

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



AKUSTİK VERİLERİN AKILLI HESAPLAMA
YÖNTEMLERİYLE ANALİZİ

Bilal TEKİN

Yüksek Lisans Tezi

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ŞUBAT 2025

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

AKUSTİK VERİLERİN AKILLI HESAPLAMA YÖNTEMLERİYLE
ANALİZİ

Tez Yazarı
Bilal TEKİN

Danışman
Doç. Dr. Turgay KAYA

ŞUBAT 2025
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı: Akustik Verilerin Akıllı Hesaplama Yöntemleriyle Analizi
Yazarı: Bilal TEKİN
İlk Teslim Tarihi: 16.01.2025
Savunma Tarihi: 14.02.2025

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

İmza

Danışman: Doç. Dr. Turgay KAYA
Fırat Üniversitesi, Mühendislik Fakültesi
Onayladım

Başkan: Prof. Dr. Melih Cevdet İNCE
Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi
Onayladım

Üye: Prof. Dr. Hasan GÜLER
Fırat Üniversitesi, Mühendislik Fakültesi
Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım ‘‘Akustik Verilerin Akıllı Hesaplama Yöntemleriyle Analizi’’ Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteđi olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

14.02.2025

Bilal TEKİN



ÖNSÖZ

Bu tez çalışmasında Akustik Verilerin Akıllı Hesaplama Yöntemi İle Analizi için MATLAB programında veri setinden alınan sesler eğitilmiş ve eğitilen veriler test sesleri üzerinden başarımları performansları incelenerek en iyi başarımları veren karar ağacı tespit edilmiştir. Hava araçlarının tespiti yapılarak kurum, kuruluş veya belirli alanlardaki koruma ekipmanlarını verimli kullanmak için hızlı bildirim yapılması hedeflenmiştir.

Bu tez çalışması boyunca bilgi ve tecrübelerinden faydalandığım, yardımlarını ve desteklerini esirgemeyen danışman hocam sayın Doç. Dr. Turgay Kaya'ya teşekkürlerimi ve saygılarımı sunarım. Son olarak tez çalışmamda maddi manevi desteğini esirgemeyen aileme ve arkadaşlarıma çok teşekkür ederim.

Bilal TEKİN
ELAZIĞ, 2025

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLOLAR LİSTESİ	x
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Tezin Amacı	1
1.2. Tezin Organizasyonu	2
2. AKILLI HESAPLAMA YÖNTEMLERİ	3
2.1. Akıllı Hesaplamanın Temel Özellikleri:	3
2.2. Akıllı Hesaplamanın Kullanım Alanları:	3
2.3. Akıllı Hesaplamanın Kapsadığı Teknikler:	4
2.3.1. Makine Öğrenmesi	4
2.3.2. Derin Öğrenme	6
2.3.3. Bulanık Mantık.....	6
2.3.4. Evrimsel Hesaplama.....	7
2.3.5. Yapay Sinir Ağları	7
2.3.6. Doğal Dil İşleme	7
3. AKUSTİK VERİLERİN AKILLI HESAPLAMA YÖNTEMLERİYLE ANALİZİ	8
3.1. Akustik Verilerin Akıllı Hesaplama Yöntemleriyle Analizinin Kullanım Alanları.....	10
4. AKUSTİK VERİLERLE DRONE VE HELİKOPTER TESPİTİ.....	11
4.1. Akustik Verilerle Drone ve Helikopter Tespiti Çalışması	11
4.1.1. Ses Kaynağının Tanımlanması	11
4.1.2. Akustik Sinyal Toplama	12
4.1.3. Sinyal İşleme ve Özellik Çıkartma.....	12
4.1.4. Makine Öğrenmesi ve Sınıflandırma.....	12
4.1.5. Tespit ve Uyarı Sistemi	13
4.2. Akustik Veri ile Drone ve Helikopter Tespitinin Avantajları.....	13
4.2.1. Görsel ve Radar Sistemlerine Bağımlılığı Azaltma:	13
4.2.2. Farklı Frekanslar ve Ses Tipleri:	13
4.2.3. Daha Erken Tespit:	13
4.2.4. Daha Düşük Maliyetli Çözümler:.....	13
4.3. Zorluklar ve Sınırlamalar.....	14
4.3.1. Gürültü ve Karışıklık:.....	14
4.3.2. Hedeflerin Yüksek Hızda Uçması:	14
4.3.3. Çoklu Hedeflerin Tespiti:	14
5. MATERYAL VE METOT	15
5.1. Dosya Okuma ve Ses Verisi İşleme.....	16
5.2. Sıfır Geçiş Oranı Hesaplama	17

5.3. Ön-impuls İşlemi	17
5.4. Framelenme ve Pencereleme	18
5.5. Mel-Frekans Filtreleme	20
5.6. Mel-Frekans Filtre Bankasının Uygulanması	21
5.7. MFCC Hesaplama	22
5.8. Etiketleme	23
5.9. Veri Depolama.....	23
5.10. Tablo Oluşturma	23
5.11. Sınıflandırma ve Eğitim	23
5.12. İstatiksel Model Analizi.....	23
6. BULGULAR VE TARTIŞMA	25
7. SONUÇLAR.....	34
ÖNERİLER	35
KAYNAKLAR.....	36
ÖZGEÇMİŞ	

ÖZET

Akustik Verilerin Akıllı Hesaplama Yöntemleriyle Analizi

Bilal TEKİN

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Şubat 2025, Sayfa: xi + 37

Günümüzde hava araçlarının kullanımı hızla artarken, bu araçların tespiti ile akustik analizlerin önemi artmaktadır. Helikopterler ve drone gibi hava araçları, belirli bir frekans aralığında ses yayar ve bu seslerin analizi, araçların uçuş karakteristiklerinin anlaşılmasını sağlar. Her iki araç türü, farklı aerodinamik yapıları ve motor sistemleri nedeniyle farklı ses profilleri üretmektedir. Bu tez, drone ve helikopterlerin akustik verilerle analizini amaçlamaktadır.

Çalışma, ses dosyalarından elde edilen Mel-Frekans Cepstral Katsayıları (MFCC) ve Zero-Crossing Rate (ZCR) gibi akustik parametrelerin kullanılmasıyla, her bir araç türünün karakteristik ses özelliklerini sınıflandırılmıştır. Toplam 546 ses dosyasından elde edilen verilerle; drone, helikopter ve çevre sesleri arasında ayırım yapabilen bir sınıflandırma modeli geliştirilmiştir. Eğitim süreci, karmaşıklık matrisine dayalı başarımlar kriterleri ile değerlendirilmiştir.

MATLAB yazılımı kullanılarak gerçekleştirilen akustik analiz, her iki araç türünün akustik imzalarını ortaya koymuş ve bu yazılım ile çevre gürültüsünün etkisini minimize eden bir model önerilmiştir.

Sonuçlar, akustik analizlerin drone ve helikopterlerin tanımlanması ve izlenmesi gibi uygulamalarda önemli bir araç olabileceğini ortaya koymaktadır. Ayrıca, çevresel gürültülerin etkisini minimize ederek, sadece hedef seslerin algılanmasını sağlayan model, güvenlik ve izleme teknolojilerinde kullanılacak potansiyeli göstermektedir. Bu çalışma, akustik verilerle hava araçları ve çevre seslerinin sınıflandırılması konusunda önemli bir adım atılmasını sağlamaktadır.

Anahtar Kelimeler: Akustik veri, Drone tespiti, Akıllı hesaplama yöntemi

ABSTRACT

Analysis of Acoustic Data with Intelligent Computational Methods

Bilal TEKİN

Master's Thesis

FIRAT UNIVERSITY

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

February 2025, Pages: xi + 37

Nowadays, as the use of aircraft is rapidly increasing, the importance of acoustic analysis increases with the detection of these vehicles. Aircraft such as helicopters and drones emit sounds in a certain frequency range, and the analysis of these sounds allows the flight characteristics of the vehicles to be understood. Both types of vehicles produce different sound profiles due to their different aerodynamic structures and engine systems. This thesis aims to analyze drones and helicopters with acoustic data.

The study classifies the characteristic sound features of each vehicle type using acoustic parameters such as Mel-Frequency Cepstral Coefficients (MFCC) and Zero-Crossing Rate (ZCR) obtained from sound files. A classification model that can distinguish between drone, helicopter and environmental sounds was developed with the data obtained from a total of 546 sound files. The training process was evaluated with performance criteria based on the complexity matrix.

The acoustic analysis performed using MATLAB software revealed the acoustic signatures of both vehicle types, and a model that minimizes the effect of environmental noise was proposed with this software.

The results show that acoustic analysis can be an important tool in applications such as identification and tracking of drones and helicopters. In addition, the model, which minimizes the effect of environmental noise and detects only target sounds, shows the potential to be used in security and monitoring technologies. This study provides an important step in the classification of aircraft and environmental sounds with acoustic data.

Keywords: Acoustic data, Drone detection, Intelligent calculation method

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Makine Öğrenimi Türleri	5
Şekil 4.1. Akustik Verilerin Tespit Aşamaları.....	11
Şekil 5.1. Ses Dosyalarının İşlenmesine ait akış diyagramı	16
Şekil 6.1. MFCC1 ile MFCC2 dağılım grafiği	26
Şekil 6.2. MFCC1 ile ZCR dağılım grafiği	26
Şekil 6.3 Doğrulama Karışıklık Matrisi	27
Şekil 6.4. Model 2.11 MFCC1'in MFCC2 ile ZCR' ye göre dağılım grafiği	27
Şekil 6.5. Model 2.27 MFCC1'in MFCC2 ile ZCR' ye göre dağılım grafiği	28
Şekil 6.6. Model 2.29 MFCC1'in MFCC2 ile ZCR' ye göre dağılım grafiği	28
Şekil 6.7. Model 2.11 Doğrulama Karışıklık Matrisi	29
Şekil 6.8. Model 2.27 Doğrulama Karışıklık Matrisi	29
Şekil 6.9. Model 2.29 Doğrulama Karışıklık Matrisi	30

TABLÖLAR LİSTESİ

	Sayfa
Tablo 5.1. Veri setinde kullanılan etiketler ve veri sayıları	15
Tablo 6.1. Eğitilen veri setinin doğruluk sonuçları	25
Tablo 6.2. Kuadratik Destek Vektör Makinesi İstatiksel Model Analizi	30
Tablo 6.3. Dar Yapay Sinir Ağı İstatiksel Model Analizi	30
Tablo 6.4. Geniş Yapay Sinir Ağı İstatiksel Model Analizi	30



SİMGELER VE KISALTMALAR

Kısaltmalar

MFCC	: Mel Frekans Cepstral Katsayıları
ZCR	: Sıfır Geçiş Oranı (Zero-Crossing Rate)
ASR	: Otomatik Konuşma Tanıma
SVM	: Destek Vektör Makineleri
KNN	: K-En Yakın Komşu
N	: Sinyalin toplam örnek sayısı
MFB	: Mel-Frekans Filtre Bankası
DCT	: Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform)
CNN	: Konvolüsyonel Sinir Ağları
RNN	: Tekrarlayan Sinir Ağları
ANN	: Yapay Sinir Ağları (Artificial Neural Networks)
NLP	: Doğal Dil İşleme (Natural Language Processing)
DNN	: Derin Sinir Ağları
ADL	: Günlük Yaşam Aktiviteleri (Activities of Daily Living)
DL	: Derin Öğrenme
SED	: Ses Olayı Algılama

1. GİRİŞ

Günümüzde hava araçlarının sayısı hızla artmakta ve bu araçlar, askeri, ticari ve sivil alanlarda yaygın olarak kullanılmaktadır. Bu araçların güvenli ve verimli bir şekilde çalışabilmesi, doğru bir şekilde izlenebilmesi ve kontrol edilebilmesi için birçok teknolojik gelişme yaşanmaktadır. Bu gelişmelerin başında, hava araçlarının akustik özelliklerinin incelenmesi yer almaktadır. Akustik analiz, ses dalgaları kullanılarak araçların tanımlanması, izlenmesi ve performansının değerlendirilmesi gibi kritik alanlarda önemli bir yere sahiptir.

