



MARMARA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



# GEMİ AKUSTİK İZLERİNİN OTOMATİK SINIFLANDIRILMASI

GÜRKAN ORHAN

**YÜKSEK LİSANS TEZİ**

Elektrik-Elektronik  
Mühendisliği Tezli Yüksek  
Lisans (Türkçe)

**DANIŞMAN**

Dr. Öğr. Üyesi Veysel Gökhan BÖCEKÇİ

İSTANBUL, 2023



**MARMARA UNIVERSITY  
INSTITUTE FOR GRADUATE STUDIES  
IN PURE AND APPLIED SCIENCES**



# **AUTOMATIC CLASSIFICATION OF SHIP ACOUSTIC TRACKS**

**GURKAN ORHAN**

**MASTER THESIS**

Department of Electrical and  
Electronics Engineering

**Thesis Supervisor**

Dr. Öğr. Uyesi Veysel Gökhan BOCEKÇI

**ISTANBUL, 2023**

# MARMARA ÜNİVERSİTESİ

## FEN BİLİMLERİ ENSTİTÜSÜ

Marmara Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Öğrencisi Gürkan ORHAN'nın "Gemi Akustik İzlerinin Otomatik Sınıflandırılması" başlıklı tez çalışması, 31 Mayıs 2023 tarihinde savunulmuş ve jüri üyeleri tarafından başarılı bulunmuştur.

### Jüri Üyeleri

Dr.Öğr.Üyesi V.Gökhan BÖCEKÇİ (Danışman)  
Marmara Üniversitesi ..... (İMZA).....

Doç.Dr. Kazım YILDIZ (Üye)  
Marmara Üniversitesi ..... (İMZA).....

Dr.Öğr.Üyesi Timur İNAN (Üye)  
Altınbaş Üniversitesi ..... (İMZA).....

### ONAY

Marmara Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ..... tarih ve ..... sayılı kararı ile Gürkan ORHAN'nın Elektrik Elektronik Mühendisliği Yüksek Lisans derecesi alması onanmıştır.

**Fen Bilimleri Enstitüsü Müdürü**  
**Prof. Dr. Bülent EKİCİ**

# İÇİNDEKİLER

İÇİNDEKİLER.....	i
ÖNSÖZ.....	iii
ÖZET .....	iv
ABSTRACT .....	v
KISALTMALAR .....	vi
ŞEKİL.....	vii
TABLO LİSTESİ .....	ix
1. GİRİŞ.....	1
1.1. Tez Motivasyonu .....	2
1.2. Tez Amacı ve Katkısı .....	2
1.3. Tez Çalışması Organizasyonu .....	3
2. LİTERATÜR ÖZETİ .....	3
2.1. Sualtı Akustiği ve Tarihi.....	3
2.1.1. Ses Teorisi .....	5
2.1.2. Ses Dalgalarını Meydana Getiren Faktörler .....	5
2.1.3. Sualtı Ses ile İlgili Temel Parametre ve Kavramlar .....	6
2.1.4. Sesin Yayılımına Etki Eden Faktörler .....	7
2.2. Sualtı Akustiğinde Kullanılan Sistem ve Sensörler .....	8
2.2.1. Sualtı Akustiğinde Kullanılan Uygulamalar.....	8
2.2.2. SONAR Sistemleri .....	9
2.2.3. Sualtı Akustiğinde Kullanılan Sensörler .....	10
2.3. Sualtı Akustiği SONAR Sistemleri Görüntüleme Yöntemleri .....	13
2.3.1. DEMON .....	13
2.3.2. LOFAR .....	14
2.3.3. KERZE (Kerteriz Zaman Ekranı).....	16
2.4. Sualtı Akustiği Gürültü Tipleri .....	16
2.4.1. Gemi Gürültüleri .....	16
2.4.2. Çevresel Gürültüler.....	17
2.5. Veri Setleri .....	18
2.6. Sınıflandırma Yöntemleri .....	18
2.7. Sınıflandırma Sonucu Performans Değerlendirme Yöntemi .....	21
3. DEMON .....	23
3.1. DEMON Literatür Araştırması .....	23
3.2. DEMON Algoritması ve Akış Şeması.....	27

3.3.	SONAR Operatörü DEMON Kullanımı.....	31
3.3.1.	DEMON Terimleri ve Açıklamaları.....	32
3.3.2.	DEMON Hesaplama Formülleri.....	33
3.3.3.	DEMON Görüntüsü Kullanımı.....	34
4.	AKUSTİK VERİ SETİ.....	36
4.1.	Shipear Veri Toplama ve Analizi.....	36
4.2.	Deepship Veri Toplama ve Analizi.....	41
4.3.	Veri Toplama ve Ön Hazırlık.....	43
4.4.	MARMARA-1 Veri Toplama ve Ön Hazırlık.....	49
5.	ANALİZ VE SINIFLANDIRMA SONUÇLARI.....	50
5.1.	Shipear Veri Seti Sonuçları.....	50
5.2.	Deepship Veri Seti Sonuçları.....	57
5.3.	MARMARA-1 Veri Seti Analizi ve Bulgular.....	64
6.	SONUÇ.....	65
	KAYNAKLAR.....	67
	ÖZGEÇMİŞ.....	69

## ÖNSÖZ

Başta, yüksek lisans eğitimimde ve akademik hayatımda desteğini ve yardımlarını hiçbir zaman esirgemeyip bilgisi ile bu çalışmanın oluşmasının yolunu açan danışmanım Dr. Öğr. Üyesi Veysel Gökhan BÖCEKÇİ'ye teşekkürlerimi sunarım.

Çalışma arkadaşım İbrahim Gökhan AKSÜREN'e,

Bütün çalışmam boyunca teşvik ve fikirleriyle çalışmamı yönlendiren değerli danışmanlarım Erhan ÖZER ve Ali Onur AKAR'a,

Son olarak, her zaman yanımda duran ve bana destek olan, aileme teşekkürlerimi sunarım.

**Mayıs, 2023**

**Gürkan ORHAN**

## ÖZET

Sualtı akustik sinyallerin sınıflandırılmasında SONAR sistemleri ile elde edilen bilgiler kullanılarak operatörler tarafından gerçekleştirilmektedir. Askeri alanda savaş durumlarında dost/düşman hedefleri tespit/teşhis ve kimliklendirilmesinde SONAR operatörüne destek olması için otomatik sınıflandırma algoritmaları kullanılması gerekmektedir.

Bu tez çalışmasında sualtı akustik sinyaller kullanılarak su üstünde yer alan hedef ya da nesnelerin otomatik olarak sınıflandırılması gerçekleştirilmiştir. Su üstü ve sualtı platformların sualtına yayılan gürültülerinde baskın olanı pervane kavitasyonu sonucu ortaya çıkan geniş bant gürültüleridir. Kavite gürültüsünü kullanarak hedef tespit ve tanınması için Gürültüde Genlik Modülasyon Tespit (DEMON, ing. Detection Envelope Modulation on Noise) algoritması geliştirilmiştir. Literatürde yer alan DEMON algoritmaları geliştirilerek elde edilen yeni DEMON algoritması ile sınıflandırma performans analizleri ve katkıları incelenmiştir.

Bu tez çalışması kapsamında önerilen DEMON algoritması açık kaynak veri setleri kullanılarak literatürde yer alan diğer çalışmalar ile performans karşılaştırılması yapılmıştır. Literatürde yer alan veri setlerine örnek oluşturması amacıyla benzer yöntemler kullanılarak sahadan veriler toplanmıştır. Toplanan veri ile elde edilen algoritmanın doğrulandığı gözlemlenmiştir.

## **ABSTRACT**

Underwater acoustic signals are classified by operators using information obtained from SONAR systems. Automatic classification algorithms should be used to assist the SONAR classify in detecting/diagnosing and identifying friendly/hostile targets in combat situations in the military domain.

