde temsil edilmektedir. Sınıflandırma adımının ilk aşamasında hareketli hedef tespiti yapılması amaçlanmıştır. İkinci adımda ise hareketli hedefin sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma adımı Şekil 3.2’te daha detaylandırılmıştır.



Şekil 3.2: Detaylı algoritma akış diyagramı.

Şekil 3.1’ de Titreşim verisi ve Ses verisi olarak ifade edilen kutucuklar Şekil 3.2’ de bahsedilen Boyut Azaltımı sonrası elde edilmiş olan verileri ifade etmektedir. Model-1 Titreşim verileri kullanılarak hareket tespit etmek üzere eğitilmiş bir modeldir. Model-2 ‘de ses verileri kullanılarak hareket tespit etmek üzere eğitilmiş bir modeldir. Model-3 titreşim ve ses verilerinin birleştirilmesi ile eğitilmiş ve hareket tespit etmek üzere eğitilmiştir. Burada Model-3 Tespit başarısını arttırmak amacıyla algoritmaya eklenmiştir. Model-4’ün minimum arka plan verisi ile karşılaşmasını sağlayarak sistemin hareketli hedef sınıflandırma başarısının artırılması amaçlanmaktadır. Model-4 ise insan ve araba örnekleri kullanılarak titreşim ve ses sensörlerinin birleştirilmiş hali ile eğitilmiş bir modeldir.

Bölümün ilerleyen başlıklarında veri toplama, veri etiketleme, Şekil 3.1 ve Şekil 3.2’ de gösterilen bloklarda kullanılan yöntemlerin detaylı ve teorik açıklamaları anlatılmaktadır.

3.1. Veri Toplama

Makine öğrenmesi süreçleri için gerekli verilerin toplanması geliştirme sürecinin ilk adımını oluşturmaktadır. Çözüm bulunacak problem için veriler değişiklik gösterebilmekte ve çeşitli sensörler aracılığı ile geliştirici tarafından bu veriler toplanabilmektedir. Verilerin veri tabanına kaydedilmesi bu adımda gerçekleştirilir. Toplanmış olan verilerin kalitesi, modelin öğrenme başarısını doğrudan etkileyen en önemli faktördür. Yetersiz veya hatalı veriler modelin performansını olumsuz yönde etkilemektedir.

Bu çalışma kapsamında, farklı zeminler üzerinden veri toplama işlemi gerçekleştirilmiştir. Beton, asfalt ve toprak yol üzerinde veri toplanmıştır. Veri toplama işlemi Gebze’de bulunan Bilişim Vadisi içerisinde gerçekleştirilmiştir. Hedefler ile sensörler arasında 1 metre, 2 metre ve 5 metre olacak şekilde veriler toplanmıştır.




Şekil 3.3: Veri toplama sahası.

3.1.1. Veri Etiketleme

Denetimli öğrenme yöntemleri için gerekli olan bir değer adım ise veri etiketleme adımımızdır. Veri setinde bulunan her bir örnek için doğru etiketin belirlenmesi gerekir.

Bu kısımda yanlış veri etiketinin verilmesi geliştirilen modelin başarısını önemli ölçüde azaltacaktır. Çünkü model gerçekleşen bir olayı yanlış etiket ile tanımaya ve olayın özelliklerini yanlış olay ile tanımış olacaktır. Bu da modelin yanlış cevaplar üretmesine sebep olacaktır.

Yapılan çalışmada toplanılan sinyaller üzerinden veri etiketlemek için Matlab üzerinde bir arayüz oluşturulmuştur. Mikrofon verileri 4 kHz ile örneklenmiş ve ivmeölçer verileri ise 200 Hz. örnekleme frekansına sahiptir. Geliştirilen Arayüz ile mikrofon verileri dinlenmiş ve olayın başlangıç ve bitiş anları etiketlenmiştir. Titreşim verileri için sensörün en yüksek değer yaptığı noktanın önünden ve arkasından etiketleme işlemi gerçekleştirilmiştir. Daha sonra etiketlenen veriler etiketli halleri ile bilgisayara kaydedilmiştir.



Şekil 3.4: Veri etiketleme arayüzü.

3.2. Öznitelik Çıkarımı

Makine öğrenmesi ve örüntü tanıma sistemlerinde öznitelik çıkarma algoritmalarının temel amacı, ham verilerden anlamlı özellikleri etkili ve optimal bir şekilde temsil eden bir bilgi seti elde etmektir. İyi bir öznitelik çıkarma algoritması, her sınıfa ait sinyal özelliklerini koruyarak veya iyileştirerek toplam veri miktarını azaltabilir ve sınıflandırma performansını artırabilir. Bu nedenle başarılı bir sistem geliştirmek için, her uygulamanın gereksinimlerine özel bir algoritma tasarlamak büyük önem taşımaktadır. Algoritmanın belirli bir hedefi tespit ve sınıflandırabilmesi için tasarımın optimize edilmesi gerekmektedir. Bu araştırma kapsamında, hedeflerin doğru

tanımlanabilmesi genellemesini geliştirebilmek için hangi özniteliklerin diğerlerine göre daha uygun olduğu deneysel olarak anlaşılması zor ama kritik bir adımdır. Eğer algoritma üstlendiği görevi düşük maliyetle ve hesaplama açısından verimli şekilde yerine getirebiliyorsa, çalışmada öznitelik çıkarımı ideal bir seçenek haline gelir. Bu nedenle bu çalışmada seçilen öznitelikler aşağıda incelenmiş ve açıklanmıştır.

Öznitelik çıkarma teknikleri genellikle işlenen sinyalin ait olduğu işlem uzayına göre üç kategoriye ayrılır: zaman, frekans ve zaman-frekans uzayı şeklindedir. Bu bölümde bu alanda kullanılan belirli öznitelik çıkarma tekniklerine ilişkin yöntemler ele alınmıştır. Literatürde bu tarz çalışmalarda kullanılabilecek birçok teknik mevcuttur. Ancak, bu bölümde diğer araştırmacılar tarafından da önerilen ve özellikle mevcut akustik ve sismik sinyaller hedef sınıflandırma konusuna uygun olduğu değerlendirilen öznitelik çıkarma teknikleri açıklanmaktadır. İdeal bir öznitelik algoritması, aynı sınıfa ait öznitelik vektörlerinin birbirine yakın olmasını sağlarken, farklı sınıflara ait vektörlerin öznitelik uzayında uzak bir mesafede kalmasını sağlar. Ayrıca, yüksek boyutlu öznitelik verilerin iyi sonuçlar vereceğinden bahsedilmemektedir.

Bu çalışmada öznitelikler çıkarımı işlemi birer saniyelik pencereler kullanılarak zaman uzayı ve frekans uzayı öznitelikleri kullanılarak bir öznitelik matrisi elde edilmiştir. Kullanılan sensörler için ortak hesaplanan öznitelikler olmakla beraber ortak olmayan özniteliklerde mevcuttur.

3.2.1. Zaman Uzayı Öznitelikleri

Mikrofon ve ivmeölçer sensörlerinden farklı örnekleme frekansı ile toplanmış olan zaman serisi işaretler bir saniyelik dikdörtgen pencere ile pencerelenerek istatistiksel olarak farklı öznitelikleri elde edilmiştir. Titreşim verileri için 200 noktalı bir dikdörtgen pencere ve mikrofon verileri için 4000 noktalı bir dikdörtgen pencere kullanılmıştır. Kullanılan öznitelikler ve bu özniteliklerin nasıl hesaplandığı aşağıda açıklanmıştır.

3.2.1.1. Basıklık (Kurtosis)

Bir veri dağılımının kuyruk yapısını ve uç değerlerinin yoğunluğunu ölçen istatistiksel özelliktir. Diğer bir deyişle, veri setinin uç noktalara olan duyarlılığını ve veri

dağılımının sivriliğini ifade eder. Basıklık dördüncü ortalama etrafındaki moment olarak ifade edilir. Aşağıdaki şekilde hesaplanır.

$$Kurtosis = \frac{n \sum (x_i - \bar{x})^4}{[\sum (x_i - \bar{x})]^2} - 3 \quad (3.1)$$

Burada:

- n : Veri setindeki eleman sayısı.
- x_i : Veri setindeki her bir örnek
- $\bar{x}$: Veri setinin ortalaması.

Ortalama aşağıdaki şekilde hesaplanır.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.2)$$

3.2.1.2. Çarpıklık (Skewness)

Bir zaman serisi işaret için verinin dağılımının simetrik olup olmadığını ve dağılımın hangi yöne doğru eğilim gösterdiğini ölçen bir istatistiksel özelliktir. Diğer bir deyişle veri setindeki dağılımın ortalamaya göre sağa veya sola kayıp kaymadığını belirlemek için kullanılır. Bu özelliği sebebi ile verilerin normal dağılımdan sapma derecesini gösterir ve verinin istatistiksel olarak modellenmesinde önemli bir rol oynar. Aşağıdaki formül ile hesaplanır.

$$Skewness = \frac{n}{(n-1)(n-2)} \sum \left(\frac{x_i - \bar{x}}{s} \right)^3 \quad (3.3)$$

Burada:

- n : Veri setindeki eleman sayısı.
- x_i : Veri setindeki her bir örnek
- $\bar{x}$: Veri setinin ortalaması.
- s : Standart sapma

3.2.1.3. Sıfır Geçiş Oranı (Zero-Cross Rate)

Sinyal genliğinin işaret deęiřtirdięi noktaların sayılmasını ieren teknikler genellikle “Sıfır Geçiř Sayısı” olarak adlandırılır. Genellikle bunun biraz daha geliřmiř bir varyasyonu olan “Sıfır Geçiř Oranı”, sıfır geiř sayısının sinyal uzunluęuna gore normalize edilmesi ile elde edilir. Ve sınıflandırma alıřmalarında kullanılır. Bunun nedeni, Sıfır Geiř Oranı farklı uzunluktaki sinyalleri adaptif bir řekilde inceleyebilme yeteneęidir. zellikle dar bant geniřlięine sahip sinyalleri iřlerken frekans bileřenlerinin kompakt bir gostergesi olarak kullanılabilir. Bu alıřmada 1 saniye uzunluęundaki sinyaller iin hesaplanmıřtır.

3.2.1.4. Enerji

Zaman uzayında toplanmıř olan ayrık zamanlı sinyalin genlięi $x[n]$ olarak tanımlandıęında, bu sinyalin enerjisi sinyalin genliğinin karesi $x^2[n]$ ile bulunur. Pratik uygulamalarda, sabit ve sınırlı bir uzunluęa sahip sinyal dilimlerinin toplam enerji deęeri Owens’ın “kısa sureli enerji fonksiyonu” olarak adlandırdıęı yntem kullanılarak hesaplanabilmektedir. Bu yntem Denklem 3.4 ile tanımlanmıřtır. Sinyalin nceden belirlenmiř bir dilim uzunluęa blnme iřlemi, dikdrtgen pencereleme fonksiyonu $W[m]$ ’nin uygulanmasıyla yapılır. Benzer řekilde, dilim boyunca ortalama enerji deęerini elde etmek iin kısa sureli enerji fonksiyonu, her dilimdeki rnek sayısına N ’ye blnerek Denklem 3.5 ile elde edilebilir.

$$E_m = \sum_{n=1}^N (x[n] * W[n - m])^2 \quad (3.4)$$

$$E_m = \frac{1}{N} * \sum_{n=1}^N (x[n] * W[n - m])^2 \quad (3.5)$$

3.2.2. Frekans Uzayı znitelikleri

Bir sinyalin zaman uzayından frekans uzayına dnřtrlmesi iřlemidir. Zaman alanında yapılan analizler temel olarak sinyalin genlięi ve zamana gore deęiřimi hakkında verirken frekans uzayında sinyalin hangi frekans bileřenlerinden oluřtuęu gzlemlenebilmektedir. Frekans uzayı analizinde kullanılan birkaç yntem mevcuttur

en yaygın olanı Fourier dönüşümüdür. Fourier Dönüşümü, bir zaman uzayı sinyalini frekans bileşenlerine ayırır ve hangi frekansta ne kadar enerjiye sahip olduğunu gösterir. Bir başka yöntem ise Fourier Dönüşümü tabanlı Güç spektral yoğunluğu kestirimi yöntemleridir.