Helikopterler ve drone gibi hava araçları, belirli bir frekans aralığında ses yayarlar ve bu seslerin analizi, araçların uçuş karakteristiklerinin anlaşılmasına olanak sağlar. Akustik veriler, bu araçların hızları, yükseklikleri, motor durumları ve çevresel etkileri hakkında bilgi verebilir. Ancak, her iki hava aracının da farklı aerodinamik yapıları ve motor sistemleri olduğu için yaydıkları ses profilleri birbirinden farklılık göstermektedir. Bu nedenle, drone ve helikopterlerin akustik özelliklerini karşılaştırarak her bir araç için özel analizlerin yapılması önemlidir.

Ses dosyaları, zaman frekans analizi, spektral özellikler ve diğer akustik parametreler kullanılarak işlenmektedir. Özellikle, ses dalgalarının frekans içeriği ve genlik analizleri, her bir ses kaynağının karakteristik özelliklerini belirlemek için kullanılmıştır. Akustik veri analizinde, geleneksel ses tanıma ve sınıflandırma yöntemleri uygulanmıştır. Bu yöntemlerle drone ve helikopter seslerinin, çevre gürültüsünden etkin bir şekilde ayrılabilirdiğini ve her bir ses kaynağının kendine has akustik imzasının doğru bir şekilde sınıflandırılabilirdiğini gösterebilmektedir.

Yapılan tez çalışmasında akustik analizlerin drone ve helikopterlerin tanımlanması ve izlenmesi gibi uygulamalarda önemli bir araç olabileceği gösterilmiştir. Ayrıca, çevresel gürültülerin etkisini minimize ederek, sadece hedef seslerin algılanmasını sağlayan model, güvenlik ve izleme teknolojilerinde kullanılabilecek potansiyeli göstermektedir. Bu çalışma, akustik verilerle hava araçları ve çevre seslerinin sınıflandırılması konusunda çalışma yapacak araştırmacılar için yardımcı olacaktır.

1.1. Tezin Amacı

Akıllı hesaplama yöntemleri, akustik veri analizi için kullanılan başlıca yöntemlerden birisidir. Drone, helikopter gibi saldırı ve gözetleme amaçlı kullanılan hava araçlarının erken tespiti hayati önem taşımaktadır. Bu tez çalışmasında,

1. Drone ve helikopter tespiti yapılarak herhangi bir kurum/kuruluşa yapılacak olası tehditleri hızlı tespit ederek erken müdahale ihtimalini arttırmak,
2. Belirlenen bir bölgeyi korumak için kullanılan sistemleri saldırıyı yapan araca karşı uygun/verimli kullanmak,

3. Drone tespiti ile olası hava araçları kazalarının önlenmesi amaçlanmaktadır.

Bu tez çalışmasında dış ortamdan alınan ses verisi analiz edilerek anlık olarak gerçekleşen hava araçlarının durumlarının belirlenmesi gerçekleştirilmiştir. Bu analiz işlemi akıllı hesaplama yöntemleri kullanılarak bir ses dosyasından özellik çıkarımı (MFCC, ZCR) yaparak bu verileri bir etiketle işlemi yapılmakta, ardından veriler bir tabloya yerleştirmektedir. Her bir dosya için MFCC ve ZCR hesaplanıp, etiketlerle birlikte birleştirilerek sınıflandırma algoritmalarına sunulmak üzere hazır hale getirilmektedir. Bu algoritmaların eğitilmesi sonucunda eğitim seti oluşturulmuştur. Kullanılacak arayüz ile yeni ses girdileri analiz edilerek hava aracı olduğu durumda tespitini gerçekleştirerek müdahale imkânını bize sağlayacaktır.

Çalışmanın amacı, drone ve helikopterlerin yaydığı seslerin karşılaştırılması, bu araçların akustik imzalarının ortaya konulması ve her iki türün karakteristik akustik davranışlarının sınıflandırılmasıdır. Ayrıca, bu akustik verilerin, hava aracı türlerini tanımada veya izleme teknolojilerinde nasıl kullanılabilceğine dair pratik önerilerde bulunulacaktır. Sonuç olarak, bu tez çalışması, hava araçlarının akustik analizlerinin teknolojik ilerlemelere nasıl katkı sağlayabileceğini ve güvenlik ile performans değerlendirmelerindeki potansiyelini ortaya koymayı hedeflemektedir.

1.2. Tezin Organizasyonu

Bu tez çalışmasının 2. bölümünde akıllı hesaplama yöntemleri, 3. bölümünde akustik verilerin akıllı hesaplama yöntemleriyle analizi, 4. bölümünde akustik verilerle drone ve helikopter tespiti ve 5. bölümde ise sunulan yöntem anlatılmaktadır.

2. AKILLI HESAPLAMA YÖNTEMLERİ

Akıllı hesaplama (Intelligent Computing), bilgisayarların ve yapay zekânın insan benzeri düşünme, öğrenme ve problem çözme becerilerini taklit ederek karmaşık görevleri yerine getirmelerini sağlayan bir yaklaşımdır [1]. Bu terim, genellikle makine öğrenmesi, yapay zekâ, derin öğrenme, bulanık mantık, evrimsel hesaplama ve diğer zekâ tabanlı hesaplama tekniklerini içeren geniş bir alanı kapsamaktadır.

2.1. Akıllı Hesaplamanın Temel Özellikleri:

Akıllı hesaplama sistemleri, çevrelerinden ve deneyimlerinden öğrenme yeteneğine sahiptir, bu sayede zaman içinde daha verimli hale gelmektedir. Bu süreç, veri analizi, örüntü tanıma ve modelleme gibi tekniklerle gerçekleştirilmektedir. Makine öğrenmesi algoritmaları bu tür sistemlerin öğrenme sürecini yönetmektedir [2]. Akıllı hesaplama yöntemleri, karmaşık ve çok değişkenli problemleri çözme yeteneğine sahip olup, bu tür problemler geleneksel algoritmalarla çözülemeyecek kadar zor ve dinamik olabilmektedir [3]. İnsan müdahalesine gerek kalmadan bu tür sorunları çözebilme kapasitesi, akıllı hesaplamaı oldukça güçlü bir araç haline getirmektedir [4]. Ayrıca, akıllı hesaplama sistemleri değişen koşullara uyum sağlama yeteneğine sahiptir, bu da onları esnek ve uyarlanabilir kılmaktadır. Bu esneklik, sistemlerin farklı ortamlarda ve senaryolarda etkili bir şekilde çalışabilmesini sağlamaktadır. Akıllı hesaplama, bulanık mantık gibi tekniklerle kesin olmayan veya belirsiz verilerle de başa çıkabilmektedir. Bu sayede, sistemler belirsiz veriler üzerinde anlamlı kararlar alabilir ve doğru sonuçlar üretmektedir. Akıllı hesaplamanın tüm bu özellikleri, onu geleneksel hesaplama yöntemlerine göre çok daha etkili ve uygulanabilir kılmaktadır [5].

2.2. Akıllı Hesaplamanın Kullanım Alanları:

Akıllı hesaplama, çeşitli alanlarda önemli uygulamalara sahiptir. Örneğin, otomatik sürüş sistemleri, araçların çevresini algılayarak ve öğrendikleri verilerle kararlar alarak kendi başlarına hareket etmelerini sağlamaktadır. Bu teknoloji, sürücüsüz araçların güvenli bir şekilde yol alabilmesi için kritik bir rol oynamaktadır [6]. Sağlık ve medikal tanı alanında ise akıllı hesaplama, hastalıkları tanımlamak ve tedavi yöntemleri önermek için tıbbi verileri analiz edebilmektedir. Bu durum, daha hızlı ve doğru tanımlar koymayı mümkün kılmaktadır. Finansal tahminlerde, akıllı hesaplama algoritmaları piyasa trendlerini analiz ederek yatırım stratejilerinin gelişmesine yardımcı olurken finansal kararlar daha bilgiye dayalı hale gelmektedir. Akıllı ev sistemlerinin kullanımında, evdeki cihazların ve sistemlerin birbirleriyle etkileşimde bulunarak daha verimli bir

yaşam ortamı sağlamlasını mümkün kılmaktadır [7]. Son olarak, görüntü işleme ve ses tanıma teknolojileri, güvenlik, etkileşim ve erişilebilirlik gibi alanlarda önemli bir rol oynamaktadır. Bu da akıllı hesaplamanın günlük yaşamda geniş bir yelpazede fayda sunduğunu göstermektedir.

2.3. Akıllı Hesaplamanın Kapsadığı Teknikler:

2.3.1. Makine Öğrenmesi

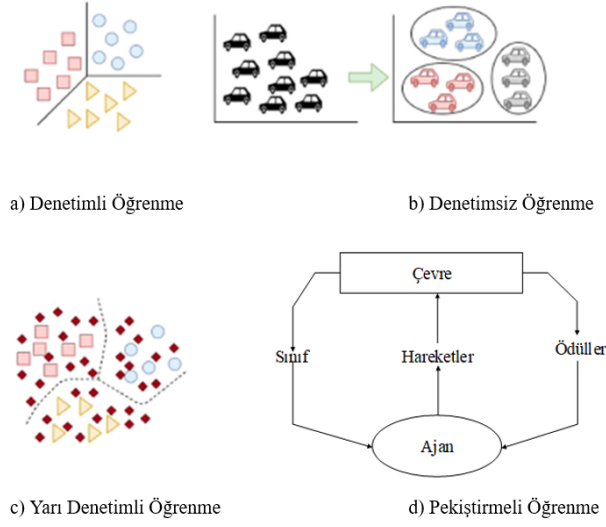
Makine Öğrenmesi (Machine Learning), verilerden öğrenme ve model geliştirme süreçlerini içermektedir. Bu yöntem, gelecekteki verilere dayalı tahminler veya sınıflandırmalar yapabilen algoritmaların geliştirilmesine olanak tanımaktadır [8].

Makine Öğrenimi, problem çözmeye yönelik faaliyetlerde insanların rolünü taklit etmek için kullanılan, Yapay Zekâ (AI) alanındaki bir yaklaşım tekniğidir. Kısacası makine öğrenimi, kullanıcılarından herhangi bir yönlendirme almadan öğrenip iş yapabilen bir makinedir [9]. Bilgisayar oyunları ve yapay zekâ alanında Amerikalı bir öncü olan Arthur Samuel, makine öğrenimini, bilgisayarların yeteneklerinin nasıl tanımlanacağını inceleyen bir bilim dalı olarak tanımlamıştır. Bu teknoloji, açıkça programlanmadan öğrenebilen bir sistemin temelini oluşturmaktadır. Bir makine öğrenimi sistemi, önceki verilerden elde edilen fikirlere dayanarak, kalıpları tanımlayabilmekte ve minimum insan müdahalesi ile kararlar alabilmektedir. Bu özellik sayesinde makine öğrenimi, öğrendikçe sınırlarını aşabilmektedir.

Makine öğrenimi terimi ilk kez duyurulduğundan beri, bu alanda pek çok önemli gelişme kaydedilmiştir. Bunlardan en ünlüsü, 1996 yılında IBM tarafından geliştirilen ve satranç oynama yeteneğiyle tanınan Deep Blue'dur. Deep Blue, profesyonel satranç şampiyonlarını yenerek büyük bir popülerlik kazanmıştır. Ayrıca, Tom M. Mitchell makine öğrenimini, "Ölçülebilir bir performans P'nin, bir görev T'nin deneyiminden E öğrenilen bir bilgisayar programı" olarak tanımlamıştır. Örneğin, bir bilgisayar programı, satranç oynama yeteneğini kazanmak için, kendisine karşı oynadığı oyunlardan edindiği deneyime dayalı olarak performansını geliştirebilmektedir.