In this study, the automatic classification of targets or objects above water was performed using underwater acoustic signals. The dominant noise among the underwater radiated noise of surface and underwater platforms is the broadband noise that occurs as a result of propeller cavitation. Detection Envelope Modulation on Noise (DEMON) algorithm has been developed for target classification and recognition using cavitation noise. With the new DEMON algorithm obtained by developing DEMON algorithms in the classification, classification performance analyzes and contributions are examined.

The DEMON algorithm proposed within the scope of this thesis study was compared with other studies in the classification by using open source datasets. The data obtained with the proposed In order to set an example for the data sets in the literature, data were collected from the field using similar methods. It was observed that the algorithm obtained with the collected data was verified.

## KISALTMALAR

<b>ASDIC</b>	: Denizaltı Tespiti Soruşturma Komitesi
<b>BR</b>	: Kanat Oranı
<b>DEMON</b>	: Gürültüde Zarf Modülasyonun Tespiti
<b>DOA</b>	: Hedeften Varış Yönü
<b>Hz</b>	: Hertz
<b>KERZE</b>	: Kerteriz Zaman Ekranı
<b>KNN</b>	: K En Yakın Komşu
<b>LOFAR</b>	: Alçak Frekans Analiz ve Kayıt
<b>NOB</b>	: Kanat Sayısı
<b>PRM</b>	: Pervane Şaftı Dönüş Sayısı
<b>PSD</b>	: Güç Spektrum Yoğunluğu
<b>PSR</b>	: Pervane Şaft Oranı
<b>STFT</b>	: Kısa Zamanlı Fourier Dönüşü
<b>SONAR</b>	: Ses Navigasyonu ve Menzil
<b>SVM</b>	: Destek Vektör Makineleri
<b>TPK</b>	: Bir Deniz Mili İçin Şaft Dönüş Oranı
<b>WAV</b>	: Dalga Biçimi Ses Dosyası Biçimi

## ŞEKİL

Şekil 2.1. Göldeki İlk Ses Hızı Ölçüm Denemeler [1].	4
Şekil 2.2 Ses Dalgasının Genlik ve Periyot Kavramlarının Gösterimi	5
Şekil 2.3. Sıcaklık, Tuzluluk ve Basınca göre Ses Hızı Profili.	7
Şekil 2.4. Munk Ses Hızı Profili [5].	8
Şekil 2.5. Hidrofon Tasarımı.	11
Şekil 2.6. Silindirik Hidrofon Dizi Şeması.	12
Şekil 2.7. Hidrofon Dizileri.	12
Şekil 2.8. Gürültüde Zarf Modülasyonunun Tespiti (DEMON).	14
Şekil 2.9. DEMON Spektogramında Dar Bant Spektrumunun Gösterimi [8].	14
Şekil 2.10. Örnek LOFARgram [11].	15
Şekil 2.11. Geniş bandlı analiz için Kerteriz/Zaman ekranı [13].	16
Şekil 2.12. Frekansa bağımlı platformların yaydığı sualtı gürültü grafiği.	17
Şekil 2.13. Naive Bayes Sınıflandırma.	19
Şekil 2.14. SVM Maksimum ayırım gösterimi.	20
Şekil 2.15. KNN Sınıflandırıcı.	21
Şekil 2.16. Karışıklık Matrisi.	22
Şekil 3.1. Literatürde yer alan DEMON algoritması [12].	24
Şekil 3.2. DEMON Algoritması Akış Şeması.	27
Şekil 3.3. Bant Geçiren Filtre.	28
Şekil 3.4. Ses Kaydının DC Ofset Uygulanmış Gösterimi.	29
Şekil 3.5. Complex Baseband Modulation Adımları	31
Şekil 3.6. Gemi Pervane ve Şaft Örneği [28].	33
Şekil 3.7. Kargo Gemisi DEMON Görüntüsü.	35
Şekil 3.8. Yolcu Gemisi DEMON Görüntüsü.	35
Şekil 3.9. Tanker Gemisi DEMON Görüntüsü.	36
Şekil 3.10. Romorkör Gemisi DEMON Görüntüsü.	36
Şekil 4.1. digitalHyd SR-1	37
Şekil 4.2. Hidrofonların Yerleşimi [16].	38
Şekil 4.3. ShipsEar Veritabanındaki Ekran Görüntüsü [16]	39

Şekil 4.4. icListen AF Hidrafonu .....	41
Şekil 4.5. icListen AF hidrofon ile sualtı kayıtları için genel kurulum.....	43
Şekil 4.6. Sistem kurulum şeması. ....	44
Şekil 4.7. Laboratuvar ortamında sistem kurulum şeması. ....	44
Şekil 4.8. National Instrument ürünü NI-FieldDaq.....	45
Şekil 4.9. Labview blok şeması.....	46
Şekil 4.10. Labview arayüzü. ....	46
Şekil 4.11. Sinyal üretici ile 250 Hz sinyal üretilmesi. ....	47
Şekil 4.12. Sinyal üretici ile sistemin doğrulanması. ....	47
Şekil 4.13. Sinyal üretici ile sistemin doğrulanması. ....	48
Şekil 4.14. Havuz ortamında hidrofon ile sistemin doğrulanması. ....	48
Şekil 4.15. Saha ortamında kurulan sistem. ....	49
Şekil 4.16. Saha ortamında veri toplama.....	49
Şekil 5.1. Shipear veri seti farklı sınıfların spektogramı görüntüsü.....	50
Şekil 5.2. Shipear veri seti farklı sınıfların güç spekturm yoğunluğu grafiği. ....	51
Şekil 5.3. Deepship veri seti farklı sınıfların spektogramı görüntüsü. ....	57
Şekil 5.4. Deepship veri seti farklı sınıfların güç spekturm yoğunluğu grafiği. ....	58

## TABLO LİSTESİ

<b>Tablo 2.1.</b> Sualtı Akustik Uygulamaları. ....	9
<b>Tablo 2.2.</b> Çevresel Gürültüler. ....	18
<b>Tablo 3.1.</b> Literatürde yer alan çalışmalar. ....	26
<b>Tablo 3.2.</b> Complex Baseband Adımları Şekil 3.4 Açıklanması. ....	30
<b>Tablo 4.1.</b> digitalHyd SR-1 Teknik Özellikleri. ....	38
<b>Tablo 4.2.</b> ShipEar Veri Seti Özellikleri. ....	40
<b>Tablo 4.3.</b> Shipear Gemi Boyutuna göre 5 Sınıf. ....	40
<b>Tablo 4.4.</b> icListen AF Teknik Özellikleri. ....	42
<b>Tablo 4.5.</b> DeepShip Veri Seti Özellikleri. ....	42
<b>Tablo 4.6.</b> Bruel & Kjaer 8106 Teknik Özellikleri. ....	45
<b>Tablo 5.1.</b> Shipear Sınıflandırma Sonuçları. ....	51
<b>Tablo 5.2.</b> Shipear KNN Karışıklık Matrisleri. ....	52
<b>Tablo 5.3.</b> Shipear NN Karışıklık Matrisleri. ....	52
<b>Tablo 5.4.</b> Shipear SVM Karışıklık Matrisleri. ....	53
<b>Tablo 5.5.</b> Shipear Sınıflandırma Sonuçları. ....	54
<b>Tablo 5.6.</b> Shipear 20 sn 0-152Hz Verisi KNN Sonuçları. ....	54
<b>Tablo 5.7.</b> Shipear KNN Karışıklık Matrisleri. ....	55
<b>Tablo 5.8.</b> Shipear NN Karışıklık Matrisleri. ....	55
<b>Tablo 5.9.</b> Shipear SVM Karışıklık Matrisleri. ....	56
<b>Tablo 5.10.</b> Deepship Sınıflandırma Sonuçları. ....	58
<b>Tablo 5.11.</b> Deepship KNN Karışıklık Matrisleri. ....	59
<b>Tablo 5.12.</b> Deepship NN Karışıklık Matrisleri. ....	60
<b>Tablo 5.13.</b> Deepship SVM Karışıklık Matrisleri. ....	60
<b>Tablo 5.14.</b> Deepship Sınıflandırma Sonuçları. ....	61
<b>Tablo 5.15.</b> DeepShip 60 sn 0-152Hz Verisi KNN Sonuçları. ....	61
<b>Tablo 5.16.</b> Deepship KNN Karışıklık Matrisleri. ....	62
<b>Tablo 5.17.</b> Deepship NN Karışıklık Matrisleri. ....	63
<b>Tablo 5.18.</b> Deepship SVM Karışıklık Matrisleri. ....	63
<b>Tablo 5.19.</b> Literatürde yer alan veri setleri. ....	64