Bu çalışmada titreşim sinyalleri için frekans uzay dönüşümü için güç spektral kestirim yöntemlerinden Welch yöntemi kullanılmıştır. Ve elde edilen frekans uzayı işaretler üzerinden spektral entropi, spektral merkez öznitelikleri hesaplanmıştır. Mikrofon verileri için ses tanıma ve sınıflandırma yöntemlerinde sıklıkla kullanılan MFKK özniteliği kullanılmıştır. Kullanılan özniteliklerin teorik arka planları aşağıda açıklanmıştır.

3.2.2.1. Güç Spektral Kestirimi

Wiener-Khinchin teoremine göre, durağan rastgele sürecin otokorelasyon fonksiyonunun Fourier dönüşümü, bu sürecin güç spektral yoğunluğunu vermektedir.

$$r_{xx}(\tau) = E[x^*(t) * x(t + \tau)] \quad (3.6)$$

$$S_{xx}(f) = \int_{-\infty}^{\infty} r_{xx}(\tau) * e^{-j2\pi f\tau} d\tau \quad (3.7)$$

Pratikte $S_{xx}(f)$ 'yi hesaplamak için Fourier dönüşümü kullanmak mümkün değildir. Çünkü gerçek otomatik korelasyon fonksiyonu $r_{xx}(\tau)$ bilinmemektedir. Ancak belirli bir zaman dilimi için zaman ortalamalı bir otokorelasyon hesaplamak mümkündür. Denklem 3.8 'de bu tanım yapılmıştır [16].

$$\tilde{r}_{xx}(\tau) = \frac{1}{N} * \int_{-\frac{N}{2}}^{\frac{N}{2}} x^*(t) * x(t + \tau) dt \quad (3.8)$$

Burada N gözlem aralığıdır. Rastgele süreçlerin ortalamada ve otokorelasyonda ergodik olduklarını biliyoruz.

$$r_{xx} = \lim_{T_0 \rightarrow \infty} \tilde{r}_{xx}(\tau) \quad (3.9)$$

Denklem 3.8'in Fourier transformunu aldığımız zaman $x(t)$ için güç spektral yoğunluğunu belirli bir N aralığı için elde etmiş oluruz. Bu işlemi ayrık zamanlı bir sinyal için gerçekleştirdiğimiz zaman Denklem 3.10 elde edilmiş olur.

$$P_{per}(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x[n] * e^{-j2\pi f n} \right|^2 = \frac{1}{N} |X(f)|^2 \quad (3.10)$$

Periodogram yönteminin avantajları herhangi bir parametreye ihtiyaç duymaz ve uygulaması kolaydır. Direk olarak sinyalin FFT'si alınarak hesaplanabilmektedir. Diğer taraftan periodogramın dezavantajları ise veri uzunluğuna bağlı olarak düşük frekans çözünürlüğüne sahip olmasıdır. Ayrıca periodogram yüksek varyansa sahiptir. Bu problemi giderebilmek için farklı yöntemler mevcuttur. Bu çalışmada titreşim sinyalleri için frekans uzay dönüşümü için güç spektral kestirim yöntemlerinden Welch yöntemi kullanılmıştır. Welch yöntemi ile periodograma iki farklı yenilik eklenmiştir. Pencereleme ve overlap eklenmiştir.

$$x_i(n) = x(n + iD) \quad (3.11)$$

$$n = 0, 1, 2, \dots, M-1$$

$$i = 0, 1, 2, \dots, L-1$$

$$\bar{P}_{xx}^i(f) = \frac{1}{M * U} \left| \sum_{n=0}^{M-1} x_i[n] * w[n] * e^{-j2\pi f n} \right|^2 \quad (3.12)$$

Burada U , penceredeki güç için bir normalizasyon faktörüdür.

$$U = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (3.13)$$

Tüm modifiye edilmiş periodogramların ortalaması alınarak, Welch spektrum tahmini elde edilir.

$$P_{xx}^{welch}(f) = \frac{1}{L} \sum_{i=0}^{L-1} \bar{P}_{xx}^i(f) \quad (3.14)$$

3.2.2.2. Spektral Entropi

Bir sinyalin frekans bileşenlerinin ne kadar düzensiz veya karmaşık olduğunu ölçmek için kullanılan bir yöntemdir. Spesifik olarak, sinyalin gücünün frekans spektrumu üzerindeki dağılımını değerlendirir ve bu dağılımın belirsizliğini hesaplar. Örnek olarak; bir sinyal düşük frekanslarda yoğunlaşmışsa ve daha düzenli bir yapıya sahipse entropisi düşük olacaktır. Buna karşın, yüksek frekanslara yayılmış ve geniş bir dağılıma sahipse entropi değeri yüksek olacaktır. Spektral entropi hesaplanırken şu adımlar izlenir.

- Sinyalin güç spektral yoğunluğu hesaplanır. Çünkü sinyalin frekans bileşenlerinin enerji dağılımlarının hesaplanması gerekmektedir. Bu aşamada genellikle Fourier dönüşümü kullanılır. Bu işlemi gerçekleştirmek için FFT algoritması kullanılır.

$$X(f) = FFT(x[n]) \quad (3.15)$$

$$PSD = |X(f)|^2 \quad (3.16)$$

- Sinyalin güç spektral yoğunluğu, her frekanstaki enerji yoğunluğunu verir. Entropiyi hesaplamak için bu spektral yoğunluğu bir olasılık yoğunluk fonksiyonu gibi ele alınması gereklidir. Bunu GSY (Güç spektral yoğunluğu)'nun her bir frekanstaki bileşenini toplam GSY' e bölerek bulabiliriz.

$$PSD = \frac{|X(f)|^2}{\sum |X(f)|^2} \quad (3.17)$$

3.2.2.3. Spektral Merkez

Bir sinyalin spektrumunun “merkezini” veya “ağırlık merkezini” temsil eden bir özneliktir. Bir sinyalin spektral merkezi değeri o sinyalin frekans içeriğinin hangi bölgeye yoğunlaştığını gösterir. Bu özellik sinyalin tonu veya parlaklığını tanımlamak için kullanılır. Yüksek spektral merkez değerine sahip sinyal için yüksek frekans bileşenlerinin baskın olduğu ve tiz bir sinyal olduğunu gösterir.

Bu özelliği itibarıyla, ses sınıflandırma ve tanıma, duygu analizi ve müzik türü sınıflandırılması gibi uygulamalarda öznelik olarak kullanılmıştır. Spektral merkez

her bir frekans bileşeninin genliği ile frekansı çarpılarak tüm spektrum boyunca ortalama alınması ile hesaplanır. Aşağıdaki denklem kullanılarak hesaplanmıştır.

$$Spektral\ Merkez = \frac{\sum_i f_i * X(f_i)}{\sum_i X(f_i)} \quad (3.18)$$

3.2.2.4. Mel Frekansı Kepstrum Katsayıları (MFKK)

MFKK, ses sinyallerinin özelliklerini çıkartmak için kullanılan bir yöntemdir. Özellikle ses tanıma ve konuşma işleme gibi alanlarda yaygın olarak kullanılır. Bu yöntem, bir ses sinyalinin insan kulağının algıladığı özelliklerini modellemek için kullanılmıştır. Bu algoritma genellikle şu adımlar kullanılarak gerçekleştirilir:

Ön işleme: Yüksek frekansların vurgulanması için sinyal bir filtreden geçirilir. Bu düşük frekansların baskınlığını azaltır.

$$y[n] = x[n] - \alpha * x[n - 1] \quad (3.19)$$

Burada α genellikle 0.95 civarında seçilir.

Çerçeveleme: Ses sinyali genellikle 20-40 milisaniye uzunluğunda çerçevelerle bölünür. Bu, sinyalin kısa süreli ve durağan olduğunu varsayar.

Pencereleme: Her çerçeveye genellikle bir Hamming penceresi uygulanır.

$$w[n] = 0.54 - 0.46 * \cos\left(\frac{2\pi n}{N-1}\right) \quad (3.20)$$

Bu, frekans spektrumunda sızıntıyı azaltır.

Hızlı Fourier Dönüşümü (FFT): Her çerçeve, frekans uzayına dönüştürülür. Bu adım, sinyalin frekans bileşenlerini analiz etmek için kullanılır.

Mel Ölçeği Filtre Bankası: İnsan kulağı, frekansları doğrusal bir ölçek yerine logaritmik bir ölçekle algılar. Bu nedenle, frekanslar Mel ölçeğine dönüştürülür.


$$M(f) = 2595 * \log_{10}\left(1 + \frac{f}{700}\right) \quad (3.21)$$

Bu ölçek kullanılarak bir dizi filtre bankası oluşturulur ve FFT sonucuna uygulanır.

Log Enerji: Her Mel frekans bandının enerjisi alınır ve logaritması hesaplanır:

Ayrık Kosinüs Dönüşümü (ACD): Enerji değerlerini elde edebilmek için ayrık kosinüs dönüşümü uygulanır. Bu, zamanla değişen özellikleri sabit hale getirir ve sinyalin en önemli özelliklerini vurgular.

MFKK yönteminin akış diyagramı Şekil 3.5'te gösterilmiştir.



Şekil 3.5: MFKK yöntemi akış diyagramı.

Sonuç olarak Mel-frekansı kestrumu, sesin temel özelliklerini etkili bir şekilde yakalayan ses sınıflandırma gibi görevlerde öznitelik olarak kullanılabilen katsayılar kümesidir.

3.3. Öznitelik Normalizasyonu

Elde edilen öznitelikler farklı çözünürlükte cevaplar üretmektedir. Bu bilgilerin belirli bir skalaya oturtulması sınıflandırmanın başarısının belirlenmesinde kritik bir görev olarak karşımıza çıkmaktadır. Bu yüzden dolayı hesaplanan tüm özniteliklere standart normalizasyon uygulanmıştır. Böylece farklı ölçeklere sahip özniteliklerin yanıltıcı olabilecek etkisi ortadan kaldırılmıştır.

3.4. Boyut Azaltma

Giriş verilerinin özelliklerini temsil etmek için kullanılan çıkarılmış özelliklerin sayısını belirli bir boyuttan fazla arttırmak, sınıflandırma sonuçlarının kötüleşmesine neden olabilmektedir. Birçok örüntü tanıma kaynağında önerildiği üzere özellik vektörlerindeki daha az belirgin öğelerin elenmesi için uygun bir boyut azaltma algoritmasının, nihai karar verme süreçlerinden önce uygulanması, doğruluk ve hesaplama verimliliği açısından sınıflandırma problemlerinde performans artışına sebep olabilmektedir [20].

Boyut indirgeme yöntemleri çeşitli şekillerde sınıflandırılabilir. İlk yaklaşım, sınıflandırma öncesinde belirli kurallara göre seçilen bir özellik alt kümesini tutarken, diğer özelliklerin elenmesini içerir. Özellikle, çıkarılan özelliklerin birbirleriyle ilişkili olduğu durumlarda, veri içerisindeki gereksiz veya yenilenen bilgiler bulunabilir. Basit bir seçim yöntemi, işlem performansının iyileşmesi açısından faydalı olabilir. Bu seçim kuralları geliştiricinin öznel tercihlerine dayanabilir, ancak daha sofistike yöntemler genellikle daha iyi sonuçlar vermektedir.

İkinci yaklaşım ise mevcut bilgiden en iyi şekilde yararlanmayı hedefleyen daha karmaşık boyut indirgeme algoritmalarını içerir. Bu yöntemlerle, test verilerinin eğitim verilerinin özelliklerini kullanarak daha iyi temsil edilmesi amacıyla bazı dönüşüm algoritmalarının uygulanmasını gerektirir. Bazen bu tür algoritmalar geliştiricilerin yaklaşımına bağlı olarak öznitelik çıkarma sürecinin bir parçası olmak yerine sınıflandırıcı olarak görülmektedir. Bu bölümde bu karar verme ve performansın optimizasyonu anlatıldığı için bu tarz algoritmaların veri boyut azaltımı yönü anlatılmaktadır.