Makine Öğrenimi Türleri

Genel olarak, makine öğrenimi algoritmaları, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme türlerine ayrılmaktadır. Bu algoritmaların her birinin farklı işlevleri ve hedefleri vardır. Makine öğrenimi türleri Şekil 2.1'de verilmiştir.



Şekil 2.1. Makine Öğrenimi Türleri

a. Denetimli Öğrenme

Denetimli öğrenme, algoritmanın belirli bir girdinin doğru çıktısını tahmin etmesi için eğitildiği bir yaklaşımdır. Algoritma, doğru işlevi tanımlamak için etiketli veri setlerinden öğrenmektedir [10]. Ancak, bu süreçte kullanılan varsayımlar gerçek verilerle uyumsuz olabilir ve bu durum yanlış sonuçlara yol açabilmektedir. Bu nedenle, doğru eğitim verileri sağlanarak algoritmanın örüntüleri tanınması, regresyon, sınıflandırma, KNN, Naive Bayes, Karar Ağaçları, Lineer Regresyon, Destek Vektör Makineleri ve sinir ağları gibi yöntemlerle doğru sonuçlar alınması sağlanmaktadır. Denetimli öğrenme, en yaygın kullanılan makine öğrenimi türüdür. Bu algoritmanın avantajları arasında anlaşılmasının kolay olması ve güçlü sınıflandırma yetenekleri bulunmaktadır. Ancak, dezavantajları arasında uzun hesaplama süresi ve her girişi etiketleme gerekliliği yer almaktadır.

b. Denetimsiz Öğrenme

Denetimsiz öğrenme, etiketli veriler gerektirmeyen bir algoritmadır. Bu tür algoritmalar, verilerdeki kalıpları veya ilişkileri keşfetmek için kullanılmaktadır. Kümelenme ve birliktelik kuralları gibi yöntemler denetimsiz öğrenme altında incelenmektedir [11,12]. Denetimsiz öğrenmenin avantajı, etiketlenmiş veriye ihtiyaç duymaması ve bilinmeyen kalıpları keşfetme esnekliği sunmasıdır. Ancak, etiket eksikliği nedeniyle verilerdeki anlamlı bilgiye ulaşmak zor olabilmektedir.

c. Yarı Denetimli Öğrenme ve Pekiştirmeli Öğrenme

Yarı denetimli öğrenme, etiketli ve etiketsiz verileri birleştiren bir algoritmadır. Bu tür algoritmalar, büyük miktarda veriyi işlerken etiketli verilerin yalnızca bir kısmının kullanılması gerektiği durumlarda kullanılmaktadır [13]. Bu yöntem, düşük maliyetli veri işleme avantajı sunmaktadır. Pekıştirmeli öğrenme ise, ajanların çevreleriyle etkileşime girerek, yaptıkları eylemlerden elde ettikleri geri bildirimler doğrultusunda öğrenmelerini sağlamaktadır. Bu algoritmalar, çevreden alınan ödüllere öğrenme süreçlerini iyileştirir ve zamanla daha doğru kararlar almaktadır [14].

Makine öğrenimi ve veri bilimi, birbirini tamamlayan iki bilim dalı olmaktadır. Her iki alan da, günümüzün veri odaklı dünyasında finans, eğitim, lojistik, iletişim ve moda gibi birçok alanlarda yaygın olarak kullanılmaktadır. Veri bilimi, son yıllarda hızla gelişen ve genişleyen bir alan olarak, giderek artan bir talep görmekte ve farklı disiplinlerde önemli bir yer edinmektedir.

2.3.2. Derin Öğrenme

Derin öğrenme (Deep Learning), makine öğrenmesinin bir alt dalı olarak, çok katmanlı yapay sinir ağlarını kullanarak verilerden daha derin ve soyut özellikler öğrenme yeteneğine sahiptir [15]. Bu teknoloji görüntü işleme, ses tanıma ve doğal dil işleme gibi karmaşık görevlerde etkili bir şekilde kullanılmaktadır. Derin öğrenme, büyük ve karmaşık veri setlerinden öğrenme kapasitesine sahip olup, güçlü ve çok yönlü bir yapay zekâ teknolojisi olarak tanımlanabilir. Özellikle görüntü işleme, doğal dil işleme ve ses tanıma gibi alanlarda derin öğrenme kullanımı ile önemli başarılar elde edilmiştir [16]. Bununla birlikte, derin öğrenme tekniklerinin en verimli şekilde kullanılabilmesi için yüksek hesaplama gücü ve büyük veri setlerine ihtiyaç duyulması, bu teknolojinin bazı zorluklarla karşı karşıya kalmasına yol açmaktadır. Bu bağlamda, derin öğrenme, özellikle yüksek işlem gücüne sahip kaynaklara ve büyük miktarda veriye sahip uygulamalarda büyük bir potansiyele sahip olmaktadır.

2.3.3. Bulanık Mantık

Bulanık Mantık (Fuzzy Logic), kesin olmayan veya belirsiz bilgileri işlemek için kullanılmaktadır. Geleneksel mantık sistemlerinin ötesine geçerek, sınıflandırmalar ve kararlar alırken belirsizliği dikkate almakta ve bu sayede daha esnek bir modelleme imkânı sunmaktadır [17].

2.3.4. Evrimsel Hesaplama

Evrimsel Hesaplama (Evolutionary Computing), doğal seleksiyon ve genetik algoritmalar gibi evrimsel süreçleri taklit etmektedir. Bu teknikler, problemleri çözmek için aday çözümleri evrimsel süreçler aracılığıyla optimize etmektedir. Son yıllarda doğal hayatın izlenmesiyle çok farklı evrimsel algoritma türleri geliştirilmiştir. Bunlar, hem doğandan hem de doğadaki canlıların avlanma ve hayatta kalma süreçlerini taklit ederek geliştirilmiş algoritmalarıdır.

2.3.5. Yapay Sinir Ağları

İnsan beyninin işleyişini taklit eden bir modelleme yaklaşımıdır. Yapay Sinir Ağları (Artificial Neural Networks - ANN) verilerden öğrenme kapasitesine sahip bir yapay zekâ tekniği olarak tanımlanabilir. Çok katmanlı yapılar sayesinde bu ağlar, karmaşık ve yüksek boyutlu problemleri çözme konusunda önemli bir beceriye sahiptir. Sinir ağlarındaki katmanlar, verileri işleyerek daha soyut ve anlamlı özellikler çıkarabilmekte, bu özellik de onları farklı alanlarda etkili bir çözüm aracı haline getirmektedir. Bu yapı, özellikle derin öğrenme tekniklerinin temelini oluşturmakta ve birçok uygulama alanında yüksek başarılar elde edilmesini sağlamaktadır [18].

2.3.6. Doğal Dil İşleme

İnsan dilini anlamak ve işlemek amacıyla kullanılan bir dizi teknik ve yöntemler bütünüdür. Doğal Dil İşleme (Natural Language Processing - NLP), makinelerin dilsel verileri analiz etmesini, anlamlandırmasını ve doğal dilde uygun yanıtlar üretmesini sağlamak için geliştirilmiştir [19]. Akıllı hesaplama sistemleri, bu teknolojiyi kullanarak dilin karmaşıklıklarını çözebilmekte ve insan benzeri etkileşimler gerçekleştirebilmektedir. Böylece makineler, dilin yapısal ve anlamsal özelliklerini daha etkili bir şekilde işleyerek, dilsel verilerle daha verimli bir iletişim kurma kapasitesine ulaşmaktadır [20].

3. AKUSTİK VERİLERİN AKILLI HESAPLAMA YÖNTEMLERİYLE ANALİZİ

Akustik verilerin akıllı hesaplama yöntemleriyle analizi, verilerin doğru ve anlamlı bir şekilde işlenmesini sağlayarak, daha verimli, hızlı ve doğru sonuçlar elde edilmesini sağlamaktadır. Bu yöntemler, akustik sinyallerin sınıflandırılması, tespiti ve tahmin edilmesi gibi çeşitli görevlerde kullanılmaktadır. Bu tür analizler, sağlık, güvenlik, mühendislik, eğlence ve birçok diğer endüstri alanlarında devrim yaratabilecek potansiyele sahiptir.

Akustik sahne sınıflandırması bir akustik sahnede geçici olarak mevcut olan ses olaylarının tespitidir. Bu tür sesli olayların örnekleri arasında araçlar, araba kornaları ve ayak sesleri sayılabilir. Bu görev, akustik olay tespiti olarak adlandırılır ve belirli ses olaylarının kesin zamansal tespitine odaklandığı için akustik sahne sınıflandırmasından önemli ölçüde farklıdır. Son teknoloji akustik sahne sınıflandırması sistemlerinin bu görevde insanlardan daha iyi performans gösterdiği gösterilmiştir. Bu nedenle, bağlama duyarlı giyilebilir ve duyulabilir cihazlar, işleme cihazları, sağlık hizmetleri, güvenlik gözetimi, doğa habitatlarında vahşi yaşam izleme, akıllı şehirler, IoT ve otonom navigasyon gibi çok sayıda uygulama senaryosunda uygulanırlar [21].

Akustik veriler, insan konuşmasının makine tarafından yorumlanması da dâhil olmak üzere çok çeşitli alanlarda bilimsel ve mühendislik çalışmalarını kapsamaktadır. Tüm bu alanlarda veri analizi, veri bozulması, eksik veya seyrek ölçümler, yankılanma ve büyük veri hacimleri gibi zorluklar nedeniyle karmaşık bir yapıdadırlar [22].

Makine öğrenimi teknikleri bilgisayarla görme, görüntü işleme, konuşma işleme ve (jeo)fizik bilimi dâhil olmak üzere birçok alanda otomatik veri işleme ve görüntü tanıma yeteneklerinde geniş ilerlemeler sağlamıştır. Akustikte makine öğrenimi, yukarıda bahsedilen akustik zorluklara birçok zorlayıcı çözüm sunan, hızla gelişen bir alandır. Makine öğrenimi tabanlı tekniklerin akustik alanındaki potansiyel etkisi ve son zamanlarda gördükleri ilgi bu incelemeyi geliştirmektedir. Geniş anlamda Makine öğrenimi, verilerdeki kalıpları otomatik olarak algılamak ve kullanmak için bir teknikler ailesidir. Makine öğreniminde modeller, örneğin, bir hayvanın türü veya akustik dizilerden alınan kayıtlara dayalı olarak konumları gibi ölçülen niteliklere dayalı olarak veri etiketlerini tahmin etmek için kullanılır. Bu ölçümler ve etiketleri genellikle belirsizdir; bu nedenle istatistiksel yöntemler makine öğrenmesi yönteminde sıklıkla kullanılmaktadır [22].

Sesler, günlük çevremizde gerçekleşen olayların ve akustik sinyal işleme ile ilgili bilgilerin büyük bir bölümünü içeren, uzun vadeli bir konudur. Son zamanlarda, derin öğrenme algoritmalarının gelişmesiyle birlikte çok sayıda araştırma bu alanında ortaya çıkmaktadır. Derin sinir ağları (DNN) derin öğrenmede kullanılan yapay sinir ağlarıdır [23].

Yapılan çalışmada [4], mikrofon sensör dizisi aracılığıyla kaydedilen çok kanallı akustik verileri evde günlük yaşam aktivitelerinden biri olarak sınıflandırmaktır. Veri seti, 23 akustik algılama ünitesi ile ev ortamında ve sürekli izleme altında yaşayan denekten toplanmıştır. Bu akustik ses verileri uyumak, yemek pişirmek, yemek yemek, duş almak, sifonu çekmek, eğlenmek, yürümek, kapıyı açıp kapatmaktır. Her aktivite, ses aktivasyonlarının bir kombinasyonudur. Ön aşamada yaşlıların yalnız yaşadığı bir evden sadece 88 günlük akustik sensör aktivasyonu toplanmıştır. 4 numaralı yayında yapılan araştırma, evdeki ziyaretçiler nedeniyle meydana gelen çakışan girdi akustiği aktivasyonlarını atmaktadır. Araştırmanın amacı, yalnız yaşayan yaşlıların ADL'sini tanımak için çok kanallı akustik tabanlı izleme üzerine bir çalışma yürütmektir. Sensör lokalizasyonu bu çalışmalar için önemli olup, her mikrofon sensörünün lokasyon etkinliği ile ilişkili benzersiz bir kimliği vardır [24].