<b>Tablo 5.20.</b> Marmara veri seti.....	64
<b>Tablo 5.21.</b> Marmara veri seti Sınıflandırma Sonuçları. ....	65
<b>Tablo 5.22.</b> Marmara KNN Karışıklık Matrisleri. ....	65



## 1. GİRİŞ

Sesin sualtında ortamında, elektromanyetik enerji veya ışık ortamına göre daha uzaklara ulaştığı eskiden bilinmemektedir. Ses hızı ölçmek amacıyla, sualtı akustiği alanında ilk çalışma 1827 yılında Fransız matematikçi Charles Sturm ve İsviçreli fizikçi Daniel Colloden tarafından yapılmıştır. Bu çalışmanın amacı sesin sualtı ortamındaki hızını tespit etmek amacıyla yapılmıştır. Araştırmacılar, İsviçre’de Geneva Gölü’nde bir su altı çanı ve bir fener arasındaki zaman farkını yaklaşık olarak ölçerek yapılmış olup bu deneme, günümüzde kullanılan ses hızı değerlerine oldukça yakındır [1].

20. yüzyılda başlarında ise, gemilerde bulunan bir su altı çanı ve bir sis düdüğünün kullanımı ile uzaklık ölçme sistemi olarak kullanılmaya başlanmıştır. Bu yöntem sayesinde diğer gemilerdeki personel her iki sesi de duyabiliyordu. Bu yöntem sayesinde, geminin karinasına yerleştirilen hidrafon ile güvertesindeki bulunan hidrofonlara ulaşan sesin zaman farkından tahmini mesafesi ölçülebilmekteydi.

Birinci Dünya Savaşı esnasında İngiliz, Fransızlar ve Amerikalılar tarafından yer altında oluşan buz dağlarını ve denizaltılarını bulmak amacıyla ilk sonar sistemleri geliştirilmiştir. Birinci Dünya Savaşında kullanılan sonarlara “ASDIC” (Denizaltı Tespiti Soruşturma Komitesi ing. AntiSubmarine Detection Investigation Committee) diye isimlendirilmekteydi. Savaştan sonraki dönemde denizaltı altında çalışmalar hız kazanmasıyla birlikte, onu tespit için yönelik sualtı akustiği alanında çalışmalar hızlandı. İkinci Dünya savaşı döneminde akustik alanındaki çalışmalar sonucunda denizaltılarının suüstü gemileri tarafından kolay olarak tespit edilebilir hale gelmiştir. Bunun sebebi yapılan çalışmalar sonucunda yönlendirilmiş ve daha güçlü sesi suya gönderebilmesidir. Üretilen ses sinyali, hedef denizaltının güvertesine çarpar ve yansırarak geri gelmektedir. Gönderilen ses ile gelen ses arasında zaman farkı ölçülerek hedefe ait mesafesi bilgi ölçülebilmektedir [2].

Günümüzde sonarlar çeşit alanlarda kullanılmaktadır. Bunlar; petrol ve doğal gaz araştırmaları, balık stoklarının bulunması, derinlik ölçme, sismik stratigrafi, deniz tabanının morfolojisinin çıkartılması, kabuk özellikleri ve kalınlığının belirlenmesi, mühendislik ve akustik uygulamalar, gibi birçok çalışmada kullanılmaktadır.

Son yıllarda akustik araştırma çalışmaları hız kazanarak artış göstermektedir.

Arařtırmacıların yaptıkları alıřmalarda aık veri setleri ve kendi ekipmanlarını kullanarak oluřturdukları veri setleri kullanılmaktadır.

Bu alıřmada, Pasif SONAR uygulamalarından biri olan kavitasyon gürültüsünü kullanarak hedef tespit ve tanınması için Gürültüde Genlik Modülasyon Tespit (DEMON, ing. Detection Envelope Modulation on Noise) analizi ile pasif sistemler ile elde edilen akustik veriler kullanarak sualtı akustik imza elde edilmesi kavramını incelemek ve arařtırmaktır. Bu sebeple farklı sualtı ve su üstü platformların üretmiş oldukları farklı seslerin elektronik ortamdaki kayıtları kullanarak bunların görsel analizlerinin yapılması alıřılmıştır.

### **1.1. Tez Motivasyonu**

Bu alıřmanın motivasyonunu sualtı akustik sinyaller kullanarak otomatik hedef sınıflandırma problemini sınıflandırmayı en iyi yapan SONAR Operatörüne destek olarak, karar destek sistemini otomatik gerçekleřtirecek bir algoritma geliřtirmektir.

### **1.2. Tez Amacı ve Katkısı**

Son yıllarda sualtı akustik alanında yapılan arařtırma gerek askeri gerekse sivil ve ticari alanda hızla büyümektedir. Sualtı akustik teknolojileri, deniz ortamı kirlilik takibi, arařtırmacılar için otomatik bilimsel veri toplanması, İnsansız sualtı arama kurtarma araçları, Askeri Dalğı Tespit SONAR'ları, Askeri gemiler ve denizaltılarda uygulamalarında kullanılan SONAR, kurtarma için deniz tabanının haritasının ıkartılması ve benzeri uygulamalar için oldukça önemlidir. Akustik ortam gürültüsünü balıklar, karidesler, gemiler, vb. tarafından meydana gelmektedir. Tüm bu karmařık sinyal ortamında akustik sinyaller kullanarak hedeflere ait parmak izi bilgisi ıkarılabilmektedir.

Sualtında iletiřim için radyo dalgaları ve ışık kullanılmamasının sebebi su içinde yayılımları ok abuk zayıflarlar ve sönümlemeye uğrarlar. Bu sebepten dolayı sualtı ortamında ses dalgaları yayılımı idealdir. Geneva Gölü'ndende başlamak üzere günümüze kadar geen süre içerisinde, su altı akustiğı konusunda devamlı olarak arařtırmalar, alıřmalar ve uygulamalar yapmaktadırlar.

Bu çalışmada, akustik sinyaller akustik sinyal işleme yöntemleri kullanılarak DEMON algoritması ile elde edilen çıktılar öznitelik olarak değerlendirilerek makine öğrenmesi algoritmaları ile sınıflandırma gerçekleştirilmiştir. Literatürde yer alan diğer çalışmalar ile karşılaştırılması yapılarak en başarılı sınıflandırma algoritması gerçekleştirilmiştir.

Problemin zorluğu sebebiyle literatüre bu çalışmanın kazandırılması gerek ticari sivil alanda gerekse askeri alanda MİLLÎ teknoloji sistemlerine katkı sağlayarak gücümüzün artması ve en önemlisi üç tarafı denizlerle çevrili olan ülkemizin denizlerimizin korunmasında büyük katkısı olacaktır.

### **1.3. Tez Çalışması Organizasyonu**


Bu tez çalışması kapsamında tezin organizasyonu altı bölümden oluşmaktadır. Bölüm 2’de daha önce yapılmış çalışmaların kısa bir özeti olarak literatür taraması yapılmıştır. Bölüm 3’te sualtı akustik sinyaller kullanılarak sınıflandırma problemi için, DEMON algoritması ve algoritma geliştirilerek karşılaştırmalı analizi anlatılmıştır. Bölüm 4’te, açık veri setleri, veri toplama ve ön hazırlık ile analizler gerçekleştirilmiştir. Bölüm 5’te sonuçlar ve analizler sunulmuştur. Devamında sonuç ile tez sonlandırılmıştır.