Genel olarak boyut indirgeme algoritması olarak TBA, DAA kullanılmaktadır.

3.4.1. Temel Bileşen Analizi (TBA)

TBA yüksek boyutlu veri setlerini daha düşük boyutlara indirerek performans artışı ve hesaplama yükünü azaltmak amacıyla kullanılan doğrusal bir boyut azaltma yöntemidir. TBA, temel olarak, veri setindeki varyansın en büyük kısmını koruyacak şekilde yeni bir koordinat sistemi oluşturarak çalışır. Bu koordinat sistemi, öz değerler ve özvektörler aracılığı ile tanımlanır.

TBA hesaplama prosedürü şu şekilde açıklanabilir. İlk olarak, giriş verisinin her boyutundaki tüm girdilerin ortalama değerleri hesaplanmalıdır. İkinci olarak, veri matrisinin değerleri bu ortalamalara göre kaydırılarak “sıfır ortalamalı bir matris” oluşturulur. Üçüncü olarak sıfır ortalamalı matrisin kovaryans matrisi elde edilir. Dördüncü adımda ise bu matrisin öz vektörleri belirlenir. Daha sonra, bu öz vektörler, ilgili öz değerlerin büyüklüğüne göre hiyerarşik bir sıra ile düzenlenir. Son olarak, giriş verisinin ana bileşenini elde etmek için, ilgili veri matrisinin, en büyük öz değere karşılık gelen öz vektörler çarpılması gerekir. Bu adımda kullanılacak öz vektör sayısı orijinal verinin ne kadarının korunması gerektiğine, başka bir deyişle veri boyutunun kaç indirileceğine bağlı olarak seçilir [18].

Her bir öz niteliğin değer aralığı farklılık gösterdiğinden, otomatik boyut indirgeme işlemi yapılmadan önce toplanan öz nitelikler ölçeklendirme işleminden geçirilmesi gerekmektedir.

3.4.2. Fisher’in Doğrusal Ayırıcı Analizi (Fisher DAA)

Fisher’in Doğrusal Ayırıcı Analizi boyut azaltma için kullanılan gözetimli bir yöntemdir ve sınıf ayrımını maksimize etmeyi hedefler. Bu yöntem verinin sınıflar arası ayrışımını arttırırken sınıf içi dağılımı minimumda tutarak, sınıflandırma algoritmaları için daha ayırıştırıcı bir veri temsili sağlar [17].

Fisher DAA, sınıflandırma problemleri için tasarlanmış doğrusal bir projeksiyon yöntemidir. Temel amacı, yüksek boyutlu veri uzayını sınıf bilgisine dayalı olarak daha düşük boyuta indirmektedir. Bu işlem, iki temel ölçüte dayanır.

- Sınıf içi Dağılım Matrisi (S_w):

Her sınıfın kendi içerisindeki veri noktalarının varyansını temsil eder. Bu matris, sınıf içindeki noktaların ne kadar yakın kümelendiğini gösterir ve şu şekilde hesaplanır.

$$S_w = \sum_{i=1}^C \sum_{x \in C_i} (x - \mu_i) \quad (6.1)$$

Sınıflar arası ayrışım Matrisi (S_b):

Sınıf ortalamalarının, tüm veri setinin genel ortalamasına göre uzaklığı ifade eder. Bu matris, sınıflar arasındaki ayrımı temsil eder:

$$S_b = \sum_{i=1}^c N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (6.2)$$

Fisher LDA, bu iki ölçüt arasındaki oranı maksimize edecek bir projeksiyon vektörü (ω) arar. Bunun için Fisher LDA aşağıdaki optimizasyon fonksiyonunu maksimize etmeye çalışır.

$$J(\omega) = \frac{\omega^T S_b \omega}{\omega^T S_w \omega} \quad (6.3)$$

Bu oran, sınıflar arası ayrışımı sınıf içi dağılıma oranlayarak en iyi projeksiyon vektörünü bulmayı sağlar. Problemi çözmek için $S_w^{-1} S_b$ matrisinin öz değerleri ve öz vektörleri hesaplanır. En büyük özdeğere karşılık gelen öz vektör, optimal projeksiyon vektörü ω verir.

Optimal projeksiyon matrisi belirlendikten sonra projeksiyon işlemi gerçekleştirilir.

$$z = \omega^T x \quad (6.4)$$

Boyut indirgeme sırasında, birden fazla öz vektör kullanılabilir. Kullanılan öz vektör sayısı orijinal verinin ne kadarının korunacağına bağlıdır.

3.5. Sınıflandırma

Örüntü tanıma süreçlerinde, yeni bir gözlemin hangi sınıfa ait olduğu, önceden tanımlanmış kurallara göre belirlenir. Finans, pazarlama, sağlık ve mühendislik gibi çeşitli alanlarda örüntü tanıma uygulamaları için geliştirilmiş çok sayıda karar verme yöntemi bulunmaktadır. Bir veri kümesi üzerinde örüntü tanıma işlemi genellikle kümeleme veya sınıflandırma yöntemleri ile gerçekleştirilir. Kümeleme, giriş sinyallerini veya çıkartılan öznitelikleri aralarındaki benzerlik veya farklılıklara dayanarak bir ölçüt üzerinden gruplandırmayı ifade eder. Diğer yandan, sınıflandırma, yeni giriş sinyallerini önceden belirlenmiş yöntemlerle sınırlı sayıda gruba ayırmayı amaçlar.

Örüntü tanıma veya makine öğrenmesi algoritmalarında sınıf ayrımının yapılabilmesi için genellikle eğitim örneklerine ihtiyaç duyulur. Eğitim örnekleri, hangi sınıfa ait oldukları bilinen veri kümelerinden oluşur ve bu sayede algoritmanın doğruluk ve

işlem verimliliği açısından performansını arttırmaya yönelik olarak kullanılabilir. Bu sürece algoritmanın öğrenme yeteneği geliştirme amacıyla gerçekleştirilen “öğrenme” adı verilir.

Makine öğrenmesi yöntemleri üç ana kategoriye ayrılır: Gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme, Gözetimli öğrenmede hedef veriler kullanılır; yani her bir eğitim örneği için beklenen çıktı önceden bilinir. Bu yöntemde genellikle algoritmanın performansı kademeli olarak arttırmayı amaçlayan bir hata fonksiyonu veya maliyet fonksiyonu bulunur. Gözetimsiz öğrenmede ise hedef verileri içermez. Bunun yerine mevcut veriler arasındaki benzerlik ve farklılıkları analiz eder, verilerin dağılımını tahmin etmeyi veya bazen eğitim örneklerinden oluşturulan kategorilere yeni bir verinin hangi olasılıkla ait olabileceğini belirlemeyi hedefler. Pekiştirmeli öğrenmede ise hedef verilere gerek duyulmaz. Bu yöntemde odak, çıktıların doğru ya da yanlış olup olmadığının değerlendirilmesidir.

Genellikle, kümeleme algoritmaları gözetimsiz öğrenme prensibini belirlerken, sınıflandırma algoritmalarında hem gözetimli hem de gözetimsiz öğrenme yöntemlerine rastlanabilir. Mevcut araştırmada olduğu gibi bir örüntü tanıma algoritmasında karar verme süreci için sınıflandırma yöntemlerinin kullanılması daha uygun bir yaklaşım olabilir. Bu bölümde bu çalışma özelinde kullanılan sınıflandırma algoritmaları anlatılmıştır.

3.5.1. K-En Yakın Komşu Algoritması (K-EYK)

k-EYK algoritması, hem sınıflandırma hem de regresyon problemlerinde kullanılan basit fakat etkili bir makine öğrenmesi algoritmasıdır. k-EYK, eğitim sürecinde herhangi bir modeli öğrenmek yerine, yeni bir veri noktası için tahmin yaparken eğitim veri kümesine dayalı olarak karar verir. k-EYK algoritması bir örneğin hangi sınıfa ait olduğuna karar vermek için önceden tanımlanmış k sayıda en yakın komşu seçer. Bu komşular genellikle bir mesafe ölçütü kullanılarak belirlenir. En yaygın kullanılan mesafe ölçütü şunlardır [19].

- Öklid Mesafesi

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (6.5)$$

- Manhattan Mesafesi:

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (6.6)$$

Tahmin yapılacak örnek için bu mesafeler hesaplandıktan sonra, küçük mesafeye sahip k komşu seçilir. Sınıflandırma probleminde, bu komşuların sınıfları arasında çoğunluk oyu kullanılarak yeni örneğin sınıfı belirlenir. Algoritma basit uygulanabilirliği sayesinde birçok problemde etkili sonuçlar verebilmektedir. Ancak, özellikle büyük veri setleri için performans anlamında problemler oluşturabilmektedir. Bununla birlikte uygun k değerinin seçimi algoritma performansında önemli yere sahiptir.

3.5.2. Destek Vektör Makinesi (DVM)

DVM hem sınıflandırma hem de regresyon problemlerinde kullanılan güçlü bir gözetimli öğrenme algoritmasıdır. DVM, sınıflar arasında maksimum ayrım sağlayan bir hiper düzlem tanımlamayı amaçlar. Bu hiper düzlem, iki sınıfa ait veri noktaları arasındaki en yakın mesafeyi, yani “marjı” maksimize edecek şekilde seçilir. Bu yaklaşım, modelin genelleştirme yeteneğini artırır ve DVM’i, özellikle yüksek boyutlu ve karmaşık veri setleriyle çalışırken etkili bir yöntem haline getirir.

DVM’in temel prensibi, doğrusal olarak ayrılabilir sınıflar varsayımına dayanır. Model, bu durumda iki sınıfı ayıran doğrusal bir hiper düzlem oluşturur ve en yakın veri noktalarına (destek vektörleri) olan mesafeyi maksimize eder. Ancak, gerçek hayatta birçok veri doğrusal olarak ayrılmaz. Bu tür durumlarda DVM, “çekirdek fonksiyonları” kullanarak veri noktalarını daha yüksek boyutlu bir özellik uzayına dönüştürür. Çekirdek fonksiyonları sayesinde, doğrusal olarak ayrılabilir olmayan veri setleri bile yeni uzayda doğrusal olarak ayrılabilir hale gelir. Yaygın olarak kullanılan çekirdek fonksiyonları arasında doğrusal, polinomsal, RBF (Radial Basis Function) ve sigmoid fonksiyonları bulunmaktadır [21].

DVM’in avantajları arasında yüksek boyutlu veri setlerinde etkili çalışması ve aşırı öğrenmeye karşı dayanıklı olması yer alır. Bununla birlikte eğitim sürecinin zaman alıcı olması ve büyük veri setlerinde yüksek bellek kullanımı gibi dezavantajları da bulunmaktadır. DVM, özellikle sınıfların net bir şekilde ayrıldığı küçük ve orta ölçekli veri setlerinde güçlü performans sergiler. Ayrıca parametre ayarlarının dikkatli bir

şekilde yapılması (örneğin, çekirdek fonksiyonu seçimi ve düzenleme parametresi C'nin optimizasyonu) modelin başarısını doğrudan etkiler.

Sonuç olarak, DVM hem teorik sağlamlığı hem de pratik uygulamalardaki başarısıyla öne çıkmış bir makine öğrenmesi algoritmasıdır. Doğrusal olmayan sınıflandırma problemlerinde çekirdek fonksiyonlarının sağladığı esneklik, DVM'i çeşitli alanlarda kullanılmasına imkân tanır.

3.5.3. XGBoost Algoritması

XGBoost (Aşırı Gradyan Güçlendirme) algoritması, makine öğrenmesi alanında sıklıkla kullanılan güçlü bir sınıflandırma algoritmasıdır. XGBoost, zayıf öğrenciler (genellikler karar ağaçları) kullanarak bir modeli ardışık adımlarla iyileştirmeyi hedefler. XGBoost, bu yöntemi hesaplama hızını arttırmak ve modelin doğruluğunu iyileştirmek amacıyla bir dizi teknikle birleştirir. XGBoost'un çalışma prensibi şu şekilde özetlenebilir. Ardışık şekilde yeni modeller ekleyerek toplam hata oranını azaltır. Her yeni model, bir önceki modelin hatalarını öğrenmeye odaklanır. Bu işlem, modelin genel performansını artırırken aşırı öğrenme durumunu da kontrol altına alır. Modelin optimizasyon sürecinde, belirli bir amaç fonksiyonu minimize edilir. Bu amaç fonksiyonu iki bileşenden oluşur [23].