Derin öğrenme, bilgisayarla görme, konuşma tanıma ve doğal dil işleme gibi çeşitli makine öğrenimi problemlerinde en son teknolojiye ulaşmıştır. Gerçek yaşam ortamlarında ses olaylarını tanıma ile ilgili olan ses olayı algılama (SED) son zamanlarda oldukça ilgi görmektedir. Beynin yapısından ve işlevinden ilham alan derin öğrenmenin gelişimi, konuşma tanıma, görüntü tanıma ve doğal öğrenme gibi karmaşık problemlerdeki en son teknolojiyi önemli ölçüde geliştirmiştir. Derin öğrenme, birden fazla soyutlama düzeyine sahip verilerin temsillerini öğrenen birçok katmandan oluşan yapay sinir ağlarını ifade etmektedir. Derin öğrenme, beklenen bir çıkış sinyali üretmek için giriş sinyallerinin dâhili parametrelerinin nasıl değiştirileceğini belirtmek için geri yayılım yaklaşımını kullanarak büyük veri setindeki karmaşık yapıyı öğrenmede verimlilik göstermiştir [25].

Son birkaç yılda, otomatik konuşma tanıma (ASR) önemli ilerlemeler kaydedilmiştir. Bu ilerlemeler, birçok gerçek dünya senaryosunda benimsenme eşiğini aşan ve Google Now, Microsoft Cortana ve Amazon Alexa gibi hizmetleri etkinleştiren ASR sistemlerine yol açmıştır. Bu başarıların çoğu, derin öğrenme (DL) teknikleriyle desteklenmektedir [26].

Akustik veriler, ses dalgalarından elde edilen dijital verilerdir. Bu veriler genellikle mikrofonlar, sensörler veya başka cihazlarla toplanarak, sayısal formata dönüştürülmektedir. Akustik veriler, sesin frekansları, genlikleri, zaman içindeki değişimleri gibi özellikleri içermekte ve bu veriler, çeşitli sesli olayların (konuşma, müzik, çevresel sesler, vb.) analiz edilmesinde kullanılmaktadır.

Örnek olarak:

- Konuşma verisi: İnsan sesinin dijitalleştirilmiş hali (sesli komutlar, konuşmalar).
- Müzik verisi: Müzik aletlerinin, vokallerin ve diğer müzik öğelerinin dijital ses kaydı.
- Çevresel sesler: Doğal ortam sesleri (örneğin, kuş sesleri, rüzgâr, su sesi).

- Sanayi ve güvenlik sesleri: Makine arızaları, alarm sesleri, araç sesleri gibi.

Akustik verilerin analizi, sadece sesin kaydedilmesiyle sınırlı değildir. Bu veriler, genellikle anlamlı bilgiler çıkarmak, sınıflandırmak, tespit etmek ve tahminlerde bulunmak için kullanılmaktadır. Ancak, akustik veriler karmaşık, gürültülü ve yüksek boyutlu olabilir bu da geleneksel analiz yöntemlerini zorlaştırmaktadır. Akıllı hesaplama yöntemleri, bu tür verilerin işlenmesini daha verimli ve doğru hale getirebilmektedir.

3.1. Akustik Verilerin Akıllı Hesaplama Yöntemleriyle Analizinin Kullanım Alanları

Akustik verilerin akıllı hesaplama yöntemleriyle analizi, birçok farklı alanda uygulanabilir:

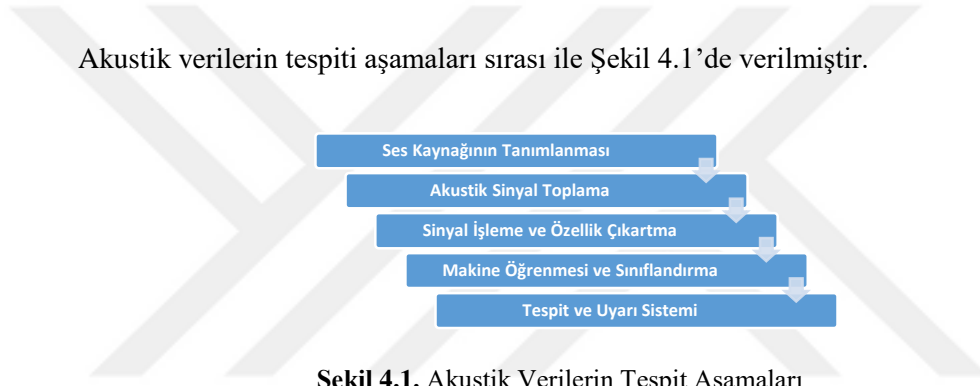
- Sesli Komut Tanıma: Kullanıcıların sesli komutları ile cihazlarla etkileşimde bulunmalarını sağlamaktadır. Akıllı telefonlar, akıllı ev cihazları ve dijital asistanlar bu tür teknolojilerle çalışır [27].
- Konuşma Tanıma ve Dil İşleme: İnsan konuşmasının yazıya dökülmesi (otomatik konuşma tanıma - ASR), sesli metin oluşturma ve dil anlama alanlarında kullanılmaktadır. Bu, çağrı merkezlerinde, sesli yanıt sistemlerinde, otomatik çeviri sistemlerinde yaygın olarak kullanılmaktadır [28].
- Görüntü ve Ses Tabanlı Anomali Tespiti: Özellikle endüstriyel ve güvenlik uygulamalarında, makine arızalarını veya olağandışı sesleri tespit etmek için kullanılmaktadır. Örneğin, bir makine tarafından çıkarılan belirli bir sesin analizi, arıza olasılığını ortaya çıkarabilir.
- Sağlık Uygulamaları: Akustik veriler sağlık alanında, özellikle sesli solunum takibi veya hırıltılı seslerin tespiti gibi alanlarda kullanılabilir. Akustik sinyaller, bazı hastalıkların erken teşhisi için yardımcı olabilir.
- Müzik ve Ses Analizi: Müzik parçalarının sınıflandırılması, müzik türlerini tanıma, sesli performans analizi gibi sanat ve kültür alanlarında da akustik veri analizi kullanılmaktadır.
- Çevresel Akustik İzleme: Çevresel seslerin (örneğin, kuş cıvıltıları, rüzgar, su akışı) analiz edilmesi, ekolojik araştırmalar, doğal afetlerin (deprem, fırtına) tespiti gibi alanlarda da kullanılmaktadır [29].
- Sesli Duygu Analizi: Konuşmanın içindeki duyguları (öfke, mutluluk, üzüntü vb.) analiz etme, özellikle müşteri hizmetleri ve psikolojik sağlık uygulamalarında faydalar sağlamaktadır.

4. AKUSTİK VERİLERLE DRONE VE HELİKOPTER TESPİTİ

Akustik Verilerle Drone ve Helikopter Tespiti, çevresel akustik sinyallerin (ses dalgaları) kullanılarak, drone ve helikopter gibi hava araçlarının varlığının tespit edilmesi işlemidir. Bu tür bir tespit, özellikle güvenlik, izleme ve askeri uygulamalar için önemli olmaktadır. Bu teknoloji, geleneksel radar ve görsel algılama sistemlerinin aksine, hava araçlarının seslerini analiz ederek varlıklarını belirlemeye çalışmaktadır. Akustik sinyal işleme ve yapay zekâ (özellikle makine öğrenmesi ve derin öğrenme teknikleri) kullanılarak, bu araçların sesleri doğru bir şekilde tanımlanabilmekte ve izlenebilmektedir.

4.1. Akustik Verilerle Drone ve Helikopter Tespiti Çalışması

Akustik verilerin tespiti aşamaları sırası ile Şekil 4.1’de verilmiştir.



Şekil 4.1. Akustik Verilerin Tespit Aşamaları

4.1.1. Ses Kaynağının Tanımlanması

- Hem dronlar hem de helikopterler, uçarken belirgin bir akustik iz bırakmaktadırlar. Bu sesler, pervane dönerken, motor çalışırken ve hava aracının aerodinamik yapısından kaynaklanan seslerden oluşmaktadır.
- Helikopterler, genellikle daha büyük ve daha güçlü motorlara sahip oldukları için daha yüksek frekansta ve daha karmaşık bir akustik iz bırakmaktadır. Ayrıca, pervanelerinin dönüş hızı ve rotor uçuşu nedeniyle belirgin gürültü üretmektedir.
- Dronlar ise daha küçük, genellikle elektrikli motorlarla çalışan araçlardır ve bu nedenle daha düşük frekansta ve daha az karmaşık sesler üretirler. Ancak hızları arttıkça, gürültü düzeyleri de artabilmektedir.

4.1.2. Akustik Sinyal Toplama

- Drone veya helikopterin çıkardığı sesler mikrofonlar veya ses algılama sensörleri ile toplanmaktadır. Bu sensörler, çeşitli frekanslarda ses dalgalarını kayıt altına almaktadırlar.
- Mikrofonlar genellikle, ses kaydını 360 derece kapsayacak şekilde yerleştirilmekte, bu sayede her açıdan gelen sesler yakalanabilmektedir.

4.1.3. Sinyal İşleme ve Özellik Çıkartma

- Toplanan akustik veriler, sinyal işleme teknikleri ile işlenmektedir. Bu işlemde, genellikle sesin frekans, genlik, zaman ve spektrogram gibi özellikleri analiz edilmektedir.
- Özellikle Mel Frekans Cepstral Katsayıları (MFCC), Fourier dönüşümü ve spektrogramlar gibi teknikler kullanılarak sesin zaman içindeki özellikleri çıkarılmaktadır. Bu sayede, dronların ve helikopterlerin farklı uçuş hızlarına ve yüksekliklerine göre karakteristik ses desenleri elde edilebilmektedir [30].

4.1.4. Makine Öğrenmesi ve Sınıflandırma

- Özellikler çıkarıldıktan sonra, bu veriler makine öğrenmesi modelleri ile analiz edilmektedir. Burada kullanılan en yaygın yöntemler arasında:
 - ✓ Destek Vektör Makineleri (SVM),
 - ✓ Karar Ağaçları,
 - ✓ K-En Yakın Komşu (KNN) gibi klasik makine öğrenmesi algoritmalarının yanı sıra,
 - ✓ Derin Öğrenme Modelleri (özellikle Konvolüsyonel Sinir Ağları - CNN ve Tekrarlayan Sinir Ağları - RNN gibi) yer alır.
- Model, toplanan akustik verileri işleyerek bir sınıflandırma yapmakta ve hava aracının bir drone mı yoksa helikopter mi olduğu belirlenmektedir. Her bir araç tipi, kendine özgü akustik izler bıraktığı için bu tür bir sınıflandırmaların yapılması mümkün olmaktadır.

4.1.5. Tespit ve Uyarı Sistemi

- Akustik analiz yapıldıktan sonra, bir drone veya helikopterin tespiti gerçekleştirilmektedir ve bu bilgi ilgili sistemlere iletilmektedir. Bu sistemler, güvenlik merkezleri, askeri birimler veya diğer otoriteler tarafından takip edilebilmektedir [31].
- Ayrıca, bu tür akustik tespit, geleneksel radar ve optik izleme sistemleriyle birleştirilebilir, böylece daha kapsamlı bir izleme ve güvenlik çözümü sağlanabilmektedir.