## **2. LİTERATÜR ÖZETİ**

### **2.1. Sualtı Akustiği ve Tarihi**

Sualtı akustiğinin insanlar tarafından 1490 yıllarından kullandığı düşünülmektedir. Leonardo da Vinci’inin “Geminizi durdurur ve uzun bir borunun başını suya sokar ve dış ucunu kulağınıza koyarsanız, sizden çok uzaktaki gemileri duyarsınız.” sözleri buna işaret etmektedir [2].

Sualtı akustiğinin geliştirilmesindeki bir sonraki büyük adım, Fransız matematikçi Charles Sturm ve İsviçreli fizikçi Daniel Colladon’un 1826’da Geneva Gölü’nde, bir ışık ile bir su altı dinleme kornası kullanılarak batık bir geminin ziline sesi arasında geçen süreyi Şekil 2.1’de gösterilen yöntemi kullanılarak hesapladılar [3]. Günümüzde ses hızını 1461 m olarak kullanılmakta iken 1826’da yapılan ölçümlerde sadece %2’lik fark ile 1435 m olarak hesaplanmıştır.



**Şekil 2.1.** Göldeki İlk Ses Hızı Ölçüm Denemeler [1].

Birinci Dünya Savaşı sualtı akustiği araştırmalarının hızlanması ve geliştirilmesine önemli katkılar sağlamıştır. Birinci Dünya Savaşı'nın başlamasıyla müttefiklerin uzak mesafelerden denizaltı tespiti ve savunmaya yönelik çalışmalar gerçekleştirilmiştir. Bu dönemde Thomas Edison tarafından tasarlanan karbon granül mikrofonu hedefin varlığını algılamak için kullanılmıştır. Bu cihaz basit bir çift kulaklı pnömatik sistemden oluşan akustik alanda yapılan çalışmalar için öncü olmuştur. Cihaz "ASDIC" (Denizaltı Tespiti Soruşturma Komitesi - ing. AntiSubmarine Detection Investigation Committee) diye adlandırılıyordu. Günümüzde ise SONAR (Ses Navigasyonu ve Menzil- ing. Sound Navigation and Ranging) adı verilmektedir.

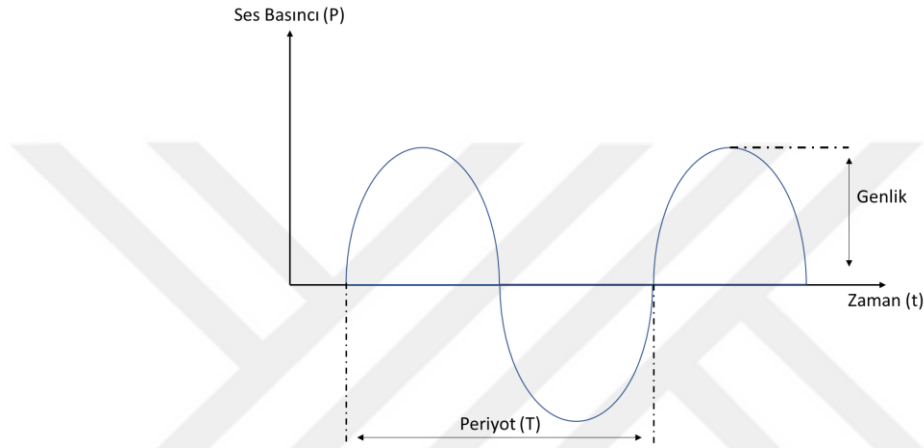
Birinci Dünya Savaşından sonra birçok Amerikalı, Fransız ve İngiliz bilim adamı ve mühendis sualtı akustiğine yönelik uygulamalar üzerine çalışmalara başladı. Langevin'in dönüştürücülerin aralıklı eko üreten cihazlar olarak çalışabileceğini, George W. Pierce, derinlik sondajı için manyetostriktif transdüksiyon geliştirilmesi, Rochelle piezoelektrik kristalleri üzerine birçok çalışma gerçekleştirildi.

İkinci Dünya Savaş'ından bu yana geçen yıllar hem askeri hem de askeri olmayan amaçlar için sualtı akustikinden yararlanma konusunda dikkate değer ilerlemeler kaydedilmiştir.

Askeri tarafta aktif sonarlar daha büyük ve daha güçlü hale gelirken pasif sonarlarda tespit olasılığını arttırmak amacıyla düşük frekansa yönelirken askeri olmayan amaçlarda ise derinlik sondajı, balıkçı sonarı, dalgıçlara yardım amaçlı vb. sistemler geliştirilmiştir [2].

### 2.1.1. Ses Teorisi

Ses, bir ses seviyesi ölçer veya canlıların işitme organları tarafından algılanabilen periyodik basınç dalgalanmalarıdır. Oluşan basınç dalgalanmaları bulunduğu ortama göre, Suda 1453 m/s, havada 340 m/s, katı cisimlerde yoğunluklarına göre değişmekle birlikte yaklaşık olarak 5000 m/s hızla yayılırlar. Şekil 2.2’de gösterilen dalganın bir genliği, frekansı, dalga boyu vardır.



Şekil 2.2 Ses Dalgasının Genlik ve Periyot Kavramlarının Gösterimi

Genlik: Basınç değişiminin büyüklüğü ( $Pa = \frac{Nt}{m^2}$ )

Periyot(T): Bir basınç devri için geçen süre

Frekans(f): Birim zamandaki basınç değişim devir sayısı  $f = 1/T$

Ses ölçümlerinde ses basıncı Pascal (Pa), ses yoğunluğu Watt/m<sup>2</sup> ile sunulur ve sesin şiddet birimine “Desibel” (dB) olarak adlandırılır.

### 2.1.2. Ses Dalgalarını Meydana Getiren Faktörler

Ses dalgalarının meydana gelmesinde üç farklı grup bulunmaktadır. Canlı varlıklar, Cansız varlıklar ve doğal afetlerden sesler meydana gelebilir. Oluşan ses dalgaları, yansıma, saçılma, yutulma ve kırılma meydana gelebilir. Yansıma, ses dalgasının büyük engellere çarparak yön değiştirmesine denir. Saçılma, yansıma oluşturacak

yüzeyin girintili çıkıntılı olması sonucu her yöne yayılmasına denir. Yutulma, ses bir malzeme içinden geçerken ya da bir yüze çarptığında enerjinin başka forma bürünmesidir. Kıvrılma, ses dalgalarının küçük aralıklardan, engellerden ya da keskin kenarlı yerlerden geçişi ile yollarının sapması olayıdır.

### 2.1.3. Sualtı Ses ile İlgili Temel Parametre ve Kavramlar

Ses dalgaları canlı, cansız ve doğal afetlerden meydana gelmektedir. İleri geri süratle hareket eden ve titreşerek etrafındaki ortamı karıştıran herhangi bir şey ses kaynağını oluşturmaktadır. Kaynağı meydana getiren parametreler;

- Saykıl: Bir genişleme ya da tekrar daralma olarak tanımlanır.
- Periyot: Tam bir saykılın meydana gelmesi için geçen birim zamandır.
- Genlik: Dalganın dikey hareketinin yarısıdır.
- Frekans: Saniyedeki titreşim adedine frekans denir. Birimi Hertz (Hz)'dir.
- Dalga Boyu: Aynı basınçta bulunan iki nokta arasındaki mesafeye dalga boyu denir. Dalga boyu ses hızının frekansa bölünmesiyle elde edilmektedir.