- Hata Fonksiyonu: Modelin tahmin hatalarını ölçer. Örneğin, sınıflandırma için lojistik kayıp fonksiyonu kullanılabilir.
- Düzenleme Terimi: Modelin karmaşıklığını kontrol ederek aşırı öğrenme durumunu engeller. Bu terim, modelin genelleştirme kapasitesini artırır.

XGBoost ayrıca “gradient boosting” yöntemini hızlandırmak için veri paralelizasyonu, eksik veri işleme, düzenli bir ağacın yapılandırılması ve histogram tabanlı algoritmalar gibi bir dizi yenilikçi özellik sunar. Bu özellikler hem doğruluk hem de hesaplama verimliliği açısından XGBoost'u benzersiz bir yöntem haline getirir.

3.5.4. Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (YSA), insan beyninin bilgi işleme biçiminden esinlenerek geliştirilmiş güçlü bir makine öğrenmesi yöntemidir. YSA'lar sınıflandırma öznetelik çıkartımı gibi görevlerde karmaşık veri setlerinden anlamlı sonuçlar çıkartma

yeteneğine sahiptirler. Bu ağlar, özellikle büyük ve karmaşık veri setleriyle çalışırken derin öğrenme yöntemlerinin temelini oluşturur. YSA'ları üç ana katmandan oluşur. Bunlardan ilki giriş katmanıdır. Bu katmanda giriş verileri alınır ve bu bilgiyi bir sonraki katmana aktarır. Kullanılan bir diğer katman ise Gizli Katmanlar, bilgi işleme sürecinin büyük kısmını gerçekleştiren bir veya birden fazla katmandan oluşur. Bu katmanlar, giriş verilerini farklı ağırlıklarla çarpar, aktivasyon fonksiyonlarını uygular ve çıktı üretir. Son katman ise çıkış katmanıdır. Modelin tahminlerini veya çıktısını üreten katmandır [24].

YSA, her bir bağlantıya bir ağırlık atar ve bu ağırlıkları öğrenme sürecinde günceller. Öğrenme işlemi, genellikle geriye yayılım (backpropagation) algoritmasıyla gerçekleştirilir. Bu algoritma, hata oranını azaltmak için ağırlıklarını ayarlar. Hata oranı, genellikle bir kayıp fonksiyonu (örneğin, ortalama kare hata veya çapraz entropi) ile ölçülür. YSA'lar kullanımına göre birtakım avantajlara sahiptirler.

- Karmaşık ve doğrusal olmayan ilişkili modelleme yeteneği
- Öznitelik mühendisliği yapmaya gerek kalmadan veri seti üzerinden öznitelik çıkarımı

Bu avantajlarının yanında ise birtakım dezavantajları da mevcuttur.

- Büyük veri setlerine ve yüksek hesaplama gücüne ihtiyaç duyarlar.
- Hiper parametre optimizasyonunun yapılmasına ihtiyaç duyarlar ve zaman alıcı bir süreçtir.
- Aşırı öğrenme riskine sahiptir.

Bu avantaj ve dezavantajlarına rağmen makine öğrenmesi konulu çalışmalarda sıklıkla kullanılan yöntemlerdendir.

3.6. Bölüm Özeti

Üçüncü bölümde bu çalışmada geliştirilen yöntemin akış diyagramı veri toplama işleminin detayları anlatılmaya çalışılmıştır. Literatür incelemesine dayanarak, mevcut araştırmaya katkı sağlayabilecek çeşitli öznitelik çıkartma teknikleri ele alınmıştır. Bu teknikler, sinyal işleme alanları doğrultusunda sınıflandırılmış olup, her bir alanın sonuçlar üzerindeki etkileri göz önünde bulundurulmuştur. En uygun yöntemi seçerken yöntemlerin hangi uzayda kategori edildiğinden ziyade, ayırt edici özellikleri

ne kadar etkili bir şekilde çıkardıkları, hesaplama hızı ve verimlilikleri gibi pratik uygulanabilirlik unsurlarına öncelik verilmiştir. Yukarıda açıklanan her bir teknik gerçek hayat verileri üzerinde değerlendirilmiş ve seçilmiştir.

Karar verme süreçlerini iyileştirmek amacıyla, bazı boyut indirgeme teknikleriyle birlikte kullanılabilecek çeşitli sınıflandırma algoritmaları üzerinde durulmuştur. Anlatılan yöntemler haricinde, bu çalışmadaki konu üzerinde kullanılabilecek farklı birçok yöntem mevcuttur. Fakat literatürdeki sonuçlar incelendiği zaman ve elde edilen verilen üzerinde gerçekleştirilen ön çalışmalar sonuçlarına dayanılarak kullanılan yöntemler belirlenmiştir. Kullanılan yöntemler ayarlanabilecek farklı parametrelere sahiptir. Ancak geliştirici açısından, her bir parametrenin sonuçlar üzerinde etkisi olduğu göz önünde bulundurulursa, ayarlanması gereken parametre sayısının artıyor olması en iyi parametre setini bulmayı zorlaştırmaktadır.

Ön işleme ve öznitelik çıkarma tekniklerinin belirlenmesinin önemi kadar sınıflandırma tekniklerinin belirlenmesi de önemlidir. Bu çalışmada kullanılan k-EYK, XGBoosting ve DVM sınıflandırıcıları kullanılmıştır.

4. TESTLER VE ANALİZ

Bir makine öğrenmesi sisteminde Şekil 3.1 gösterildiği gibi üç ana adımdan oluşan her bir başlık için farklı yöntemleri içeren algoritmalar geliştirilerek bir çözüm oluşturulabilir. Bu yöntemlerin birbiriyle olan kombinasyonlarının sınıflandırma performansını ölçmek çözüm yolu olarak kullanılabilir. Bu yöntemler için parametre optimizasyonu performansın belirlenmesinde kritik bir öneme sahiptir. Çünkü kullanılan yöntemlerin maksimum performansı vereceği parametre setleri literatürde mevcut değildir. Bu noktada performans değerlendirmesi uygulama, veri seti ve geliştiricinin uzmanlık seviyesine bağlı olabilmektedir. Bu değişkenlerin hepsi performans süreci üzerinde dikkate alınması gereken bir belirsizlik süreci oluşturmaktadır.

Bu bölümde çalışmanın ana konusu olan insan ve araç sınıflandırmasını yüksek doğrulukla gerçekleştirebilen makine öğrenmesi algoritmasının geliştirilmesi için kullanılan öznitelikler, performans değerlendirme yöntemleri ve algoritma üzerinde gerçekleştirilen testler ve senaryolar özetlenmektedir.

4.1. Değerlendirme Yöntemleri

Makine öğrenmesi modellerinin başarısını değerlendirmek, geliştirilen algoritmanın ne kadar etkili olduğunu ve farklı veri setleri üzerinde nasıl performans gösterdiğini anlamak açısından kritik öneme sahiptir. Model performansı, doğru seçilmiş değerlendirme yöntemleriyle ölçülerek hem modelin güçlü yönleri hem de iyileştirilmesi gereken alanları belirlenmesinde faydalı olmaktadır. Değerlendirme sürecinde kullanılan yöntemler veri setinin yapısına, problem türüne ve uygulama alanına göre değişiklik gösterebilmektedir. Bu çalışma da sınıflandırma problemi için kullanılan doğruluk, kesinlik duyarlılık ve F-1 Skoru metrikleri kullanılmıştır.

4.1.1. Doğruluk

Tüm doğru tahminlerin, toplam tahminlere oranıdır. Ancak, sınıflar arasında dengesizlik olduğunda yanıltıcı olabilmektedir.

$$Doğruluk = \frac{Doğru\ tahminler}{Toplam\ Tahminler} \quad (4.1)$$

4.1.2. Kesinlik

Pozitif tahminlerin ne kadarının doğru olduğunu ölçer. Özellikle yanlış pozitiflerin önemli olduğu durumlarda kullanılır.

$$Kesinlik = \frac{Doğru\ Pozitifler}{Doğru\ Pozitifler + Yanlış\ Pozitifler} \quad (4.2)$$

4.1.3. Duyarlılık

Gerçek pozitiflerin ne kadarının doğru tahmin edildiğini gösterir. Yanlış negatiflerin kritik olduğu durumlarda kullanılır.

$$Duyarlılık = \frac{Doğru\ Pozitifler}{Doğru\ Pozitifler + Yanlış\ Negatifler} \quad (4.3)$$

4.1.4. F-1 Skoru

Kesinlik ve duyarlılık arasındaki dengeyi ölçen bir metriktir. Özellikler dengesiz veri setleri için kullanışlıdır.

$$Kesinlik = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (4.4)$$

4.2. Veri Seti Özellikleri

Değerlendirme için, veri toplama işlemi gerçekleştirilmiştir. Bu bölümde oluşturulmuş veri setinin özellikleri açıklanmıştır. Titreşim verilerini toplamak amacıyla üç eksenli ivme ölçer zemine sabitlenmiş ve yakınında bir mikrofon sensörü yerleştirilmiştir. Sensörler ile hedefler arasında 1 metre 2 metre ve 5 metre mesafe olacak şekilde veri toplama işlemi gerçekleştirilmiştir. İvme ölçer verileri 200 Hz frekansında örnekleme frekansı ile örneklenmiştir. Mikrofon verileri 4000 Hz örnekleme frekansı ile örneklenerek kaydedilmiştir. Veri etiketleme işlemi gerçekleştirildikten sonra

sinyaller bir saniyelik zaman pencerelerine bölünerek analiz edilmiştir. Çalışmada kullanılan veri setine ait bilgi Tablo 4.1’de verilmiştir.

Tablo 4.1: Toplam veri seti.

Sensör	İnsan	Araba	Boş Ortam	Toplam (örnek)
Mikrofon	8111	7130	11846	27087
İvmeölçer	8111	7130	11846	27087

4.3. Kullanılan Öznitelikler

Makine öğrenmesi algoritmalarını içeren sistemlerde öznitelik çıkartma, model performansını doğrudan etkileyen önemli bir adımdır. Bu çalışmada, mikrofon ve titreşim sinyalleri için zaman ve frekans uzayından öznitelikler çıkartılmıştır.

4.3.1. Zaman Uzayı Öznitelikleri

Zaman uzayı analizinde mikrofon ve titreşim sinyalleri için ortak olarak aşağıdaki öznitelikler çıkarılmıştır:

- Ortalama
- Standart Sapma
- Çarpıklık (Skewness)
- Basıklık (Kurtosis)
- Sıfır Kesme Oranı
- Enerji
- Güç

Bu öznitelikler, sinyalin temel istatistiksel ve zaman tabanlı karakteristiklerini temsil etmektedir.

4.3.2. Frekans Uzayı Öznitelikleri

Titreşim sinyallerinin frekans uzayı analizinde Güç Spektral Yoğunluğu (GSY) hesaplaması için Welch Yöntemi kullanılmıştır. Bu yöntem, sinyalin baskın frekans bileşenlerini tespit etmek amacıyla kullanılmıştır.

- Her yarım saniyelik zaman dilimi için $L=100$ olacak şekilde dikdörtgen pencereleme işlemi yapılmıştır. (Denklem 3.13)
- Pencerelemiş her bir dilim üzerinden Fourier Dönüşümü hesaplanır. (Denklem 3.12)
- Fourier dönüşümü sonucunda elde edilen değerlerin ortalaması hesaplanarak GSY hesaplanmıştır. (Denklem 3.14)

GSY hesaplanan sinyaller üzerinden ortalama ve standart sapma değerleri öznitelik olarak kullanılmıştır. Ayrıca, spektral merkez ve spektral entropi değerleri de öznitelik olarak kullanılmıştır.

Mikrofon verilerinin frekans analizi için MFKK kullanılmıştır. Toplamda 15 noktalı MFKK hesaplanarak sinyalin frekans uzayındaki öznitelikleri elde edilmiştir.