4.2. Akustik Veri ile Drone ve Helikopter Tespitinin Avantajları

4.2.1. Görsel ve Radar Sistemlerine Bağımlılığı Azaltma:

- Akustik veri, görsel veya radar sistemlerinin sınırlı olduğu koşullarda önemli bir avantaj sağlamaktadır. Örneğin, yoğun hava koşullarında (yağmur, kar, sis) görsel izleme zorlaşırken, akustik sinyaller hala etkin bir şekilde algılanabilmektedir.

4.2.2. Farklı Frekanslar ve Ses Tipleri:

- Drone ve helikopterlerin ses profilleri birbirinden farklıdır, bu nedenle akustik yöntemle her birini tanımlamak mümkündür. Helikopterlerin sesi genellikle daha gürültülü ve karmaşıkken, dronlar daha ince ve sabit frekansta sesler üretmektedir.

4.2.3. Daha Erken Tespit:

- Akustik sensörler, radar gibi sistemlerden daha erken tespit yapabilmektedir. Özellikle düşük irtifadaki drone'lar, radar sistemleri tarafından yeterince iyi algılanamayabilirken, akustik sensörler bu tür tehditleri daha erken fark edebilmektedir.

4.2.4. Daha Düşük Maliyetli Çözümler:

- Akustik sensörler, radar sistemlerine kıyasla daha ucuz ve daha az karmaşık olabilmektedir. Ayrıca, daha küçük alanlarda kurulabilecek sensör ağları ile geniş alanlarda izleme yapılabilmektedir.

4.3. Zorluklar ve Sınırlamalar

4.3.1. Gürültü ve Karışıklık:

- Çevresel gürültü, akustik tespiti zorlaştırabilmektedir. Özellikle şehir içindeki trafik gürültüsü, rüzgar, inşaat faaliyetleri gibi sesler, drone veya helikopterlerin seslerini gizleyebilmektedir. Bu nedenle, doğru verilerin elde edilebilmesi için gürültü engelleme teknikleri önemli olmaktadır.

4.3.2. Hedeflerin Yüksek Hızda Uçması:

- Dronlar ve helikopterler hızla hareket ettiklerinde, ses dalgalarının frekansları değişmektedir. Bu da tespit ve sınıflandırma doğruluğunu etkileyebilmektedir. Bu gibi durumlarda Doppler etkisi (sesin hareketle değişen frekansı) dikkate alınarak doğru analiz yapılmalıdır.

4.3.3. Çoklu Hedeflerin Tespiti:

- Aynı anda birden fazla drone veya helikopterin havada olması, seslerin çakışmasına ve karışmasına yol açabilmektedir. Bu durumda, farklı frekanslar ve zaman dilimlerinden gelen veriler arasındaki ayrım yapılması gerekmektedir.

5. MATERYAL VE METOT

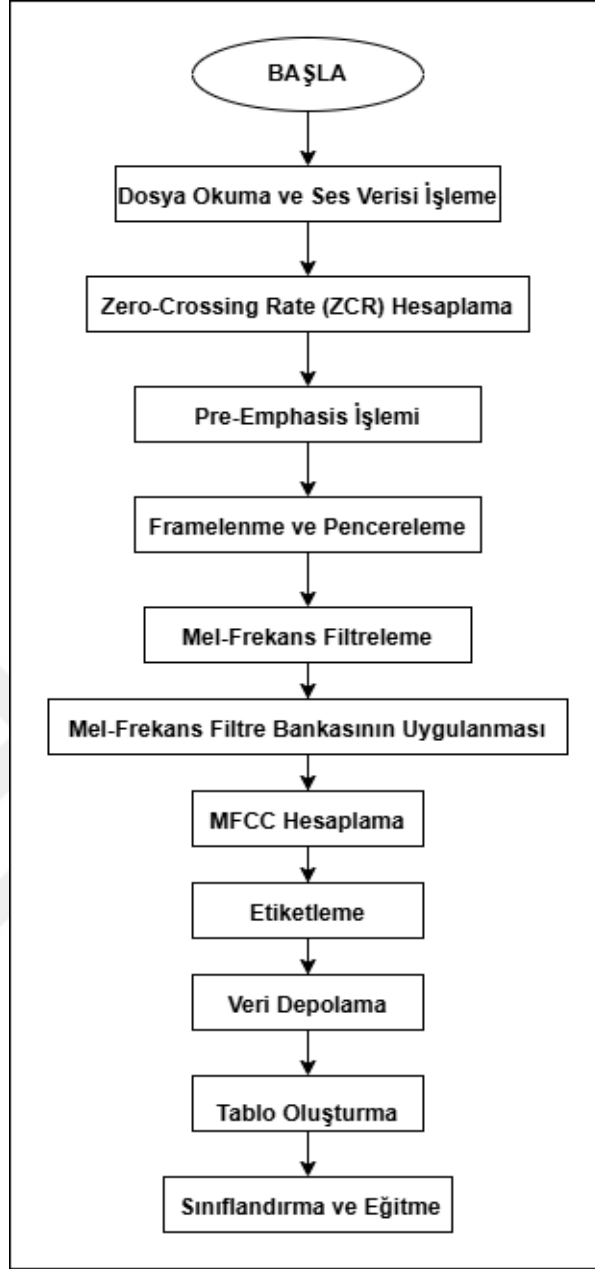
Tez çalışmasının temel amacı, drone ve helikopterlerin yaydığı seslerin karşılaştırılması, bu araçların akustik imzalarının ortaya konulması ve her iki türün karakteristik akustik davranışlarının sınıflandırılmasıdır. Bu bölümde tez çalışmada izlenecek yol ve yöntemlere yer verilmiştir.

Bu çalışmada toplam 546 ses dosyasından elde edilen verilerle, üç farklı ses kaynağının ayrımını yapabilen bir sınıflandırma modeli eğitilmiştir. Veri seti [32], Dropbox sitesinden alınmış olup, 60 ses dosyası helikopter ile drone sesini, 213 ses dosyası sadece drone sesini ve 273 ses dosyası çevre gürültüsünü temsil etmektedir. Bu dosyalar, farklı ortam koşullarında ve çeşitli uçuş manevralarında kaydedilmiştir. Tablo 5.1’de veri setinde bulunan ses dosyalarının sınıflarına dağılımı verilmiştir.

Tablo 5.1. Veri setinde kullanılan etiketler ve veri sayıları

Sınıf	Ses Dosyası Sayısı
Drone ile Helikopter Sesi	60
Drone Sesi	213
Çevre Sesi	273

Ses dosyaları, zaman frekans analizi, spektral özellikler ve diğer akustik parametreler kullanılarak işlenmiştir. Özellikle, ses dalgalarının frekans içeriği ve genlik analizleri, her bir ses kaynağının karakteristik özelliklerini belirlemek için kullanılmıştır. Akustik veri analizinde, geleneksel ses tanıma ve sınıflandırma yöntemleri uygulanmıştır. Bu yöntemler, özellik çıkarımı, boyut indirgeme ve sınıflandırma algoritmaları gibi adımlardan oluşmaktadır. Veri setine uygulanan işlemler sırası ile Şekil 5.1’de belirtilmiştir.



Şekil 5.1. Ses Dosyalarının İşlenmesine ait akış diyagramı

5.1. Dosya Okuma ve Ses Verisi İşleme

Bu aşamada, ses verisi belirli bir formatta (örneğin, WAV veya MP3) dosya olarak saklanmış olmalıdır. MATLAB’da, ses verilerini işlemek için `audioread()` fonksiyonu kullanılmaktadır. Bu fonksiyon, ses dosyasını okutup iki çıktıya dönüştürmektedir: ses verisi (ses dalgası) ve örnekleme frekansı. Ses verisi, genellikle bir vektör veya matris şeklinde olmaktadır. Örnekleme frekansı ise ses verisinin saniye başına kaç örnek içerdiğini belirtmektedir.

5.2. Sıfır Geçiş Oranı Hesaplama

Sıfır Geçiş Oranı (Zero-Crossing Rate), ses dalgasındaki sıfır noktasından geçişlerin sayısını hesaplamakta ve sesin değişkenliğini göstermektedir. Zero-Crossing Rate (ZCR), özellikle sesin belirli bir frekansta ne kadar "sert" veya "yumuşak" olduğunu anlamada kullanılmaktadır.

ZCR hesaplama, ses verisinin her bir örneği için, ardışık örneklerin işaretinin değişip değişmediğini kontrol etmeyi içermektedir. Denklem 5.1’de bu duruma ait ifade verilmiştir.

$$ZCR = \frac{1}{N-1} \sum_{n=1}^{N-1} (\text{sgn}(x[n]) - \text{sgn}(x[n-1])) \quad (5.1)$$

- $x[n]$: Sinyalin n. örneği.
- $\text{sgn}(x[n])$: $x[n]$ değerinin işareti. Eğer $x[n]$ pozitifse $\text{sgn}(x[n])=1$, negatifse $\text{sgn}(x[n])=-1$, sıfırsa $\text{sgn}(x[n])=0$.
- N : Sinyalin toplam örnek sayısı.
- ZCR, sinyalin ardışık örnekleri arasındaki işaret değişikliklerini saymaktadır.

Formülde, ardışık örnekler arasındaki işaret değişikliği kontrol edilmektedir. Eğer önceki örnek ile şu anki örneğin işareti farklıysa, bir sıfır geçişi olmuş demektir.

5.3. Ön-impuls İşlemi

Ön-impuls işlemi, düşük frekansların işlenmesinde bozulmalara karşı koruma sağlamaktadır. Bu işlem, sesin yüksek frekans bileşenlerinin güçlendirilmesine dayanmakta ve genellikle ses tanıma sistemlerinde uygulanmaktadır. Ön-impuls, ses verisinin her örneği ile bir öncekilerin belirli bir katsayı ile çarpılarak yapılmaktadır. Bu işlem denklem 5.2’de gösterilmiştir.

$$y[n] = x[n] - \alpha \cdot x[n-1] \quad (5.2)$$

- $x[n]$: Orijinal ses sinyalinin n.örneği.
- $y[n]$: Ön-impuls uygulanmış sinyalin n. örneği.
- α : Ön-impuls faktörü (genellikle 0.9 ile 1 arasında bir değere sahiptir). Bu, işlemdeki yüksek frekansları ne kadar artıracığımızı belirler. Yüksek α değeri, daha fazla Ön-impuls etkisi oluşturmaktadır.
- $x[n-1]$: Orijinal ses sinyalinin bir önceki örneği.

Ön-İmpuls işlemi ile;

- Yüksek frekansları artırmak: Ön-impuls, genellikle sinyalin düşük frekanslı bileşenlerini baskılar ve yüksek frekans bileşenlerini güçlendirir. Bu, sesin daha belirgin hale gelmesine ve daha iyi işlenebilmesine yardımcı olur.
- Sinyalin genlik farkı: Formülde, her örneğin değeri ile bir önceki örneğin değeri arasındaki fark alınır ve bu fark belirli bir faktörle (α) çarpılır. Bu işlem, yüksek frekans bileşenlerini daha fazla vurgular.

Ön-İmpuls Uygulamanın Kullanım Alanları:

- Ses Tanıma: İnsan sesi genellikle düşük frekanslarda daha fazla enerji taşır. Ön-impuls, bu düşük frekansları baskılayarak, yüksek frekansları vurgular, böylece sistemin yüksek frekanslardaki bilgileri daha iyi almasını sağlar.
- Telekomünikasyon: Ön-impuls, sesin iletilmesi sırasında kayıpları azaltarak, iletim kalitesini artırabilir.
- Ses Sinyali İşleme: Sesin daha net ve ayrıntılı bir şekilde analiz edilmesi için Ön-impuls kullanılır.

5.4. Framelenme ve Pencereleme

Framelenme, ses verisinin belirli zaman dilimlerine (frame) bölünmesi işlemidir. Bu işlem, genellikle ses tanıma ve analizinde kullanılmaktadır. Çünkü sesin kısa zaman dilimlerinde analiz edilmesi gerekmektedir. Pencereleme, her bir frame'in üzerinde pencere fonksiyonu uygulanarak frekans bileşenlerinin kaymasını engeller.