Ses dalgaları, içinden geçtikleri maddenin molekülleri vasıtasıyla yayılmaktadırlar. Ses dalgalarının yayılabilmesi için ortam şarttır. Ortam ses enerjisini aktaran herhangi bir cisim olarak tanımlanabilir ve gaz, sıvı veya katı halde olabilir. Ses sinyallerinin işitebilmesi için alıcıya ihtiyaç duyulur. Alıcı yoksa ses de yoktur.

- Pitch: Bir cismin saniyedeki titreşim adedinin çoğalarak veya azalarak çıkardığı sesin tizleşmesine veya pesleşmesine pitch denilmektedir. Titreşim adedi çoğaldıkça yani frekans arttıkça dalga boyu kısalacağından yüksek pitch tiz sesler meydana gelmektedir. Frekans azaldıkça dalga boyu uzayacağından alçak pitch pes sesler meydana gelmektedir.
- Şiddet: Sesin frekansında herhangi bir değişiklik olmadan ses seviyesinin yükselmesi veya alçalmasını ifade eder.
- Kalite: Sesi üreten kaynağın kendi yapısına has olarak çıkardığı ses özellikleri kalite olarak tanımlanabilir.
- Ses ölçü birimi (dB): Sensörler gelen ses dalgalarını geçişi boyunca yoğunluk değişimlerini hassas olarak ölçebilmektedir. Yoğunluk, normal yayılma yönünde

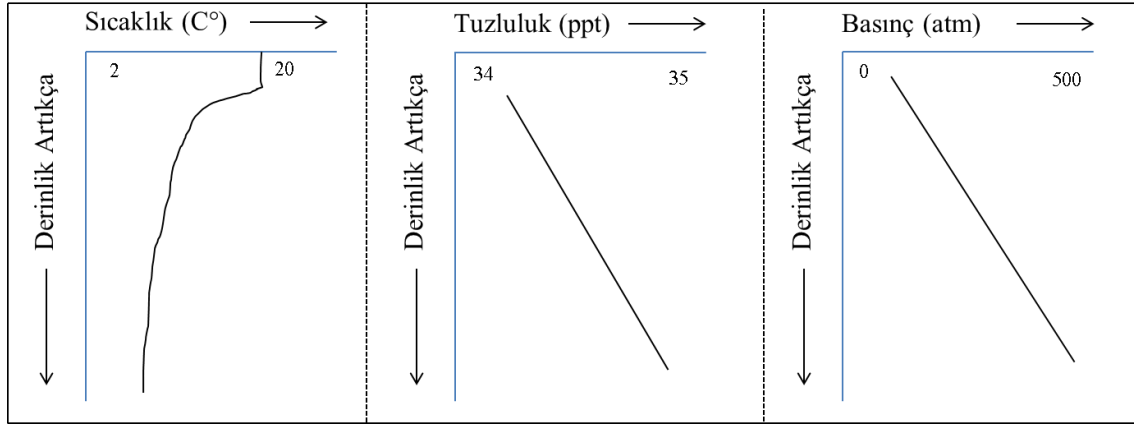
bir bölge içinden geçen ses gücünün ölçülmesi olarak tanımlanabilir ve ölçüsü watt/m karedir. Ses ölçü birimi ise BEL olarak kullanılmaktadır. BEL onda biri olan desibel en yaygın olarak kullanılan ölçüdür.

#### 2.1.4. Sesin Yayılımına Etki Eden Faktörler

Sesin yayılmasını etkileyen faktörler, sesin yayıldığı ortamın yoğunluğu ve ortamın sıcaklığıdır. Sualtı ortamında ise yoğunluk, basınç ve tuzluluk değişmektedir. Bunun için sudaki ses hızı yayılımına etki eden faktörler, sıcaklık, tuzluluk ve basınç olarak söylenebilir. Sudaki ses hızı, artan su sıcaklığı, artan tuzluluk ve artan basınç (derinlik) ile artar. Şekil 2.3'te görüldüğü üzere sesin sudaki hızı, artan su sıcaklığı, artan tuzluluk ve artan basınç (derinlik) ile artar ve her bir özellikteki bir değişiklikle ses hızındaki yaklaşık değişiklik:

- Sıcaklığın 1°C değişmesi = 4 m/s,
- Tuzluluğun 1PSU değişmesi = 1,4 m/s,
- Derinlik (Basınç) 1km değişmesi = 17 m/s,

ses hızına etki etmektedir.



Şekil 2.3. Sıcaklık, Tuzluluk ve Basınca göre Ses Hızı Profili.

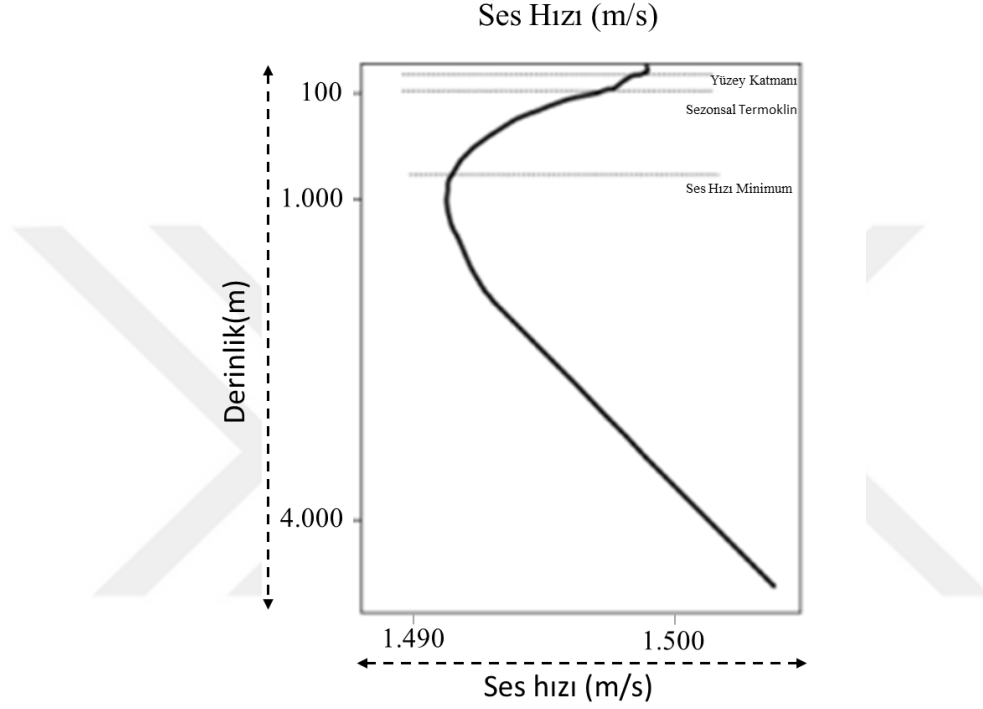
Sualtı ses hızı hesaplama formülü Denklem 2.1'de gösterilmektedir [4].

$$c = c(T, S, z) = 1429,9 + 3 * (T - 10) - 6 * 10^{-3} * (T - 10)^2 - 4 * 10^{-2} * (T - 18) + 1,2 * (S - 35) - 10^{-2} * (T - 18) * (S - 35) + z/61 \quad (2.1)$$

Denklem 2.1'de kullanılan parametreler;

$c$	= ses hızı
$T$ (°C)	= sıcaklık
$z$ (m)	= derinlik
$S$ (Binde bir cinsinden)	= tuzluluk

Şekil 2.4'te gösterilen orta enlemlerde bulunan derin ve açık okyanus sularında bir ses hızı profili gösterilmektedir [5].



Şekil 2.4. Munk Ses Hızı Profili [5].

## 2.2. Sualtı Akustiğinde Kullanılan Sistem ve Sensörler

Sualtı akustiğinde kullanılan sistem ve sensörler ile sualtı haberleşme ağı, oşinografik veri toplama, kirlilik izleme, açık deniz araştırmaları, afet önleme, yardımcı navigasyon ve taktiksel gözetim uygulamaları için kullanılmaktadır.