Mikrofon verileri için elde edilen öznitelik matrisinin boyutu 27087×24 . Üç eksen ivmeölçer verileri için elde edilen öznitelik matrisinin boyutu 27087×36 şeklindedir.

4.3.3. Öznitelik Seçimi ve Boyut Azaltımı

Normalize edilen öznitelikler, XGBoosting algoritmasının öznitelik önemi özelliği kullanılarak modelin hangi özniteliklere daha fazla önem verdiği hesaplanmıştır. XGBoost ağaç tabanlı bir algoritma olduğundan, her bir özelliğin modeli oluştururken nasıl katkıda bulunduğunu ölçen çeşitli metrikler sunar.

Temel metrikler şu şekilde açıklanabilir.

- 1- **Frekans:** Her bir özelliğin, model tarafından ağaçların dallarında kaç kez kullanıldığını ölçer. Çalışma yöntemi ise daha sık kullanılan öznitelikler daha önemli olarak değerlendirilir.
- 2- **Kazanç:** Bir özelliğin ağaçlarda dallanması sırasında sağladığı bilgi kazancının ortalamasıdır. Çalışma yöntemi ise bölünme yapılırken, dallanma sonucunda hata ölçüsündeki azalmayı temsil eder. Daha yüksek kazanç, özelliğin modele daha fazla bilgi kattığını gösterir. Bu sebepten dolayı özniteliklerin modele ne kadar değer kattığını doğrudan ölçer ve bu nedenle genellikle daha güvenilir bir metrik olarak kabul edilir.

- 3- Kapsam:** Her bir özelliğin, modelde dallanma yaptığı yerlerde etkilediği veri noktalarının oranıdır. Çalışma yöntemi ise daha fazla veri örneğini etkileyen bir özellik, daha önemli kabul edilir.

Bu çalışmada kazanç metriği kullanılarak model için öznitelik önem hesabı yapılmıştır. Modelin gelişimine etkisi olmayan öznitelikler veri kümesinden kaldırılmıştır. Kalan mevcut özniteliklerin birbirleriyle olan ilişki Pearson Korelasyon tekniği ile analiz edilmiştir. Bu yöntem ile birbirleriyle korelasyon ilişkisi bulunan özniteliklerin sınıflandırma işleminde sapma (bias) oluşturabilme durumundan dolayı TBA uygulanmıştır.

4.4. Testler ve Senaryolar

Bu bölümde, problemin çözümü için Şekil 3.3 ve Şekil 3.4 önerilen algoritmanın tasarlanma aşamasında gerçekleştirilen testler ve elde edilen sonuçlar sunulmuştur. Test kurgusu şu şekilde yapılmıştır:

- Test-1: Problemin çözümüne yönelik olarak, her bir sensörün sınıflandırma performansı DVM, k-EYK ve XGBoost yöntemleri kullanılarak değerlendirilmiştir. Sınıflandırıcıların parametreleri k katmanlı çapraz doğrulama yöntemi kullanılarak farklı parametreler için gerçekleştirilmiştir. Bu doğrultuda en uygun sınıflandırıcı parametrelerini belirlenmiş ve her bir sensör için ayrı ayrı sınıflandırma performansları ortaya koyulmuştur.
- Test-2: İkinci aşamada, farklı sensörlerden elde edilen verilerin birleştirilmesi yoluyla oluşturulan birleşik veri seti üzerinde çalışılmıştır. Bu süreçte, birleştirilmiş sensör verileri kullanılarak sınıflandırma işlemleri gerçekleştirilmiş ve bu verilerin sınıflandırma performansı üzerindeki etkisi incelenmiştir. Bu testin temel amacı, birleştirilmiş verilerin tekil sensör verilerine kıyasla sınıflandırma başarısına nasıl katkıda bulunduğunu göstermektir.
- Test-3: Şekil 3.4'de önerilen algoritmanın tespit sonuçları farklı sınıflandırıcılar ve parametreleri için gerçekleştirilmiştir. Bir sonraki adımda sensörlerin tespitlerinin birbirinden farklı olduğu noktalarda tespit performansını arttırması için algoritmaya eklenen Model-3 sınıflandırıcısının test performansı analiz edilmiş ve sonuçları sunulmuştur. Önerilen yöntemin


toplam tespit başarı ile sensör verilerinin birleştirilmesi ile oluşturulacak olan bir modelin tespit başarısının karşılaştırması yapıldı. Son katmanda hareketli hedef sınıflandırması yapmak üzere algoritmaya dahil edilen Model-4'ün test performansı sunulmuş. Bütün işlemler tamamlandıktan sonra önerilen yöntemin sınıflandırma performansı hesaplanmıştır.

Yapılan testlerin her biri ayrı başlıklar altında ele alınmış ve sonuçları belirtilen performans metrikleri için hesaplanarak sunulmuştur.

4.4.1. Test-1 Senaryoları ve Sonuçları

4.4.1.1. Titreşim Verileri Analiz ve Sonuçları


Toplanan titreşim verileri üzerinde 36 adet öznitelik elde edilmiştir. Elde edilen öznitelikler içerisinde öznitelik analizi gerçekleştirilmiştir. XGBoost algoritmasının öznitelik önem özelliği kazanç parametresiyle kullanılarak özniteliklerin model üzerindeki ağırlıkları hesaplanmıştır. Her bir öznitelik için Şekil 4.1'de ve Şekil 4.2'de gösterilmiştir.



Şekil 4.1: Titreşim verileri için öznitelik önem sonucu.

Şekil 4.1 incelendiğinde zaman uzayında her eksen için hesaplanmış olan güç özniteliliğinin etkisi olmadığı gözlemlenmektedir. Etkisi olmayan öznitelikler veri setinden çıkartılmıştır. Bu işlem sonrasında veri seti 33 boyuta düşmüştür. Etkisiz

öznitelik analiz yapıldıktan sonra diğer özniteliklerin birbirleri ile olan ilişkileri Pearson Korelasyon Analizi yapılarak sıcaklık haritasında incelenmiştir.



Şekil 4.2: Titreşim verileri öznitelik pearson korelasyon analizi.

Burada pozitif veya negatif yönde güçlü korelasyonlu özniteliklerin olduğu gözlemlenmiştir. Bu durum sınıflandırma sırasında bir bias oluşturabileceğinden dolayı TBA işlemi uygulanmıştır. TBA işlemi için parametre veri setindeki toplam varyansın yüzde 95'ini açıklayacak şekilde seçilmiştir. Veri setinin boyutu 20'e düşürülmüştür. Öznitelikler üzerindeki analizler tamamlandıktan sonra 3 farklı sınıflandırıcı için farklı farklı parametrelerle modeller eğitilmiştir. K=3 katmanlı çapraz doğrulama yöntemi kullanılarak farklı parametreler ile modeller eğitilmiş ve test sonuçları sergilenmiştir. Aşağıdaki tabloda eğitim ve test veri kümelerinin bilgileri verilmiştir.

Tablo 4.2: Titreşim verisi eğitim veri kümesi bilgileri.

İnsan	Araba	Boş Ortam	Toplam (örnek)
5272	4634	7700	17606

Tablo 4.3: Titreşim verisi test veri kümesi bilgileri.

İnsan	Araba	Boş Ortam	Toplam (örnek)
2839	2496	4146	9481

XGBoost algoritması için 4 farklı model eğitilmiş ve test performansları sergilenmiştir.

Tablo 4.4: XGboost modelleri parametre tablosu.

Model Adı	Parametre bilgileri
XGBoost_Model1	objective='multi:softmax',num_class=3,learning_rate=0.01,n_estimator=200
XGBoost_Model2	objective='multi:softmax',num_class=3,learning_rate=0.1,n_estimator=200
XGBoost_Model3	objective='multi:softmax',num_class=3,max_depth=10,learning_rate=0.01,n_estimator=200
XGBoost_Model4	objective='multi:softmax',num_class=3,max_depth=5,learning_rate=0.01,n_estimator=200

Burada oluşturulan modeller üzerinde öğrenme oranı ve ağaç derinliği parametrelerinin model performansı üzerinde durulmuştur. Yapılan testler sonucunda elde edilen karmaşıklık matrisleri Aşağıda verilmiştir.

Tablo 4.5: Titreşim verisi XGBoost_Model1 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2434	73	332
Gerçek Araba	0	2020	476
Gerçek Arka plan	16	44	4086

Tablo 4.6: Titreşim verisi XGBoost_Model2 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2481	21	337
Gerçek Araba	0	2496	0
Gerçek Arka plan	20	2	4124

Tablo 4.7: Titreşim verisi XGBoost_Model3 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2465	32	342
Gerçek Araba	0	2474	22
Gerçek Arka plan	15	4	4127

Tablo 4.8: Titreşim verisi XGBoost_Model4 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2419	91	329
Gerçek Araba	9	1959	528
Gerçek Arka plan	15	62	4069

XGBoost sınıflandırıcısı için kullanılan 4 farklı modelin performans metriklerine göre sonuçları aşağıdaki tabloda sergilenmiştir.

Tablo 4.9: Titreşim verileri için XGBoost modellerinin performans sonuçları.

Model İsmi	F-1 Skoru (%)	Kesinlik (%)	Duyarlılık (%)
XGBoost_Model1	91.0	90.0	90.0
XGBoost_Model2	96.0	96.0	96.0
XGBoost_Model3	96.0	96.0	96.0
XGBoost_Model4	90.0	89.0	89.0

Titreşim verileri üzerinde sınıflandırma performansı hesaplamak için farklı bir sınıflandırıcı olarak DVM sınıflandırıcısı kullanılmıştır. Oluşturulan 4 farklı model için farklı çekirdek fonksiyonlarına sahip modeller eğitilmiş ve testler gerçekleştirilmiştir.

Tablo 4.10: DVM modelleri parametre tablosu.

Model Adı	Parametre bilgileri
DVM_Model1	kernel='rbf', decision_function_shape='ovr'
DVM_Model2	kernel='linear', decision_function_shape='ovr', C=0.95
DVM_Model3	kernel='poly', degree=3, decision_function_shape='ovr', C=0.95, gamma='scale'
DVM_Model4	kernel='sigmoid', decision_function_shape='ovr', C=0.95, gamma='scale'

Burada farklı çekirdek fonksiyonlarının titreşim verilerini sınıflandırmadaki performansları sergilenmeye çalışılmıştır.

Tablo 4.11: Titreşim verisi DVM_Model1 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2434	73	332
Gerçek Araba	0	2020	476
Gerçek Arka plan	16	44	4086

Tablo 4.12: Titreşim verisi DVM_Model2 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2321	139	379
Gerçek Araba	50	1727	719
Gerçek Arka plan	7	37	4102

Tablo 4.13: Titreşim verisi DVM_Model3 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	1808	52	979
Gerçek Araba	0	1198	1298
Gerçek Arka plan	0	4	4142

Tablo 4.14: Titreşim verisi DVM_Model4 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2197	168	474
Gerçek Araba	219	2245	32
Gerçek Arka plan	429	39	3678

DVM sınıflandırıcısı için kullanılan 4 farklı modelin performans metriklerine göre sonuçları aşağıdaki tabloda sergilenmiştir.

Tablo 4.15: Titreşim verileri için DVM modellerinin performans sonuçları.

Model İsmi	F-1 Skoru (%)	Kesinlik (%)	Duyarlılık (%)
DVM_Model1	91.0	90.0	90.0
DVM_Model2	88.0	86.0	86.0
DVM_Model3	83.0	75.0	74.0
DVM_Model4	69.0	71.0	69.0

Titreşim verileri üzerinde sınıflandırma performansı hesaplamak için farklı bir sınıflandırıcı olarak k-EYK sınıflandırıcısı kullanılmıştır. Oluşturulan 4 farklı model için farklı komşu sayısı ve uzaklık tipleri kullanarak modeller eğitilmiş ve testler gerçekleştirilmiştir.

Tablo 4.16: K-EYK modelleri parametre tablosu.

Model Adı	Parametre bilgileri
k-EYK_Model1	n=21, metrik = öklid
k-EYK_Model2	n=31, metrik = öklid
k-EYK_Model3	n=31, metrik = manhattan
k-EYK_Model4	n=31, metrik = minkowski, p=3

Burada farklı komşu sayısı seçimi ve metriklerin sınıflandırma üzerindeki etkileri incelenmeye çalışılmıştır.