Framelenme (pencereleme), bir sinyalin belirli bir süre diliminde parçalara ayrılmasıdır. Bu işlem, sinyali daha küçük segmentlere böler ve her segment üzerinde farklı sinyal işleme yöntemleri uygulamaya olanak tanır. Bu işlem, genellikle ses veya zaman serisi verilerini analiz ederken kullanılır.

Framelenme Formülü:

Bir sinyali $x[n]$ bir zaman penceresi içinde framelenmek için, sinyal küçük parçalara bölünür. Eğer bir pencere uzunluğu N ve pencere kaydırma (overlap) miktarı S ile tanımlanmışsa, $x[n]$ sinyalinin her bir dilimi denklem 5.3' te ki gibi ifade edilir:

$$Frame[k] = x[kS : kS + N - 1] \quad (5.3)$$

- $x[n]$: Orijinal sinyalin n . örneği.
- $Frame[k]$: k -inci çerçeve (frame) veya dilim.
- N : Her bir çerçeve için alınacak örnek sayısı (pencere uzunluğu).
- S : Çerçeveler arasındaki kaydırma (overlap) miktarı.

Pencereleme, framelemiş veriler üzerinde daha fazla analiz yapılabilir hale getirmek için kullanılan bir tekniktir. Bu işlem, her bir çerçevenin uçlarındaki keskin geçişleri (discontinuities) yumuşatarak sinyalin daha düzgün bir şekilde analiz edilmesine imkân sağlamaktadır.

Pencereleme Formülü:

Pencereleme işlemi, her bir çerçeveye bir pencere fonksiyonu $w[n]$ uygulamayı içermektedir. Bu pencere fonksiyonu genellikle Hamming, Hann veya Rectangular gibi fonksiyonlar olabilir. Pencereleme formülü denklem 5.4'te verildiği gibidir.

$$y[n] = x[n] \cdot w[n] \quad (5.4)$$

- $x[n]$: Çerçeve (frame) verisi.
- $w[n]$: Pencere fonksiyonu.
- $y[n]$: Pencere uygulandıktan sonra elde edilen yeni çerçeve.

Pencere fonksiyonu $w[n]$, genellikle 0 ile 1 arasında bir değere sahip olan ve çerçeveyi sınırlarında yavaşça sıfıra indirgeyen bir fonksiyondur.

Yaygın olarak kullanılan pencere fonksiyonları:

Rectangular Pencereleme:

Rectangular Pencereleme fonksiyonuna ait matematiksel ifade denklem 5.5'te verilmiştir.

$$w[n] = 1 \quad (\text{tüm } n \text{ için}) \quad (5.5)$$

Basit bir pencereleme fonksiyonudur ve hiçbir değişiklik yapmaz.

Hamming Pencereleme:

Hamming Pencereleme fonksiyonuna ait matematiksel ifade denklem 5.6'da verilmiştir.

$$w[n] = 0.54 - 0.46 \cdot \cos\left(\frac{2\pi n}{N-1}\right) \quad (5.6)$$

Hamming pencere fonksiyonu, çerçeve uçlarındaki keskin geçişleri yumuşatmak için yaygın olarak kullanılan bir pencere türüdür.

Hann Pencereleme:

Hann Pencereleme:fonksiyonuna ait matematiksel ifade denklem 5.7'de verilmiştir.

$$w[n] = 0.5 \cdot (1 - \cos(\frac{2\pi n}{N-1})) \quad (5.7)$$

Hann pencere fonksiyonu da uçlardaki geçişleri yumuşatmak için kullanılan farklı bir pencere türüdür.

Blackman-Harris Pencereleme:

Blackman-Harris Pencereleme fonksiyonuna ait matematiksel ifade denklem 5.8'de verilmiştir.

$$w[n] = 0.35875 - 0.48829\cos(\frac{2\pi n}{N-1}) + 0.14128\cos(\frac{4\pi n}{N-1}) - 0.01168\cos(\frac{6\pi n}{N-1}) \quad (5.8)$$

Daha fazla yumuşama sağlayan ve düşük frekansların daha iyi korunmasına yardımcı olan bir pencere fonksiyonudur.

5.5. Mel-Frekans Filtreleme

Mel-frekans filtreleme, ses verisinin frekans spektrumunun Mel skalasına dönüştürülmesi işlemidir. Mel skalası, insanların duyabileceği frekansları daha iyi temsil etmek için logaritmik bir ölçek kullanmaktadır. Mel frekans filtre bankası, bu dönüşüm için kullanılmaktadır.

Mel Frekans Dönüşümü Formülü:

Bir frekans (f) için Mel frekansı m, denklem 5.9 ile hesaplanır:

$$m = 2595 \cdot \log_{10} (1 + \frac{f}{700}) \quad (5.9)$$

- m: Mel frekansı
- f: Lineer frekans (Hz)
- 700: Sabit bir katsayıdır, insan kulağının frekans algılama özelliklerine dayalı olarak seçilmiştir.

Mel Frekansından Lineer Frekansa Dönüşüm:

Bir Mel frekansını m lineer frekansa dönüştürmek için ters formül kullanılır. Bu durum denklem 5.10'da verilmiştir.

$$f = 700 \cdot (10^{\frac{m}{2595}} - 1) \quad (5.10)$$

- f: Lineer frekans (Hz)
- m: Mel frekansı

Bir Mel-Frekans Filtre Bankası (MFB), Fourier Dönüşümü ile elde edilen spektrumun üzerine uygulanan bir dizi Mel filtresinden oluşmaktadır. Her bir filtre, belirli bir Mel frekans aralığında sinyalin enerjisini hesaplamaktadır. Bu filtreler genellikle üçgen şeklinde olup, Mel ölçeğinde frekansları kapsayacak şekilde düzenlenmektedir.

Bir filtre bankası, genellikle şu adımlarla oluşturulur:

1. **Frekans aralığının Mel frekanslarına dönüştürülmesi:** Sinyalin analiz edilen frekansları, Mel frekans ölçeğine dönüştürülür.
2. **Üçgen filtrelerin yerleştirilmesi:** Mel frekanslarına karşılık gelen filtreler, her birinin üst kısmı belirli bir Mel frekansında ve alt kısmı da bir üst Mel frekansında olacak şekilde yerleştirilir.
3. **Sinyalin her bir filtre ile çarpılması ve enerji hesaplaması:** Sinyal, her bir Mel filtresiyle çarpılır ve her filtreden elde edilen enerji hesaplanır.

5.6. Mel-Frekans Filtre Bankasının Uygulanması

Bir Mel-frekans filtre bankası, her frame'in spektrumuna uygulanarak Mel frekans katsayılarını hesaplamaktadır. Bu işlem, ses verisinin temel özelliklerini çıkarmaya yardımcı olmaktadır. Bu işlemde, Fourier dönüşümü ile her bir frame'in spektrumu hesaplanır ve ardından Mel filtre bankası ile çarpılır.

Bir filtre bankası, genellikle denklem 5.11'de ki gibi ifade edilir:

$$E_k = \sum_{i=1}^N (X(i) \cdot H_k(i)) \quad (5.11)$$

- E_k : k. Mel frekansı filtresi için hesaplanan enerji.
- $X(i)$: Fourier Dönüşümünden elde edilen sinyalin i. frekans bileşeni.
- $H_k(i)$: k. filtre için i. frekans bileşeninin filtresi.
- N: Toplam frekans sayısı.

Mel-Frekans Filtre Bankasının Temel Özellikleri:

- Filtreler genellikle üçgen şeklinde olur ve her biri belirli bir Mel frekans bandında sinyalin enerjisini hesaplar.
- Bu filtreler düşük frekanslarda daha geniş, yüksek frekanslarda ise daha dar olabilir.
- Mel frekansı ile lineer frekans arasındaki ilişki, insan kulağının sesleri nasıl algıladığına dayalıdır.

5.7. MFCC Hesaplama

Mel-Frekans Cepstral Katsayıları (MFCC), Mel frekans filtreleri ile işlenmiş ses verisinin daha düşük boyutlu bir temsilini oluşturmaktadır. Bu sesin temel özelliklerini ortaya çıkarır ve konuşma tanıma gibi uygulamalarda yaygın olarak kullanılır. Mel spektrumunun logaritmasını alıp üzerine Discrete Cosine Transform (DCT) uygulanarak elde edilir. Bu sesin karakteristik özelliklerini daha anlamlı bir biçimde ortaya çıkmasını sağlar. Genellikle ilk 13 katsayı (MFCC1'den MFCC13'e kadar) kullanılmaktadır. Denklem 5.12'de logaritmik enerji hesaplamada kullanılan ifadeyi vermektedir.

$$L_k = \log(E_k) \quad (5.12)$$

- L_k : Logaritmik enerji.
- E_k : Mel frekansı filtresindeki enerji.

Discrete Cosine Transform (DCT), Mel-frekanslı logaritmik enerjileri cepstral katsayılar haline getirmek için kullanılır. Bu durum, Mel frekansları üzerinde yoğunlaşan bilgiyi daha anlamlı ve kompakt bir biçime dönüştürür.

DCT, genellikle denklem 5.13 yardımıyla hesaplanır:

$$C_m = \sum_{k=1}^K L_k \cdot \cos\left(\frac{\pi}{K}\left(m + \frac{1}{2}\right)k\right) \quad (5.13)$$

- C_m : m. cepstral katsayısı (MFCC).
- L_k : Mel-frekanslı logaritmik enerji.
- K: Toplam Mel filtre sayısı.
- m: Cepstral katsayısı sırası (genellikle 1'den başlar).

5.8. Etiketleme

Etiketleme, verilerin doğru sınıflandırılmasını sağlamak amacıyla, her ses verisine uygun etiketlerin atanması işlemidir. Bu işlem genellikle sesli komut tanıma, ses sınıflandırma gibi görevlerde kullanılmaktadır. Her ses örneği için, sesin hangi sınıfa ait olduğunu belirten etiketler atanarak işlem gerçekleştirilir.

5.9. Veri Depolama

Elde edilen özellikler ve etiketler daha sonra dosya olarak depolanabilir. Dosyaların depolanması işlemi tez çalışmamızda “.mat” formatında yapılmıştır.

5.10. Tablo Oluşturma

Elde edilen veriler ve etiketler bir araya getirilip bir tablo oluşturulur. Bu tablo, verilerin analiz edilmesi için kullanılmaktadır.

Bu tez çalışması için yapılan kodlama ile bir ses dosyasından özellik çıkarımı (MFCC, ZCR) yaparak bu verileri bir etiketle birlikte toplamaktadır. Ardından, bu veriler bir tabloya yerleştirilir. Bu genellikle ses tanıma veya sınıflandırma problemlerinde, model eğitimi için kullanılan bir ön işleme adıdır.

Her bir dosya için MFCC ve ZCR hesaplanıp, etiketlerle birlikte birleştirilerek sınıflandırma algoritmalarına sunulmak üzere hazır hale getirilir.

5.11. Sınıflandırma ve Eğitime

MATLAB programında Classification Learner uygulaması kullanılarak, MFCC (Mel-Frekans Cepstral Katsayıları) ve ZCR (Zero-Crossing Rate) değerlerinden oluşan eğitim verileriyle sınıflandırma yapılmıştır. Bu işlem sonucunda, test ve kıyaslama yapılabilecek şekilde düzenlenmiş bir eğitim veri dosyası oluşturulmuştur.

5.12. İstatiksel Model Analizi

Kesinlik, duyarlılık ve F-Skor (F1-Skor), genellikle sınıflandırma problemlerinde kullanılan performans ölçütleridir. Bu terimler, modelin doğru sonuçlar üretme yeteneğini değerlendirmek için kullanılır.

Kesinlik:

- Modelin pozitif olarak sınıflandırdığı öğeler arasından gerçekten pozitif olanların oranıdır.
- Yüksek kesinlik, modelin yanlış pozitif hatalarını düşük tuttuğunu gösterir.