### 2.2.1. Sualtı Akustiğinde Kullanılan Uygulamalar

Günümüz teknolojisi gelişmesiyle birlikte sualtı akustiğinde kullanılan uygulamalar gelişmiş ve gelişmeye devam etmektedir. Askeri alanlarda kullanımının yanında sivil alanda da kullanımı artmış ve yaygınlaşmaya devam etmektedir. Kullanılan uygulamalar arasında Sualtı Haberleşme, Sualtı Navigasyon ve Takibi, Sismik Araştırma, Hava ve İklim Gözetleme, Oşinografi, Deniz Biyolojisi kullanılan uygulamalar arasındadır.

**Tablo 2.1.** Sualtı Akustik Uygulamaları.

Sualtı Uygulamalar	Kullanım Alanları
İletişim	İnsanlı ve insansız sualtı araçları arasındaki haberleşmeyi sağlamak için sualtı iletişime ihtiyaç duyulmaktadır. En çok kullanılan uygulamalar arasında askeri alanda sualtı telefonlarında kullanılmaktadır.
Navigasyon ve Takip	Sualtı navigasyonu ve takibi, otonom sualtı araçları, denizaltılar tarafından yapılan çalışmalarda keşif için en önemli uygulamalar arasında yer almaktadır.
Sismik Araştırma	Sismik araştırma uygulamaları ile deniz dip tabiatını, derinlikleri ile deniz tabanını araştırmak için kullanılmaktadır.
Hava ve İklim Gözetleme	Hava iklim gözetlemesi ile deniz durumu; sıcaklık, rüzgâr ve yağışın denize etkisi araştırılarak akustik sensörlerin kullanımının ayarlanmasında çok önemli bir yere sahiptir.
Oşinografi	Akustik SONAR ile büyük ölçekli denizlerin özellikleri tespit edilebilir. Yan taramalı sonarlar en çok bu uygulamada kullanılmaktadır.
Deniz Biyolojisi	Sualtı akustik sensörler kullanılarak deniz yaşamını takip etmek ve araştırmak için kullanılır. Deniz yaşamı incelenerek canlıların dağılımları ve davranış bilgileri takip edilebilir.

### 2.2.2. SONAR Sistemleri

Sualtı hedeflerin akustik sinyaller ile tespit edilerek hedeflerin sınıflandırılması yerinin belirlenmesi için SONAR (Ses Navigasyonu ve Menzil- ing. Sound Navigation and


Ranging) kullanılır. SONAR sistemleri hedef için gerekli bilgileri alırken sistem analizi ve tasarım gereksinimleri olarak iki başlık altında toplanmaktadır. Bu sistemler Aktif ve Pasif SONAR sistemleri olarak ikiye ayrılmaktadırlar.

- Pasif SONAR: Dinleme SONAR'ı olarakta bilinmekte olan Pasif SONAR'lar sualtı hedeflerden yayılan makine, pervane gürültülerini kullanarak tespit ve kimliklendirme işlemlerinde kullanılmaktadırlar. Pasif SONAR düşük ses enerjisini elektrik enerjisine çeviren su alt mikrofonu olan **hidrafon** denilen aygıtlar ile dinleme gerçekleştirilmektedir.
- Aktif SONAR: Akustik dalga göndererek, hedeften yansıyan akustik dalgaların tekrar yakalanarak çalışan sistemler olarak bilinmektedirler. Aktif sistemlerde elektrik enerjisini ses enerjisine ve ses enerjisini elektrik enerjisine dönüştüren TRANSDÜSER'ler kullanılmaktadır. Aktif sonarlarda ses işaretini üreten PROJEKTÖR'ler mevcuttur. Aktif sonarlar araştırma, derinlik tespiti, görüntüleme için kullanılmaktadırlar.

### 2.2.3. Sualtı Akustiğinde Kullanılan Sensörler


Sensörler ortamdaki değişiklikleri tespit ederek elektronik cihazlara bilgi sağlayan sistemler olarak ifade edilmektedir. Sualtında olan değişimleri tespit edilmesi ve bilgilerin saklanması akustik sensörler kullanılmaktadır. Başlıca akustik sensörler aşağıda gösterilmektedir.

- Hidrafon: Sualtındaki akustik sinyallerin algılanması ve toplanması amacıyla hidrafonlar kullanılır. Havadaki sesin algılanması ve toplanması için kullanılan mikrofonun çalışma prensibi benzerdir. Hidrafon yapısında bulunan seramikler sayesinde basınca maruz bırakılması durumunda elektrik sinyalleri üretir. Şekil 2.5'te hidrafonun yapısı gösterilmektedir [6].



Şekil 2.5. Hidrofon Tasarımı.

- Hidrafon Dizileri: Birden fazla hidrofonun bir araya getirilerek silindirik ya da küresel form yapısında oluşturulmasına hidrofon dizini olarak tanımlanmaktadır. Düzlemsel, silindirik ve küresel yapıda olan hidrofon dizileri genellikle sualtı ve su üstü platformlarda pasif dinleme amaçlı kullanılmaktadır [6]. Hidrofon dizinlerini oluşturulmasının asıl amacı hedeften yayılan gürültülerin dizininde bulunan açı bilgisi kullanılarak kerteriz bilgisi bulmak ve alışı hassasiyetini arttırmaktır. Şekil 2.6'da silindirik hidrofon dizileri şeması gösterilmektedir [7].



**Şekil 2.6.** Silindirik Hidrofon Dizi Şeması.

Şekil 2.7’de örnek Hidrofon dizi uygulamaları gösterilmektedir. Dizi uygulamaları denizaltı platformlarında yaygın olarak kullanılmaktadır.



**Şekil 2.7.** Hidrofon Dizileri.

- Önyükselticiler: Ses dalgalarının titreşimleri hidrofon ile düşük voltaj elektrik akımına dönüştürerek kaydedilir ve sinyal seviyeleri mikro volt olan düşük seviyelerdedir. Düşük seviyedeki sinyal seviyelerini yükseltmek için ön yükselticiler kullanılmaktadır.

### 2.3. Sualtı Akustiđi SONAR Sistemleri Görüntüleme Yöntemleri

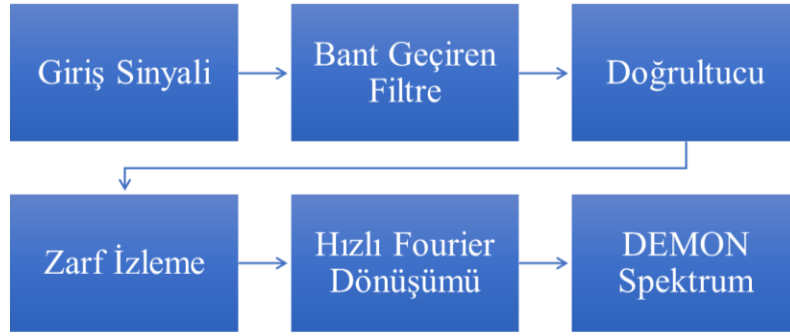
Sualtı akustik sensörler ile kaydedilmiş ve analiz edilmesi gereken birçok ses bileşeni içermektedir. Hedeflerin imzası olarak kullanılabilcek ilgili frekansların ses bileşenlerini seçmek çok önemlidir. Sualtı ve su üstü savaş platformlarının deniz görevlerini yerine getirmesi için ortamsal şartlar kaynaklı dađınık sinyal ortamından hedef izi tanımlayan araştırmalardan yararlanılması açısından literatürde mevcut çalışmalardan yararlanılmaktadır. Hedeflere ait parmak izi niteliğinde olan DEMON verisi öznitelik olarak değerlendirilmektedir. DEMON'un ana görevi olan sualtı ve su üstü platformların yaymış olduđu kavitasyon gürültülerini tespit etmek ve analiz etmektir. Ses verisi çeşitli analizler ile görüntülenmektedir aşağıda görüntüleme için yöntemler açıklanmaktadır. Bu yöntemler daha çok Pasif SONAR sistemleri görüntüleme yöntemleri olarak bilinmektedir.