Tablo 4.17: Titreşim verisi k-EYK_Model1 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	1948	269	622
Gerçek Araba	6	1750	740
Gerçek Arka plan	3	183	3960

Tablo 4.18: Titreşim verisi k-EYK_Model2 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	1928	279	632
Gerçek Araba	0	2496	0
Gerçek Arka plan	0	62	4084

Tablo 4.19: Titreşim verisi k-EYK_Model3 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	1920	294	625
Gerçek Araba	0	1654	842
Gerçek Arka plan	2	118	4026

Tablo 4.20: Titreşim verisi k-EYK_Model4 karmaşıklık matrisi.


Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	1899	295	645
Gerçek Araba	8	1626	862
Gerçek Arka plan	4	161	3981

Tablo 4.21: Titreşim verileri için k-EYK Modellerinin performans sonuçları.

Model İsmi	F-1 Skoru (%)	Kesinlik (%)	Duyarlılık (%)
k-EYK_Model1	81.0	83.0	81.0
k-EYK_Model2	89.0	91.0	90.0
k-EYK_Model3	80.0	83.0	80.0
k-EYK_Model4	79.0	79.0	82.0


4.4.1.2. Mikrofon Verileri Analiz ve Sonuçları

Toplanan mikrofon verileri üzerinde 24 adet öznitelik elde edilmiştir. Elde edilen öznitelikler içerisinde öznitelik analizi gerçekleştirilmiştir. XGBoost algoritmasının öznitelik önem özelliği kazanç parametresiyle kullanılarak özniteliklerin model üzerindeki ağırlıkları hesaplanmıştır. Her bir öznitelik için Şekil 4.3'te gösterilmiştir.



Şekil 4.3: Ses veri seti için öznitelik önem sonucu.

Şekil 4.3 incelendiğinde zaman uzayında hesaplanmış olan güç ve frekans uzayında hesaplanan spektral entropi özniteliklerinin etkisi olmadığı gözlemlenmektedir. Etkisi olmayan öznitelikler veri setinden çıkartılmıştır. Bu işlem sonrasında veri seti 22 boyuta düşmüştür. Etkisiz öznitelik analiz yapıldıktan sonra diğer özniteliklerin birbirleri ile olan ilişkileri Pearson Korelasyon Analizi yapılarak sıcaklık haritasında incelenmiştir.



Şekil 4.4: Ses verileri öznitelik pearson korelasyon analizi.

Burada pozitif veya negatif yönde güçlü korelasyonlu özniteliklerin olduğu gözlemlenmiştir. Bu durum sınıflandırma sırasında bir bias oluşturabileceğinden dolayı TBA işlemi uygulanmıştır. TBA işlemi için parametre veri setindeki toplam varyansın yüzde 95'ini açıklayacak şekilde seçilmiştir. Veri setinin boyutu 16'ya düşürülmüştür. Öznitelikler üzerindeki analizler tamamlandıktan sonra 3 farklı sınıflandırıcı için farklı farklı parametrelerle modeller eğitilmiştir. K=3 katmanlı çapraz doğrulama yöntemi kullanılarak modeller eğitilmiş ve test sonuçları sergilenmiştir. Aşağıdaki tabloda eğitim ve test veri kümelerinin bilgileri verilmiştir.

Tablo 4.22: Ses verisi eğitim veri kümesi bilgileri.

İnsan	Araba	Boş Ortam	Toplam (örnek)
5272	4634	7700	17606

Tablo 4.23: Ses verisi test veri kümesi bilgileri.

İnsan	Araba	Boş Ortam	Toplam (örnek)
2839	2496	4146	9481

XGBoost algoritması için Tablo 4.5'te ki modeller için mikrofon veri seti kullanılarak eğitim ve test faaliyetleri gerçekleştirilmiştir. Elde edilen karmaşıklık matrisleri ve model performans sonuçları aşağıda verilmiştir.

Tablo 4.24: Ses verisi XGBoost_Model1 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2677	10	152
Gerçek Araba	0	2496	0
Gerçek Arka plan	16	0	4130

Tablo 4.25: Ses verisi XGBoost_Model2 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2736	4	99
Gerçek Araba	0	2496	0
Gerçek Arka plan	16	0	4130

Tablo 4.26: Ses verisi XGBoost_Model3 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2705	7	127
Gerçek Araba	0	2496	0
Gerçek Arka plan	21	0	4125

Tablo 4.27: Ses verisi XGBoost_Model4 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2666	12	161
Gerçek Araba	0	2496	0
Gerçek Arka plan	22	0	4124

XGBoost sınıflandırıcısı için kullanılan 4 farklı modelin performans metriklerine göre sonuçları aşağıdaki tabloda sergilenmiştir.

Tablo 4.28: Ses verileri için XGBoost modellerinin performans sonuçları.

Model İsmi	F-1 Skoru (%)	Kesinlik (%)	Duyarlılık (%)
XGBoost_Model1	98.0	98.0	98.0
XGBoost_Model2	99.0	99.0	99.0
XGBoost_Model3	98.0	98.0	98.0
XGBoost_Model4	98.0	98.0	98.0

Ses verileri üzerinde sınıflandırma performansı hesaplamak için farklı bir sınıflandırıcı olarak DVM sınıflandırıcısı kullanılmıştır. Tablo 4.11’de verilen 4 farklı model için farklı çekirdek fonksiyonlarına sahip modeller eğitilmiş ve testler gerçekleştirilmiştir.

Tablo 4.29: Ses veri seti DVM_Model1 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2643	4	192
Gerçek Araba	0	2496	0
Gerçek Arka plan	24	0	4122

Tablo 4.30: Ses veri seti DVM_Model2 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2588	27	224
Gerçek Araba	0	2496	0
Gerçek Arka plan	66	0	4080

Tablo 4.31: Ses Veri seti DVM_Model3 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2551	7	281
Gerçek Araba	0	2496	0
Gerçek Arka plan	24	0	4131

Tablo 4.32: Ses veri seti DVM_Model4 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2197	168	474
Gerçek Araba	219	2245	32
Gerçek Arka plan	429	39	3678

Tablo 4.33: Ses verileri için DVM modellerinin performans sonuçları.

Model İsmi	F-1 Skoru (%)	Kesinlik (%)	Duyarlılık (%)
DVM_Model1	98.0	98.0	98.0
DVM_Model2	97.0	97.0	97.0
DVM_Model3	97.0	97.0	97.0
DVM_Model4	86.0	86.0	86.0

Ses verileri üzerinde sınıflandırma performansı hesaplamak için farklı bir sınıflandırıcı olarak k-EYK sınıflandırıcısı kullanılmıştır. Tablo 4.17’de verilen 4 farklı model için modeller eğitilmiş ve testler gerçekleştirilmiştir.

Tablo 4.34: Ses veri seti k-EYK_Model1 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2213	46	580
Gerçek Araba	0	2496	0
Gerçek Arka plan	1	1	4144

Tablo 4.35: Ses veri seti k-EYK_Model2 karmaşıklık matrisi

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2178	52	609
Gerçek Araba	0	2496	0
Gerçek Arka plan	0	0	4146

Tablo 4.36: Ses veri seti k-EYK_Model3 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2222	46	571
Gerçek Araba	0	2496	0
Gerçek Arka plan	2	0	4144

Tablo 4.37: Ses veri seti k-EYK_Model4 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2112	53	674
Gerçek Araba	0	2496	0
Gerçek Arka plan	1	2	4143

Tablo 4.38: Ses verileri için k-EYK modellerinin performans sonuçları.


Model İsmi	F-1 Skoru (%)	Kesinlik (%)	Duyarlılık (%)
k-EYK_Model1	93.0	94.0	93.0
k-EYK_Model2	93.0	94.0	93.0
k-EYK_Model3	93.0	94.0	93.0
k-EYK_Model4	92.0	93.0	92.0

Test Senaryosu-1 in sonucunda titreşim verilerinin sınıflandırma performansı bütün sınıflar bazında ses verilerinin sınıflandırma performansına göre düşük kaldığı gözlemlenmiştir. Bütün sınıflardaki başarının arttırılması için birleştirilmiş sensör verileri kullanılarak bir sınıflandırma yapılmasının sınıflandırma performansı üzerindeki etkilerini analiz etmek için Test Senaryosu-2 adımı işletilmiştir.

4.4.2. Test Senaryosu-2


4.4.2.1. Birleştirilmiş Sensör Verileri Analiz ve Sonuçları

Kaynaştırma sonrasında toplamda 60 adet öznitelik elde edilmiştir. Bu öznitelikler XGBoost algoritmasının öznitelik önem analizi gerçekleştirilmiştir. Her bir öznitelik için önem analizi Şekil 4.5'te gösterilmiştir.



Şekil 4.5: Kaynaştırılmış veri seti için öznitelik önem sonucu.

Şekil 4.5 incelendiğinde zaman uzayında hesaplanmış olan güç ve frekans uzayında hesaplanan spektral entropi özniteliklerinin etkisi olmadığı gözlemlenmektedir. Etkisi olmayan öznitelikler veri setinden çıkartılmıştır. Bu işlem sonrasında veri seti 55 boyuta düşmüştür. Etkisiz öznitelik analiz yapıldıktan sonra diğer özniteliklerin birbirleri ile olan ilişkileri Pearson Korelasyon Analizi yapılarak sıcaklık haritasında incelenmiştir.



Şekil 4.6: Birleştirilmiş veriler için öznelilik pearson korelasyon analizi.

Öznelilikler arasında pozitif veya negatif yönde güçlü korelasyonların bulunduğu tespit edilmiştir. Bu durum, sınıflandırma sürecinde olası bir yanlılığa (bias) neden olabileceği için TBA uygulanmıştır. TBA işlemi veri setindeki toplam varyansın %95'ini koruyacak şekilde yapılandırılmış ve veri setinin boyutunu 48 bileşene indirmiştir. Öznelilik analizi tamamlandıktan sonra, üç farklı sınıflandırıcı kullanılarak Test Senaryosu-1'de yapılan testler sonucunda iki sensör içinde en iyi sonucu veren model parametreleri için testler gerçekleştirilmiştir. XGBoost sınıflandırıcısı için XGBoost_Model2, DVM sınıflandırıcısı için DVM_Model1 ve k-EYK sınıflandırıcısı için k-EYK_Model2 parametresi ile birleştirilmiş veri seti için model eğitilmiş ve test sonuçları sergilenmiştir. Sınıflandırma işlemi için Test Senaryo-1'deki gibi veri setinin %65'i eğitim %35'i test olarak ayrılmıştır.

Tablo 4.39: Kaynaştırılmış veri seti XGBoost-Model2 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2780	5	54
Gerçek Araba	0	2496	0
Gerçek Arka plan	7	2	4137

Tablo 4.40: Kaynaştırılmış veri seti DVM-Model1 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2621	5	213
Gerçek Araba	15	2481	0
Gerçek Arka plan	5	0	4141

Tablo 4.41: Kaynaştırılmış veri seti k-EYK-Model2 karmaşıklık matrisi.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2342	31	466
Gerçek Araba	15	2496	0
Gerçek Arka plan	0	2	4144

Test Senaryo-1’de elde edilen sonuçlar, titreşim verilerinin problem çözümü sürecinde tek başına kullanıldığı zaman yetersiz performans sergilediğini ortaya koymaktadır. Ses verileri incelendiği zaman araç sınıfını ayırma noktasında başarılı olduğu ancak insan ve boş ortam sınıflandırmasında performansının sınırlı kaldığı gözlemlenmiştir. Test Senaryo-2’de sensör verilerinin kaynaştırılması sonucunda, insan ve boş ortam sınıflarının ayırımında kayda değer bir performans artışı sağlanmıştır. Tablo 4.31’ de uygulanan değerlendirme metrikleri kullanılarak tüm senaryolar için ağırlıklı skor tahminleri tablo halinde sunulmuştur.

Tablo 4.42: Başarım sonuç tablosu.