Kesinlik işlemi denklem 5.14’de verildiği gibi hesaplanmaktadır.

$$Kesinlik = \frac{True\ Positives}{True\ Positives+False\ Positives} \quad (5.14)$$

Duyarlılık:

- Modelin gerçek pozitif öğelerini ne kadar doğru tespit ettiğini gösterir. Yani, modelin pozitif sınıfı ne kadar doğru bulduğunun ölçüsüdür.
- Yüksek duyarlılık, modelin yanlış negatiflerini (yani pozitif sınıfları atlama) az tuttuğunu gösterir.

Duyarlılık işlemi denklem 5.15’de verildiği gibi hesaplanmaktadır.

$$Duyarlılık = \frac{True\ Positives}{True\ Positives+False\ Negatives} \quad (5.15)$$

F-Skor (F1-Skor):

- Kesinlik ve duyarlılık arasında bir denge sağlamayı amaçlayan bir ölçüttür. Özellikle dengesiz veri setlerinde, sadece kesinlik veya duyarlılığa bakmak yanıltıcı olabilir. F1-Skor, her iki ölçütü birleştirerek genel performansı değerlendirir.
- F1-Skor, kesinlik ve duyarlılığın harmonik ortalamasıdır ve her iki metriğin de yüksek olmasını isteyen durumlarda kullanılır.

F1-Skor denklem 5.15 yardımıyla hesaplanmaktadır.

$$F1 - skor = 2 * \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik} \quad (5.15)$$

Bu üç metrik, modelin doğru sınıflandırma yapma becerisini daha iyi anlamamızı sağlar.


6. BULGULAR VE TARTIŞMA

Veri setindeki akustik seslerin eğitimi, çok modellenli sayısal hesaplama araç ve yazılımı olan MATLAB programında gerçekleştirilmiştir. Bu bölümde, eğitilen sesler dışında alınan seslerle de test yapılarak sonuçları incelenmiştir. Eğitilen Akustik verilerin model tipine göre doğruluk oranları Tablo 6.1’de verilmiştir.


Tablo 6.1. Eğitilen veri setinin doğruluk sonuçları

Model Number	Model Type	Preset	Doğruluk % (Validation)	Total Cost (Validation)
2.1	Tree	Fine Tree	95,4	25
2.2	Tree	Medium Tree	95,4	25
2.3	Tree	Coarse Tree	96,1	21
2.4	Discriminant	Linear Discriminant	97,0	16
2.5	Discriminant	Quadratic Discriminant	97,9	11
2.6	Efficient Logistic Regression	Efficient Logistic Regression	39,0	333
2.7	Efficient Linear SVM	Efficient Linear SVM	92,8	39
2.8	Naive Bayes	Gaussian Naive Bayes	97,2	15
2.9	Naive Bayes	Kernel Naive Bayes	96,8	17
2.10	SVM	Linear SVM	97,9	11
2.11	SVM	Kuadratik Destek Vektör Makinesi	98,1	10
2.12	SVM	Cubic SVM	97,8	12
2.13	SVM	Fine Gaussian SVM	55,3	244
2.14	SVM	Medium Gaussian SVM	97,4	14
2.15	SVM	Coarse Gaussian SVM	96,1	21
2.16	KNN	Fine KNN	95,0	27
2.17	KNN	Medium KNN	95,0	27
2.18	KNN	Coarse KNN	88,6	62
2.19	KNN	Cosine KNN	94,5	30
2.20	KNN	Cubic KNN	94,8	28
2.21	KNN	Weighted KNN	95,7	23
2.22	Ensemble	Boosted Trees	50,0	273
2.23	Ensemble	Bagged Trees	96,3	20
2.24	Ensemble	Subspace Discriminant	96,5	19
2.25	Ensemble	Subspace KNN	85,1	81
2.26	Ensemble	RUSBoosted Trees	96,7	18
2.27	Neural Network	Dar Yapay Sinir Ağı	98,1	10
2.28	Neural Network	Medium Neural Network	97,6	13
2.29	Neural Network	Geniş Yapay Sinir Ağı	98,1	10
2.30	Neural Network	Bilayered Neural Network	97,2	15
2.31	Neural Network	Trilayered Neural Network	97,6	13
2.32	Kernel	SVM Kernel	86,4	74
2.33	Kernel	Logistic Regression Kernel	87,9	66


Karar ağaçları algoritmaları kullanılarak oluşturulan dağılım grafikleri Şekil 6.1 ve Şekil 6.2’de örnek olarak verilmiş. Karar ağaçları algoritmaları kullanılarak oluşturulan Doğrulama karışıklık matrislerinden modelimizin ilki “Fine Tree” Şekil 6.3’te verilmiştir.



Şekil 6.1. MFCC1 ile MFCC2 dağılım grafiği




Şekil 6.2. MFCC1 ile ZCR dağılım grafiği




Şekil 6.3 Doğrulama Karışıklık Matrisi


Çalışmamızda, akustik verilerin eğitilmesiyle ortaya çıkan eğitim seti ile diğer ses verilerinin karşılaştırılması sonucu hata oranı düşük çıkmıştır.



Şekil 6.4. Model 2.11 MFCC1'in MFCC2 ile ZCR' ye göre dağılım grafiği



Şekil 6.5. Model 2.27 MFCC1'in MFCC2 ile ZCR' ye göre dağılım grafiği



Şekil 6.6. Model 2.29 MFCC1'in MFCC2 ile ZCR' ye göre dağılım grafiği

		Model 2.11		
		cevre sesi	drone	helikopter ile drone
True Class	cevre sesi	273		
	drone		211	2
	helikopter ile drone	1	7	52
		Predicted Class		

Şekil 6.7. Model 2.11 Doğrulama Karışıklık Matrisi

		Model 2.27		
		cevre sesi	drone	helikopter ile drone
True Class	cevre sesi	270	2	1
	drone		210	3
	helikopter ile drone	1	3	56
		Predicted Class		

Şekil 6.8. Model 2.27 Doğrulama Karışıklık Matrisi

		Model 2.29		
		cevre sesi	drone	helikopter ile drone
True Class	cevre sesi	270	1	2
	drone		209	4
	helikopter ile drone		3	57
		Predicted Class		
		cevre sesi	drone	helikopter ile drone

Şekil 6.9. Model 2.29 Doğrulama Karışıklık Matrisi

Tablo 6.1’ de eğitilen veri seslerinin doğruluk sonuçları değerlendirildiğinde en yüksek doğruluk oranını veren 3 model baz alınarak istatistiksel model analizleri hesaplanmıştır(Kuadratik Destek Vektör Makinesi, Dar Yapay Sinir Ağı, Geniş Yapay Sinir Ağı).

Şekil 6.4’te Kuadratik Destek Vektör Makinesi, Şekil 6.5’te Dar Yapay Sinir Ağı ve Şekil 6.6’da Geniş Yapay Sinir Ağı modellerinin MFCC1’in MFCC2 ile ZCR’ ye göre dağılım grafiği verilmiştir.

- Kuadratik Destek Vektör Makinesi modelinin Şekil 6.7’de verilen doğrulama karışıklık matrisini baz alarak yapılan hesaplamalarda;

Tablo 6.2. Kuadratik Destek Vektör Makinesi İstatistiksel Model Analizi

Sınıf	Kesinlik	Duyarlılık	F1-Skor
Çevre sesi	0.997	1.000	0.998
Drone	0.967	0.991	0.979
Helikopter ile Drone	0.981	0.881	0.928

- Dar Yapay Sinir Ağı modelinin Şekil 6.8’de verilen doğrulama karışıklık matrisini baz alarak yapılan hesaplamalarda;

Tablo 6.3. Dar Yapay Sinir Ağı İstatistiksel Model Analizi

Sınıf	Kesinlik	Duyarlılık	F1-Skor
Çevre sesi	0.996	0.989	0.993
Drone	0.985	0.991	0.988
Helikopter ile Drone	0.966	0.949	0.957

- Geniş Yapay Sinir Ağı modelinin Şekil 6.9’da verilen doğrulama karışıklık matrisini baz alarak yapılan hesaplamalarda;

Tablo 6.4. Geniş Yapay Sinir Ağı İstatistiksel Model Analizi

Sınıf	Kesinlik	Duyarlılık	F1-Skor
Çevre sesi	1.000	0.988	0.994
Drone	0.985	0.980	0.982
Helikopter ile Drone	0.983	0.950	0.966

Tablolar 6.2, 6.3 ve 6.4, farklı model analizlerine ait Kesinlik, Duyarlılık ve F1-Skor değerlerini sunmaktadır. Her bir tablo, Çevre Sesi, Drone ve Helikopter ile Drone sınıfları için her modelin performansını ortaya koymaktadır.

Tablo 6.2'deki Kuadratik Destek Vektör Makinesi İstatistiksel Modeli incelendiğinde;

- Çevre Sesi sınıfı, Kesinlik (0.997) ve Duyarlılık (1.000) açısından en yüksek performansı göstermektedir. Bu modelin bu sınıfı doğru tahmin etmede çok başarılı olduğunu ve sınıfın tam olarak tanımlandığını ifade etmektedir. F1-Skor değeri ise 0.998 ile oldukça iyi bir dengeyi sunmaktadır.
- Drone sınıfı, yüksek Duyarlılık (0.991) ve biraz daha düşük Kesinlik (0.967) değeri ile dikkat çekmektedir. Bu durum, modelin Drone sınıfına ait örnekleri doğru tahmin etme konusunda etkili olduğunu, ancak zaman zaman yanlış pozitif tahminler yapabildiğini göstermektedir. F1-Skor değeri ise 0.979 ile oldukça yüksek bir performans sergilemektedir.
- Helikopter ile Drone sınıfı, en düşük Duyarlılık (0.881) değerine sahiptir. Bu, modelin bu sınıfı tahmin etmede zorluk yaşadığını, ancak Kesinlik (0.981) ve F1-Skor (0.928) değerlerinin hâlâ tatmin edici olduğunu göstermektedir.

Tablo 6.3'deki Dar Yapay Sinir Ağı İstatistiksel Modeli incelendiğinde;

- Çevre Sesi sınıfı için, Kesinlik (0.996) ve Duyarlılık (0.989) değerleri birbirine oldukça yakın olup, modelin bu sınıfı yüksek doğrulukla tahmin ettiğini ortaya koymaktadır. F1-Skor değeri 0.993 ile iyi bir denge sunmaktadır.
- Drone sınıfı, Kesinlik (0.985) ve Duyarlılık (0.991) ile oldukça dengeli bir performans sergilemektedir. F1-Skor değeri ise 0.988 olup, modelin bu sınıfı tahmin etme başarısının çok yüksek olduğunu göstermektedir.
- Helikopter ile Drone sınıfı, Kesinlik (0.966) ve Duyarlılık (0.949) değerleriyle iyi bir performans sergilemektedir. F1-Skor değeri ise 0.957 olup, modelin bu sınıfı tahmin etmede başarılı olduğunu, ancak Duyarlılık değerinin bir miktar daha düşük olduğunu ifade etmektedir.

Tablo 6.4'deki Geniş Yapay Sinir Ağı İstatistiksel Modeli İncelendiğinde;

- Çevre Sesi sınıfı için model, Kesinlik (1.000) ile mükemmel bir başarı sergileyerek tüm pozitif tahminlerini doğru yapmaktadır. Duyarlılık (0.988) değeri oldukça yüksek olup, F1-Skor değeri 0.994 ile mükemmel bir denge sağlamaktadır.

- Drone sınıfı, Kesinlik (0.985) ve Duyarlılık (0.980) ile oldukça dengeli bir şekilde tahmin edilmektedir. F1-Skor değeri ise 0.982 olup, modelin Drone sınıfını çok iyi tahmin ettiğini göstermektedir.
- Helikopter ile Drone sınıfı, Kesinlik (0.983) ve Duyarlılık (0.950) değerleriyle güçlü bir performans göstermektedir. F1-Skor değeri ise 0.966 olup, modelin bu sınıfı tahmin etmede başarılı olduğunu ifade etmektedir.