#### 2.3.1. DEMON

DEMON (Gürültüde Zarf Modülasyonun Tespiti - ing. Detection Envelope Modulation on Noise), kavitasyon gürültüsünü kullanarak hedef tespit ve tanınması için Gürültüde Genlik Modülasyon Tespit kısaltması olarak bilinmektedir. DEMON denizaltılar ve su üstü gemilerinin tespit edilmesine ve gürültülerinin analiz edilerek sınıflandırılmasına imkân sağlar.

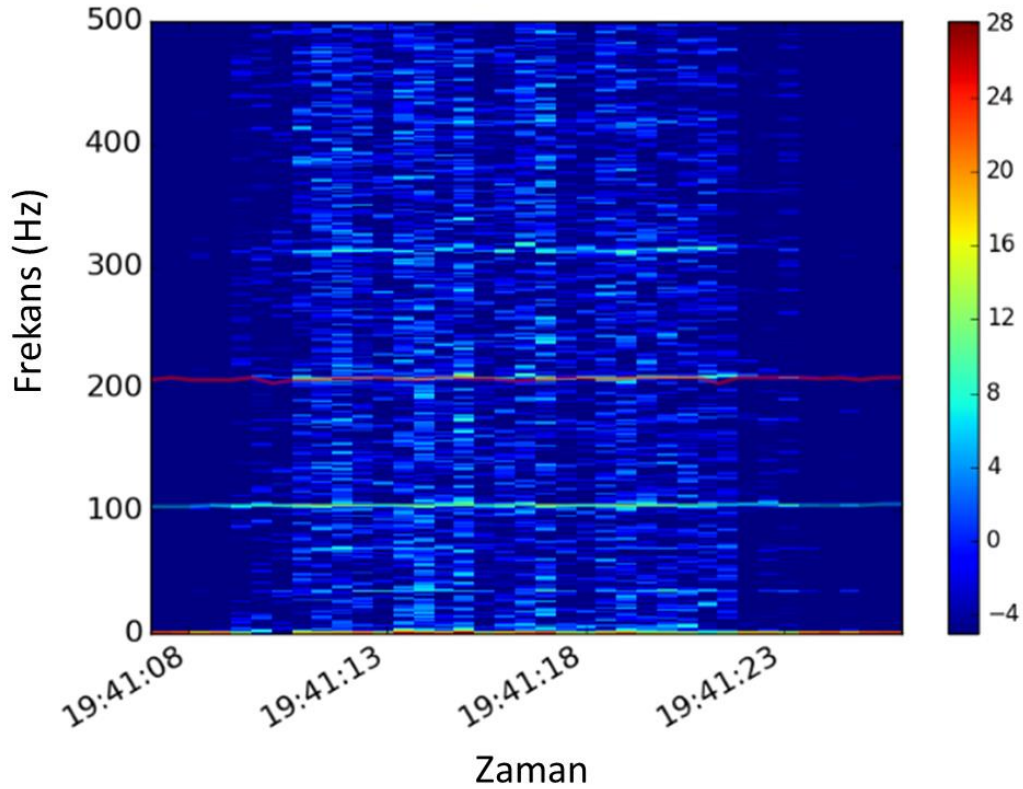
Gemi gürültüsünün tespiti ve sınıflandırılması için sualtı pasif akustiğinde DEMON yaygın olarak kullanılmaktadır. DEMON algoritması, bir gemi pervanesi tarafından oluşturulan yüksek frekanslı kavitasyon gürültüsünü modüle eden frekansları çıkarır ve Gürültü Üzerinde Zarf Modülasyonu Algılama ile gemi tespit ve sınıflandırılmasını sağlar. DEMON, büyük gemilerin sınıflandırılması için yaygın olarak kullanılmaktadır, çünkü bu modülasyon frekansları, pervanenin dönüş hızı ve pervane kanatlarının sayısı ile doğrudan ilişkilidir [8].

Literatürde yer alan klasik DEMON algoritması için ham giriş sinyalinden son DEMON spektrumuna kadar DEMON sürecinin temel yapısı Şekilde 2.8'de gösterilmektedir [9].



**Şekil 2.8.** Gürültüde Zarf Modülasyonunun Tespiti (DEMON).

Dar bant frekans seçiminin bir örneği Şekil 2.9'da bir DEMON spektrogramında gösterilmektedir [8].



**Şekil 2.9.** DEMON Spektrogramında Dar Bant Spektrumunun Gösterimi [8].

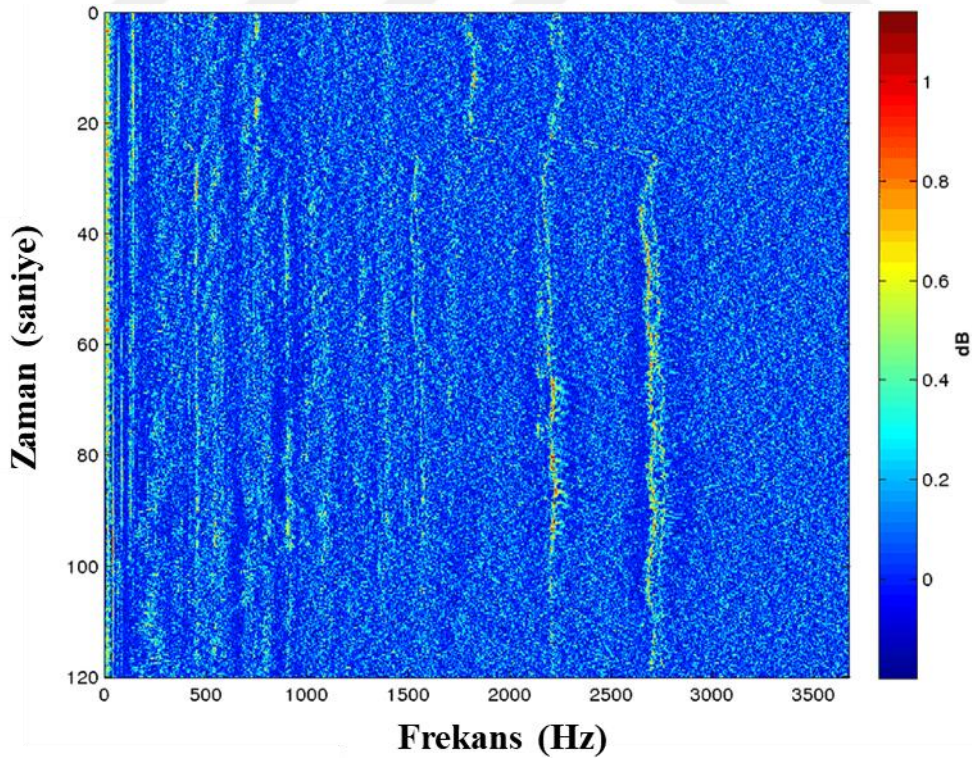
### 2.3.2. LOFAR

LOFAR (Alçak Frekans Analiz ve Kayıt - ing. Low Frequency Analysis and Recording) alçak frekans analiz ve kaydının kısaltmasıdır. Su üstü ve sualtı platformları olan

gemilerin uzak mesafelerden gürültüleri analiz edilerek tespit ve sınıflandırılmasına imkân sağlamaktadır. Sualtı akustik sensörler tarafından kaydedilen akustik sinyalleri oluşturan gemi gürültüleri frekans-zaman alanına dönüştürülerek güç spektrumları görüntülenerek elde edilmektedir. LOFAR'da yatay eksen frekansı dikey ekran zamanı göstermektedir ve buna LOFARgram denmektedir.