Sınıflandırıcı	Sensör	Keskinlik	Duyarlılık	F-1 Skoru
XGBoost-Model2	İvme ölçer	%96,0	%96,0	%96,0
DVM-Model1	İvme ölçer	%90,0	%90,0	%91,0
k-EYK-Model2	İvme ölçer	%90,0	%90,0	%91,0
XGBoost-Model2	Mikrofon	%99,0	%99,0	%99,0
DVM-Model1	Mikrofon	%98,0	%98,0	%98,0
k-EYK-Model2	Mikrofon	%94,0	%93,0	%93,0
XGBoost-Model2	Kaynaştırılmış Veri	%99,0	%99,0	%99,0
DVM-Model1	Kaynaştırılmış Veri	%98,0	%97,0	%97,0
k-EYK-Model2	Kaynaştırılmış Veri	%95,0	%95,0	%95,0

4.4.3. Test Senaryo-3

4.4.3.1. Önerilen Algoritmanın Analiz ve Sonuçları

Bu bölümde Şekil 3.4’ de önerilen algoritmanın tespit aşamasında geliştirilen Model-1, Model-2 ve Model-3 eğitim ve test aşamaları anlatılmaktadır. Bir önceki adımlarda

gerçekleştirilen ve kullanılan eğitim ve test verileri bu adımda aynı şekilde kullanılmıştır. İlk olarak eğitim veri kümesi içerisindeki insan ve araba örnekleri hareketli hedef sınıfı içerisine koyulmuş ve arka plan verileri ise hareketsiz ortam olarak etiketlenmiştir. Bu işlem mikrofon ve ivme ölçer verileri için ayrı ayrı gerçekleştirilmiştir. Bu kapsamda önceki senaryolarda kullanılan test verileri de bu kapsamda etiketlenmiş ve yeni bir test veri seti oluşturulmuştur. Eğitim ve test veri kümesi dağılımı aşağıda verilmiştir.

Tablo 4.43: Tespit aşaması eğitim kümesi veri özellikleri.

Sensör	Hareketli Hedef	Boş ortam	Toplam (örnek)
Mikrofon	9906	7700	17606
İvmeölçer	9906	7700	17606

Tablo 4.44: Tespit aşaması test kümesi veri özellikleri.

Sensör	Hareketli Hedef	Boş ortam	Toplam (örnek)
Mikrofon	5335	4146	9481
İvmeölçer	5335	4146	9481

Titreşim verileri üzerinde hareketli hedef tespiti gerçekleştirecek olan Model-1 iki farklı sınıflandırıcı kullanılarak XGBoost-Model2 ve DVM-Model1 sınıflandırıcıları ile eğitilmiş ve test edilmiştir. Elde edilen karmaşıklık matrisleri aşağıda verilmiştir.

Tablo 4.45: Titreşim verisi XGBoost-Model2 tespit sonucu.

Test Veri Sayısı: 9481	Tahmin Hedef	Tahmin Arka plan
Gerçek Hedef	5016	319
Gerçek Arka plan	36	4110

Tablo 4.46: Titreşim verisi DVM-Model1 tespit sonucu.

Test Veri Sayısı: 9481	Tahmin Hedef	Tahmin Arka plan
Gerçek Hedef	4218	1117
Gerçek Arka plan	68	4078

Model-1 en iyi sonuç veren iki sınıflandırıcı parametreleri test edilmiş ve elde edilen sonuçlar ışığında XGBoost-Model2 parametrelili sınıflandırıcı kullanılmasına karar verilmiştir.

Ses verileri üzerinde hareketli hedef tespiti gerçekleştirecek olan Model-2 iki farklı sınıflandırıcı kullanılarak XGBoost-Model2 ve DVM-Model1 sınıflandırıcıları ile eğitilmiş ve test edilmiştir. Elde edilen karmaşıklık matrisleri aşağıda verilmiştir.

Tablo 4.47: Ses verisi XGBoost-Model2 tespit sonucu.

Test Veri Sayısı: 9481	Tahmin Hedef	Tahmin Arka plan
Gerçek Hedef	5230	105
Gerçek Arka plan	12	4134

Tablo 4.48: Ses verisi DVM-Model1 tespit sonucu.

Test Veri Sayısı: 9481	Tahmin Hedef	Tahmin Arka plan
Gerçek Hedef	5137	198
Gerçek Arka plan	18	4128

Ses verileri için Model-2 sonuçlar incelendiği zaman Model-2'nin XGBoost-Model2 parametrelili sınıflandırıcı ile daha başarılı sonuç aldığı gözlemlenmiştir. Model-2 için XGBoost-Model2 sınıflandırıcısının kullanılmasına karar verilmiştir.

İvmeölçer ve mikrofon sensörlerinden elde edilen test verileri ayrı ayrı test edilmiştir. Sensörlerin farklı sonuçlar ürettiği durumlarda, bu veriler birleştirilerek Şekil 3.4'te gösterilen Model-3'e aktarılmıştır. Model-3'ün temel amacı, tüm test verilerini birleştirmeden, yalnızca sensörlerin farklı sonuçlar verdiği noktalarda verileri birleştirip işleyerek modelin tespit başarısını arttırmaktır. Bu yaklaşımla, gereksiz veri işleme maliyetlerinden kaçınılması ve daha yüksek doğruluk oranının elde edilmesi hedeflenmektedir.

Model-3'ün test verileri üzerinden ürettiği sonuçlar kullanılarak, önerilen yöntemin genel tespit başarısı hesaplanmıştır. Ayrıca, önerilen yöntemin tespit başarısı, her bir sensör için elde edilen test verilerinin birleştirilmesiyle oluşturulan veri seti üzerinden elde edilen sonuçlar ile karşılaştırılmıştır. Bu karşılaştırma, önerilen yöntemin tespit performansını ve sensör verilerinin birleştirilmesinin etkisi değerlendirmek için yapılmıştır.

Model-1 ve Model-2'ye test edilmek için verilen test verilerinden tespit sonuçları farklı olan toplam 442 adet test verisi için Model-3 kullanılmıştır. Model3 için XGBoost-Model2 parametrelili sınıflandırıcı kullanılmıştır. Elde edilen karmaşıklık matrisi aşağıda verilmiştir.

Tablo 4.49: XGBoost-Model2 parametrelili model-3 tespit sonucu.

Test Veri Sayısı: 442	Tahmin Hedef	Tahmin Arka plan
Gerçek Hedef	371	17
Gerçek Arka plan	4	50

Önerilen yöntemin tespit aşamasında elde edilen toplam başarısı, Model-1 Model-2 ve Model-3'ün test verileri üzerinde ürettiği sonuçlar kullanılarak, önerilen yöntemin genel tespit başarısı hesaplanmıştır. Ayrıca, önerilen yöntemin tespit başarısı, her bir sensör için elde edilen test verilerinin birleştirilmesiyle oluşturulan veri seti üzerinden elde edilen sonuçlarla karşılaştırılmıştır. Bu karşılaştırma, yöntemin performansını ve sensör verilerinin birleştirilmesinin etkisini değerlendirmek için yapılmıştır.

Tablo 4.50: Önerilen yöntemin tespit sonucu.

Test Veri Sayısı: 9481	Tahmin Hedef	Tahmin Arka plan
Gerçek Hedef	5308	27
Gerçek Arka plan	4	4142

Tablo 4.51: Birleştirilmiş test verileri için tespit sonucu.

Test Veri Sayısı: 9481	Tahmin Hedef	Tahmin Arka plan
Gerçek Hedef	5292	43
Gerçek Arka plan	7	4139

Sonuçlar incelendiğinde, önerilen yöntemin tespit yeteneğinin doğrudan sensör verilerinin birleştirilmesi ile oluşturulan veri kümesi ile yapılan tespitlere kıyasla daha iyi sonuçlar verdiği görülmüştür. Önerilen yöntemin hareket tespit etme aşaması detaylı bir şekilde değerlendirilmiş ve yapılan testler sonucunda önerilen yöntemin tespit yeteneğinin başarılı olduğu gösterilmiştir.

Test Senaryo-3'ün son aşamasında, hareketli hedef olarak tespit edilen veriler birleştirilmiş ve bu veriler Model-4 üzerinde insan ve araba olarak sınıflandırılmaya çalışılmıştır. Model-4 sınıflandırıcısı, önceki test senaryolarında kullanılan mevcut eğitim verilerinin çaprazlanmasıyla örnek sayısının artırılması sağlanarak toplamda 19812 örnek üzerinden eğitilmiştir. Bu modelde XGBoost-Model2 parametreleri ile yapılandırılmış sınıflandırıcı kullanılmıştır.

Hareketli hedef olarak tespit edilen test verileri, Model-4 ile sınıflandırılmış ve önerilen yöntemin çıkışındaki sınıflandırma performansı değerlendirilmiştir. Elde

edilen sonuçlar, önerilen yöntemin test senaryosu-1 ve test senaryosu-2 de elde edilen sınıflandırma sonuçlarından daha iyi bir sonuç sağladığını göstermiştir. Bu doğrultuda önerilen yöntemin çıkışında oluşan karmaşıklık matrisi aşağıda verilmiştir.

Tablo 4.52: Önerilen yöntemin sınıflandırma sonucu.

Test Veri Sayısı: 9481	Tahmin İnsan	Tahmin Araba	Tahmin Arka plan
Gerçek İnsan	2811	5	27
Gerçek Araba	0	2496	0
Gerçek Arka plan	4	0	4142

Gerçekleştirilen test senaryoları sonrasında elde edilen performanslar her sınıf doğruluk parametresi için hesaplanmış ve Tablo 4.42’de gösterilmiştir.

Tablo 4.53: Test senaryoları sonunda her sınıf için başarı sonuçları.

Test Senaryosu	Sensör	Sınıf		
		Araba	İnsan	Arka Plan
Test Senaryo-1	Mikrofon	%100,0	%96,37	%99,61
	İvme ölçer	%100,0	%87,38	%99,46
Test Senaryo-2	Birleştirilmiş Veri	%100,0	%97,92	%99,78
Test Senaryo-3 (Önerilen Yöntem)	Birleştirilmiş Veri	%100,0	%99,01	%99,90

4.5. Bölüm Özeti

Bu bölümde, insan araç ve arka plan sınıflandırması için tasarlanan makine öğrenmesi algoritmalarının geliştirilme süreci ve bu süreçte kullanılan yöntemler detaylı şekilde ele alınmıştır. Çalışma, üç ana adımdan oluşan bir sistemin (Şekil 3.3) farklı yöntemler ve algoritmalar kullanılarak çözüm üretilmesi hedeflenmiştir. Sınıflandırma performansını optimize etmek amacıyla parametre ayarlarının önemi vurgulanmış ve değerlendirme sürecinde kesinlik, duyarlılık ve F-1 skoru performans metrikleri olarak kullanılmıştır.

Veri setinin oluşturulması sürecinde, üç eksenli ivmeölçer ve mikrofon sensörlerinden elde edilen veriler analiz edilmiştir. Sensörlerden alınan sinyallerin zaman ve frekans uzayı öznitelikleri çıkartılmış, bu öznitelikler üzerinde normalizasyon ve boyut

azaltımı (TBA) işlemleri uygulanmıştır. Dengeli bir veri seti oluşturmak için sınıflar arasındaki örnek sayıları artırılarak sınıf dengesizliği giderilmiştir.

Çalışmada önerilen yöntemin başarılı sonuç sağladığını gösterebilmek için üç farklı test senaryosu ile değerlendirmesi gerçekleştirilmiştir.

- Test-1: Her bir sensörün bağımsız sınıflandırma performansı DVM, k-EYK ve XGBoost yöntemleriyle analiz edilmiştir.
- Test-2: Farklı sensörlerden elde edilen veriler birleştirilerek sınıflandırma yapılmış ve birleşik veri setinin sınıflandırma performansı incelenmiştir.
- Test-3: Önerilen algoritmanın tespit yönteminin başarısının birleştirilmiş veri ile yapılan tespit sonucundan daha başarılı olduğu gösterilmiş ve önerilen yöntemin bütün sınıfları sınıflandırma noktasında Test-1 ve Test-2 senaryolarından daha başarılı sonuç verdiği gösterilmiştir.