Genel Değerlendirme:

- Geniş Yapay Sinir Ağı modeli, Çevre Sesi sınıfında mükemmel bir Kesinlik (1.000) ve yüksek Duyarlılık (0.988) değeri ile öne çıkmaktadır. Ayrıca, Drone ve Helikopter ile Drone sınıflarında da dengeli sonuçlar elde edilmiştir.
- Dar Yapay Sinir Ağı modeli, Drone ve Helikopter ile Drone sınıflarında oldukça iyi sonuçlar elde etmiştir. Özellikle Drone sınıfında Duyarlılık (0.991) değeri ile yüksek doğruluk oranları göstermektedir. Bununla birlikte, Helikopter ile Drone sınıfındaki Duyarlılık değeri (0.949) biraz daha düşük olup, Kesinlik ve F1-Skor değerleri ise tatmin edici seviyelerdedir.
- Kuadratik Destek Vektör Makinesi modeli, özellikle Çevre Sesi sınıfında yüksek Kesinlik (0.997) ve Duyarlılık (1.000) değerlerine sahip olmakla birlikte, Drone sınıfında Kesinlik (0.967) ve Duyarlılık (0.991) değerlerinde bir miktar düşüş görülmektedir. Helikopter ile Drone sınıfındaki düşük Duyarlılık (0.881) değeri, modelin bu sınıfı doğru tahmin etmede zorluk yaşadığını ortaya koymaktadır.

Sonuç:

- Geniş Yapay Sinir Ağı modeli, genel olarak tüm sınıflarda oldukça yüksek Kesinlik ve Duyarlılık değerleriyle en dengeli performansı sergileyen model olarak öne çıkmaktadır. Özellikle Çevre Sesi sınıfında elde edilen Kesinlik (1.000) değeri, modelin bu sınıfı doğru şekilde tanımasında mükemmel olduğunu göstermektedir.
- Kuadratik Destek Vektör Makinesi modeli, Çevre Sesi sınıfı için mükemmel bir performans sergileyerek dikkat çekerken, Helikopter ile Drone sınıfındaki düşük Duyarlılık değeri, modelin bu sınıfı doğru şekilde tanıma konusunda zorluk yaşadığını ortaya koymaktadır. Ancak Drone sınıfında yine iyi sonuçlar alınmaktadır.
- Dar Yapay Sinir Ağı modeli, Drone ve Helikopter ile Drone sınıflarında güçlü bir performans sergileyip, yüksek F1-Skor değerleri ile bu sınıfların doğru tahmin edilmesinde etkili olmuştur. Ancak Helikopter ile Drone sınıfındaki Duyarlılık değeri hala iyileştirilebilir.

Genel Öneriler:

- Geniş Yapay Sinir Ağı modelinin, Çevre Sesi ve Drone sınıflarında sergilediği yüksek Kesinlik ve Duyarlılık değerleri ile Helikopter ile Drone sınıfında da oldukça iyi sonuçlar elde etmesi, tüm sınıflarda yüksek performans sergileyen bir model olarak potansiyel taşımaktadır.
- Kuadratik Destek Vektör Makinesi modelinin, Helikopter ile Drone sınıfındaki düşük Duyarlılık değeri dikkate alındığında, bu sınıf için parametre optimizasyonu ve modelin iyileştirilmesi gerekmektedir.
- Dar Yapay Sinir Ağı modelinin daha fazla optimizasyon gerektirdiği, özellikle Helikopter ile Drone sınıfındaki Duyarlılık değerinin artırılması gerektiği vurgulanmaktadır.



7. SONUÇLAR

Yapılan tez çalışmasında, akustik verilerin denetimli öğrenme modeli ile eğitilerek tahmin edilmesinde kullanılmak üzere bir uygulama geliştirilmiştir. Bu çalışmada gerçek zamanlı veriler üzerinde kullanılabilirlik amacıyla özgün test ve eğitim verileri kullanılmıştır. Sürekli yapılan sentezde verilerin hızlı tespiti bizim amacımızla daha uyumlu olduğu ortaya konulmuştur. MATLAB programı ile eğitilen ağların benzer verilere dayalı test başarımları yüksek çıkmıştır. Bu yüksek oran test verilerinde de gözlemlenmiştir. Bazı karar ağaçları algoritmalarında bunun tersi gözlemlenmesi ilgili karar ağaçlarının akustik veri gibi karmaşık verilerin tespitini ve/veya analizini yapacak düzeyde gelişmiş olmamasından kaynaklanmaktadır. Akustik verilerin analizinde kullanılan eğitim setinin yüksek doğruluk oranı olması ve test edilen seslerin analizindeki yüksek doğruluk tespiti modelimizin istenilen amaca göre kullanılabilir olduğunu göstermektedir.

ÖNERİLER

Yapılan tez çalışmasında kullanılan analiz işlemi daha büyük bir veri seti ile eğiterek uygulama başarımı artırılabilir. Ayrıca, farklı öznelikleri de barındıran genişletilmiş bir veri setinde; uçak ve füze gibi saldırı araçlarının da sınıflandırma olarak kullanılabilmesi, korunacak alanda kullanılacak karşı silah sistemini devreye alarak verimli silah kullanılmasına olumlu etki yaratacaktır.



KAYNAKLAR

- [1] D. A. Yardımcı, Yapay Zeka, Ankara: OSBÜK, 2024.
- [2] Makine Öğrenmesi Algoritmaları, [Çevrimiçi]. Available: <https://ckk.com.tr/ders/ML.html>. (Accessed 05 March 2024).
- [3] Jang, H., & Topal, E. A review of soft computing technology applications in several mining problems. *Applied Soft Computing*. 22 (2014) 638–651. <https://doi.org/10.1016/j.asoc.2014.05.019>
- [4] B. Karasulu, *Esnek Hesaplama* “Melez Zeki Sistemler İçin Bir Rehber”, Nobel Akademik Yayıncılık, 2015.
- [5] A. Alaybeyoğlu, K. F. Balbal, A. Özdemir, Bulanık Mantığın Eğitim Alanındaki Uygulamaları, *Bilim, Eğitim, Sanat ve Teknoloji Dergisi (BEST Dergi)*. 3 (2019) 45-50.
- [6] Y. Almalıoğlu, Mehmet Turan, Geliştirilen yapay zeka otonom araçları yaygınlaştıracak, Boğaziçi Üniversitesi, 2022.
- [7] A. Cihan, Akıllı Sağlık, T.C.Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2020.
- [8] H. Wang, Y. Wu, Y. Zhang, F. Lai, Z. Feng, B. Xie, A. Zhao, Uncertainty and explainable analysis of machine learning model for reconstruction of sonic slowness logs, *Artificial Intelligence in Geosciences*. 4 (2023) 182-198, <https://doi.org/10.1016/j.aiig.2023.11.002>.
- [9] O. Peña-Cáceres, H. Silva-Marchan, M. Albert, M. Gil, Recognition of Human Actions through Speech or Voice Using Machine Learning Techniques, *Computers, Materials and Continua*, 77 (2023) 1873-1891. <https://doi.org/10.32604/cmc.2023.043176>
- [10] E. Brynjolfsson, A. McAfee, The business of artificial intelligence, *Harvard Bus. Rev.*, 1–20, 2017.
- [11] G. James, D. Witten, T. Hastie, R. Tibshirani, *Unsupervised Learning*, (2013) 373–418. http://dx.doi.org/10.1007/978-1-4614-7138-7_10.
- [12] T. Hastie, R. Tibshirani, J.F. learning, *Unsupervised learning*, *Elements Stat. Learn.* (2009) 485–585.
- [13] D.P. Kingma, D.J. Rezende, S. Mohamed, M. Welling, Semi-supervised learning with deep generative models, in: *Advances in Neural Information Processing Systems*. (2014) 3581–3589.
- [14] H. van Hasselt, A. Guez, D. Silver, *Deep reinforcement learning with double q-learning*, 2016.
- [15] M. Al-Sarem, W. Boulila, M. Al-Harby, J. Qadir, A. Alsaedi, Deep learning- based rumor detection on microblogging platforms: A systematic review. (2019) 152788–152812.
- [16] J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shuai, T. Liu, X. Wang, L. Wang, G. Wang, J. Cai, T. Chen, Recent advances in convolutional neural networks, *Pattern Recognit.* (2018) 354–377.
- [17] S. K. U. Ajit Kumar Sahoo, A novel fuzzy inspired machine learning framework for relative humidity estimation using time-of-flight of ultrasonic sensor, *Measurement*, 195 (2022). <https://doi.org/10.1016/j.measurement.2022.111035>.
- [18] M. E. Şahin, E. Akın, *Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme*, *EMO Bilimsel Dergi*. 14 (2024).
- [19] S. C. Alkan, *Yapay Zeka ve Doğal Dil İşleme (NLP)*, *Hukuk ve Bilişim Dergisi*. 2023.
- [20] A. Yılmaz, A. Dayan, Doğal dil işleme ve derin öğrenme algoritmaları ile makine dili modellemesi, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 13 (2022) 467-475. <https://doi.org/10.24012/dumf.1131565>.
- [21] J. Abeßer, *A Review of Deep Learning Based Methods for Acoustic Scene Classification*. Semantic Music Technologies, Fraunhofer IDMT, Ehrenbergstraße 31, 98693 Ilmenau, Germany, 2020.
- [22] M. J. Bianco, P. Gerstoft, J. Traer, E. Ozanich, M. A. Roch, S. Gannot, and Charles-Alban Deledalle. *Machine Learning In Acoustics: Theory And Applications*. *The Journal of the Acoustical Society of America*, 146 (2019) 3590.

- [23] S. Guan , W. He, Wenjin Gu , Y. Hou , Y. Chen , X. Zeng, Multi-mode Study of Deep Learning Applications in Acoustic Signal Processing. IEEE International Workshop on Signal Processing Systems (SiPS), 2018.
- [24] H. Ghayvat, S. Pandya, A. Patel, Deep Learning Model for Acoustics Signal Based Preventive Healthcare Monitoring and Activity of Daily Living. 2nd International Conference on Data, Engineering and Applications (IDEA), 2020.
- [25] A. Dang, T. H. Vu, Jia-Ching Wang, A Survey Of Deep Learning For Polyphonic Sound Event Detection 2017 International Conference on Orange Technologies (ICOT), 2017.
- [26] D. Yu and J. Li, Recent Progresses in Deep Learning Based Acoustic Models. IEEE/Caa Journal Of Automatica Sinica, 2017.
- [27] S. Bıçakcı, H. Güneş, Akıllı evler için sesli komut algılama yöntemleri, BAUN Fen Bil. Enst. Dergisi, (2018) 561-568. <https://doi.org/10.25092/baunfbed.445239>.
- [28] Crist, R., Talk to your house with these voice-activated smart-home systems, (2015).
- [29] H. Yılmaz, Akıllı ev'in Dünyadaki ve Türkiye'deki yeri, Bina Elektrik, Elektronik, Mekanik ve Kontrol Sistemleri Dergisi, 2004.
- [30] A. Sanada, Y. Takano, Double Imaging by a Periodic Bi-Fold Transformation Medium, Fourteenth International Congress on Artificial Materials for Novel Wave Phenomena (Metamaterials), New York, USA, 2020.
- [31] O. Coşkun, C. Sertkaya, İnsansız Hava Araçlarının (İHA) Şifrelenmiş Wi-Fi Trafığı Üzerinden Çalışma Modlarının Yapay Sinir Ağları Aracılığı İle Belirlenmesi, Gazi Üniversitesi Fen Bilimleri Dergisi. (2021) 562-563. <https://doi.org/10.29109/gujsc.980170>.
- [32] Acoustic-UAV-Identification, <https://github.com/pcasabianca/Acoustic-UAV-Identification.git> (Accessed 1 November 2023)