Sonuçlar, önerilen yöntemin hem bireysel sensör verileriyle yapılan analizlere hem de doğrudan birleştirilmiş veri setiyle yapılan sınıflandırmalara kıyasla daha yüksek performans sağladığını göstermektedir. Önerilen yöntemin, daha iyi bir tespit sonucu ve daha yüksek bir sınıflandırma performansı sağladığı gösterilmiştir. Ayrıca, farklı sınıflandırma yöntemlerinin ve parametrelerinin sınıflandırma üzerindeki etkisi detaylı şekilde analiz edilmiştir.

Bu bölüm, önerilen algoritmanın tasarımı, kullanılan yöntemleri, veri işleme adımlarını ve test senaryoları ile sonuçların kapsamlı olarak anlatıldığı bir bölümdür.

5. SONUÇLAR

Sınır güvenliğini arttırmaya yönelik olarak, otomatik hareketli yer hedeflerinin insan ve araba tanıma sisteminin geliştirilmesi hedeflenmiştir. Bu problemin çözümü için akustik ve sismik sensörler tercih edilmiştir. Söz konusu sensörleri, pasif oldukları için düşük kurulum, işletme ve bakım maliyetlerine sahip olup, aynı zamanda düşük güç tüketimine sahiptir.

Akustik ve sismik hareketli hedef tanıma üzerine yapılan literatür taramaları sonucunda belirli çözümlere ulaşılmıştır. Öncelikle, bu çalışmaların büyük bir kısmının askeri araçların sismik karakterleri kullanılarak sınıflandırılmasına yönelik olduğuna rastlanmıştır. Ek olarak karayolu taşıtlarının da sınıflandırılması için çalışmalara da rastlanmıştır. Bazı çalışmalarda, sismik sinyaller ile akustik sinyallerin kullanılması tanıma performansını belirli ölçüde arttırdığı gösterilmiştir.

Sensörlerin sinyal karakteristiğini etkileyen birçok faktör olduğu bilinmektedir. Akustik ve sismik sinyallerin karakteristik özellikleri belirli oranda açıklanmaya çalışılmıştır. Bu kapsamda problemin çözümü için gerçek veri toplanması işlemi gerçekleştirilmiştir. 3. Bölümde otomatik veri toplama sisteminin bileşenleri ve sistem blok diyagramı gösterilmiştir. Çalışmada optimum tanıma performansına ulaşabilmek için toplanan veriler üzerinden öznitelik çıkarımı işlemi gerçekleştirilmiştir. İki farklı sensör için kullanılabilecek ortak ve farklı öznitelik çıkarımı yöntemleri ele alınmıştır. Elde edilen özniteliklerin sınıfları ayırabilme yeteneklerine karar verebilmek için kullanılabilecek sınıflandırma algoritmalarından bahsedilmiştir. Çalışmanın esas konusu olan hareketli yer hedeflerinin sınıflandırılması için özgün ve yenilikçi bir yöntem önerilmiştir. Önerilen yöntemin algoritma akış diyagramı verilmiştir.

4. bölümde ise çalışmada özelinde analiz ve testler gerçekleştirilmiştir. Problemin çözümü için iki sensörün verileri ilk olarak ayrı ayrı ele alınmış ve çalışmanın ilk test senaryosu kurgulanmıştır. Bu aşamada her bir sensör için DVM k-EYK ve XGBoost algoritmaları kullanılmıştır. Elde edilen sonuçlar şu şekildedir.

- Titreşim verileri: İnsan sınıfı için doğruluk oranı görece düşük bulunmuş, bunun nedeni titreşim sinyallerinin sınıflar arasında daha az belirgin ayrımlar içermesi olarak değerlendirilmiştir.

- Ses verileri: İnsan sınıfı için doğruluk oranı önemli ölçüde arttığı gözlemlenmiştir. Titreşim verilerine göre ayırt etmede daha başarılı olduğu görülmüştür.
- Oluşturulan modeller içerisinde XGBoost algoritması diğer yöntemlere kıyasla daha iyi sonuç vermiştir.

Test Senaryosu-2’de farklı sensörlerden elde edilen veriler birleştirilmiş ve birleştirilmiş veri seti üzerinden sınıflandırma gerçekleştirilmiştir. Bu adımda elde edilen sonuçlar, birleştirilmiş sensör verilerinin sensörlerin tek başına kullanıldığı durumlara göre daha fazla bilgi taşıdığı için sınıflandırma performansında artış sağladığı gözlemlenmiştir.

Test Senaryosu-3 ise çalışmada kullanılması önerilen iki aşamalı çözüm yönteminin her aşamasının değerlendirilmesi şeklinde kurgulanmıştır. İlk aşamada önerilen tespit yönteminin tespit performansı birleştirilmiş veri kullanılarak yapılan tespit ile kıyaslanmış ve önerilen yöntemin tespit performansının daha iyi sonuç verdiği gösterilmiştir. Sınıflandırma aşaması da tamamlanarak insan ve araba ayrımı yapılmış ve önerilen yöntemin sınıflandırma performansı hesaplanmıştır. Elde edilen sonuçlar Test Senaryosu-1 ve Test Senaryosu-2’de elde edilen sonuçlar ile karşılaştırılmıştır. Bütün sınıflar özelinde doğruluk metriği üzerinden karşılaştırma yapılmıştır. Önerilen yöntemin bütün sınıfları yüksek doğrulukla sınıflandırıldığı gösterilmiştir.

Sonuçlar incelendiği zaman önerilen yöntemin araba sınıfını %100,0 insan sınıfını %99,01 ve arka plan verilerini %99,90 performansla sınıflandırdığı gösterilmiştir.

REFERANSLAR

- [1] Tian Y. and Qi H., (2002), "Target detection and classification using seismic signal processing in unattended ground sensor systems", 2002 IEEE International Conference on Acoustics, Speech, and Signal Processing, 4172-4176, Orlando, FL, USA, 13-17 May.
- [2] H. O. Park, A. Dibazar, and T. W. Berger, (2009), "Cadence analysis of temporal gait patterns for seismic discrimination between human and quadruped footsteps", 2009 IEEE International Conference on Acoustics, Speech, and Signal Processing, 1749–1752, Taipei, Taiwan, 19-24 April.
- [3] M. Wyssession, S. Stein, (1991). "An Introduction to Seismology Earthquakes Earth Structure", 2nd Edition, Wiley.
- [4] P. Bormann, (2012), "New Manual of Seismological Observatory Practice 2 (NMSOP2)", 2nd Edition, GFZ German Research Center for Geosciences.
- [5] L. Beker, (2023), "Uç ağırlıklı piezoelektrik kirişlerin ivmeölçer olarak tasarımı ve sayısal analizi", Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi, 39 (3), 350-356.
- [6] E. Özgündüz, H. İ. Türkmen, T. Şentürk, M. E. Karşılıgil and A. G. Yavuz, (2010), "Vehicle identification using acoustic and seismic signals" 2010 IEEE 18th Signal Processing and Communications Applications Conference (SIU), 941-944, Diyarbakir, Turkey, 22–24 April.
- [7] R. Ghosh, A. Akula, Satish Kumar and H. K. Sardana, (2015), "Time-frequency analysis based robust vehicle detection using seismic sensor", Journal of Sound and Vibration, 346, 424-434.
- [8] M. Kalra, S. Kumar, and B. Das (2018), "Target detection using smooth pseudo Wigner-Ville distribution" 2018 IEEE Recent Advances in Intelligent Computational System (RAICS), 6-10, Thiruvananthapuram, India, 06-08 December.
- [9] B. Mukhopadhyay, S. Anchal, and S. Kar, (2018), "Detection of an intruder and prediction of his state of motion by using seismic sensor", IEEE Sensors Journal, 18 (2), 703–712.
- [10] M. Kalra, S. Kumar, and B. Das, (2020), "Seismic signal analysis using empirical wavelet transform for moving ground target detection and classification", IEEE Sensors Journal, 20 (14), 7886-7895.
- [11] M. Okutan, (2016), "Sismik sinyal işleme tabanlı hedef tespiti ve sınıflandırması", Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi
- [12] L. Pucci, E. Testi, E. Favarelli and A. Giorgetti, (2020), "Human activities classification using biaxial seismic sensors", IEEE Sensors Letters, 4 (10), 1-4.

- [13] Y. Wang, X. Cheng, P. Zhou, B. Li and X. Yuan, (2019) "Convolutional neural network based moving ground target classification using raw seismic waveform as input", *IEEE Sensors Journal*, 19 (14), 5751-5759.
- [14] Y. Qian, H. Tang, Y. Ran and B. Li, (2023), "Target classification in unattended ground sensors with a two-stream convolutional network", *IEEE Sensors Journal*, 23 (4), 3747-3755.
- [15] L. Sun, Z. Zhang, H. Tang, H. Liu and B. Li, (2023) "Vehicle acoustic and seismic synchronization signal classification using long-term features", *IEEE Sensors Journal*, 23 (10), 10871-10878.
- [16] M. Durnerin and N. Martin, (2000), "Minimum variance filters and mixed spectrum estimation", *Signal Processing*, 80 (12), 2597-2608.
- [17] R. A. Fisher, (1936), "The use of multiple measurements in taxonomic problems," *Annals of Eugenics*, 7 (2), 179–188.
- [18] A. Rehman, A. Khan, M. A. Ali, M. U. Khan, S. U. Khan and L. Ali, (2020), "Performance Analysis of PCA, Sparse PCA, Kernel PCA and Incremental PCA Algorithms for Heart Disease Classification", 2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE), 585-589, Istanbul, Turkey, 12-13 June.
- [19] P. K. Syriopoulos, N. G. Kalampalikis, S. B. Kotsiantis, and M. N. Vrahatis, (2023), "kNN Classification: a review," *Annals of Mathematics and Artificial Intelligence*, 91 (1), 1–25.
- [20] S. Marsland, (2009), "Machine Learning: An Algorithmic Perspective", 2nd edition, Chapman and Hall/CRC.
- [21] Andrew H. Jazwinski, (1970), "Stochastic Processes and Filtering Theory", 1st Edition, Academic Press.
- [22] C. Cortes and V. Vapnik, (1995), "Support-vector networks," *Machine Learning*, 20 (3), 273–297.
- [23] T. Chen and C. Guestrin, (2016), "XGBoost: A Scalable Tree Boosting System", 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, (KDD), 785–794, San Francisco, CA, USA, 13 August.
- [24] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, (1986), "Learning representations by back-propagating errors", *Nature*, 323 (6088), 533–536.

ÖZGEÇMİŞ

İsmail Can BÜYÜKTEPE 2018 yılında Gebze Teknik Üniversitesi (GTU) Elektronik Mühendisliği bölümünü tamamlamıştır. Meslek hayatına 2018 yılında SADTEK Elektronik firmasında yazılım mühendisi olarak başlamış ve 2019 yılında ARÇELİK Merkez Arge bünyesinde Test ve Onay bölümünde Proje mühendisi olarak görev almıştır. 2021 yılından itibaren HAVELSAN A.Ş.'de yazılım mühendisi olarak görevine devam etmektedir. LHD, MİLGEM, Pakistan MİLGEM, Endonezya SYS, Ukrayna SYS, ADVENT MARTI projelerinde aktif rol almıştır. Aynı zamanda dost düşman tanıma sistemi üzerine yazılım entegrasyonu ve geliştirme çalışmalarını sürdürmektedir. 2025 yılında Gebze Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim Dalında yüksek lisans eğitimini tamamlamıştır.

TEZ ÇALIŞMASI KAPSAMINDA YAPILAN YAYINLAR

[1] İ. C. Büyüktepe and A. K. Hocaoglu, (2022), "Classification of Moving Ground Targets Using Measurement from Accelerometer on Road Surface", 30th Signal Processing and Communications Applications Conference (SIU), pp. 1-4, Safranbolu, Turkey, 15-18 May.

[2] İ. C. Büyüktepe, K. İnce and A. K. Hocaoglu, (2024), "Classification of Moving Ground Targets Using Accelerometer and Microphone Data" 2024 32nd Signal Processing and Communications Applications Conference (SIU), pp. 1-4, Mersin, Türkiye, 15-18 May.