LOFAR, gemilerin üzerinde bulunan cihaz, sistem, yardımcı ve ana tahrik sistemlerinin gemi teknesine çarpması sonucunda oluşan titreşim kaynaklı gürültüleri inceleyen ve odaklanan Pasif SONAR uygulamaları içinde yer alır.

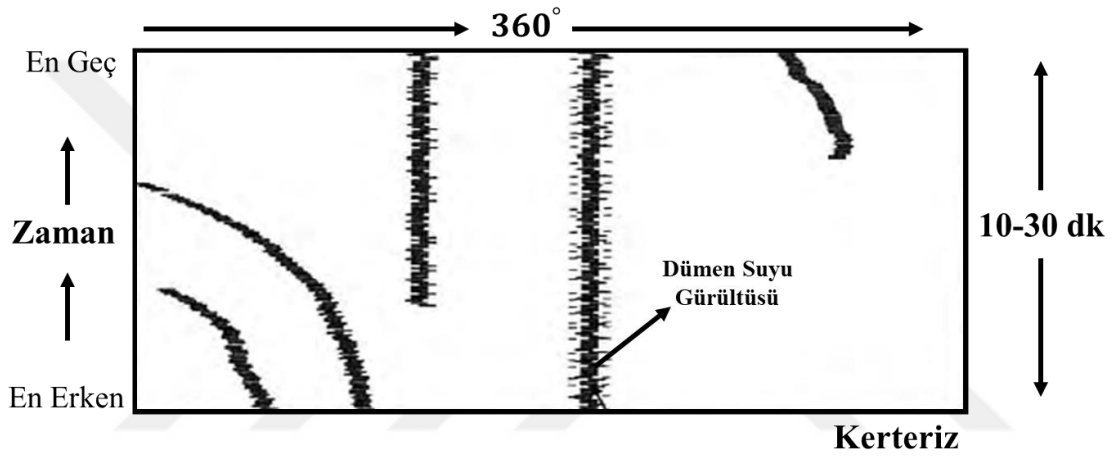
LOFAR spektrumu akustik sinyallerin kısa süreli durağan özelliği nedeniyle sinyallerin etkin bir temsili niteliğinde olup, sinyalin frekans-zaman spektrumunu elde etmek için kısa zamanlı Fourier dönüşümüne (STFT ing. Short Time Fourier Transform) dayanır ve hat spektrumunu tespit etmek için düşük frekanslı hat spektrumunun zaman birikimini kullanır [10]. Örnek olarak Şekil 2.10'da gösterilen LOFARgram, şelale (waterfall) ekranı hem frekans hem de zaman bilgisi, belirli bir edinim penceresi dikkate alınarak gösterilir [11].



Şekil 2.10. Örnek LOFARgram [11].

### 2.3.3. KERZE (Kerteriz Zaman Ekranı)

Pasif SONAR sistemi, denizaltılar tarafından belirli bir operasyon alanında gözetleme ve ortam dinleme gerçekleştirmek için kullanılır. Hüzme oluşturma, belirli bir hedeften varış yönünü (DOA, ing. Direction of Arrival) tahmin etmeyi amaçlar. Şelale ekranında (ing. waterfall display) yatay eksen,  $-180$  ile  $180$  derece temsil eder ve dikey eksen, zamanı temsil etmektedir. Kerteriz zaman ekranının amacı hedeflerin varış yönünü tespit etmeyi ve hedeften yayılan enerjiyi tahmin etmek için kullanılmaktadır. Şekil 2.11’de kerteriz zaman ekranı (ing. bearing rate display) görüntüsü gösterilmiştir [12].



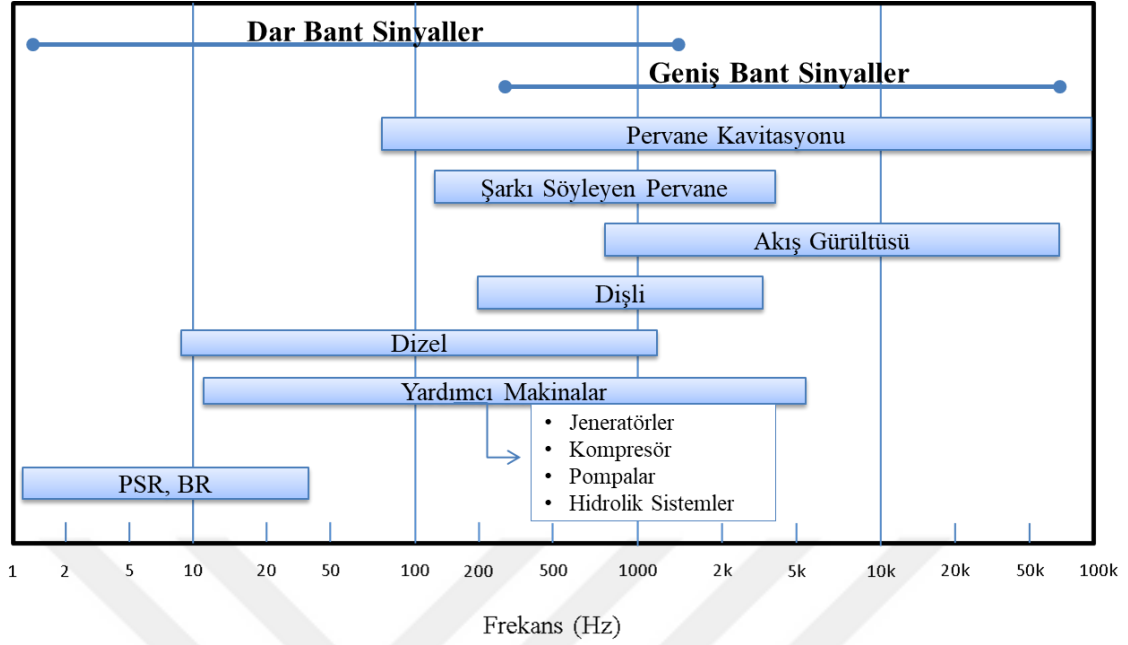
Şekil 2.11. Geniş bantlı analiz için Kerteriz/Zaman ekranı [13].

## 2.4. Sualtı Akustiği Gürültü Tipleri

Sualtı akustiğinde 2 çeşit gürültü bulunmaktadır. Bu gürültüler Gemi ve Çevresel gürültülerden oluşmaktadır. Gemi gürültüleri tespit etmeyi amaçladığımız gürültüler sınıfındayken çevresel gürültüler ise gemi gürültülerini tespit etmeyi zorlaştıran gürültülerdir.

### 2.4.1. Gemi Gürültüleri

Sualtı ve su üstü platformların bünyesinde bulunan tüm sistem ve cihazlar başlıca gürültü kaynaklarıdır. Sistem ve cihazların yarattıkları titreşimlerin gemi teknesine çarparak sualtında uzak mesafelere yayılarak gürültüyü meydana getirmektedir. Platformlardan yayılan gürültülerin frekans grafiği Şekil 2.12’de gösterilmektedir [14].



**Şekil 2.12.** Frekansa bağımlı platformların yaydığı sualtı gürültü grafiği.

#### 2.4.2. Çevresel Gürültüler

Çevresel gürültü, çok yönlü bir sensör tarafından alınan ve sensörün kendisinden veya monte edilme şeklinden kaynaklanmayan sestir. Ortam gürültüsü hem doğal hem de antropojenik birçok kaynağın katkılarından oluşur.

Ortam gürültüsü genellikle üç bileşen tipinden oluşur. Bunlar geniş bant sürekli gürültü, tonlar ve dürtüsel gürültülerdir. Dürtüsel gürültü doğası gereği geçicidir ve genellikle geniş bant genişliğinde ve kısa sürelidir. Sürekli geniş bant gürültüsü, normalde 1 Hz. bant genişliğindeki seviye olan bir spektrum seviyesi olarak karakterize edilir. Ortam gürültüsü, 1 Hz'in altından 100 kHz'in çok üstüne kadar tüm akustik spektrumunu kapsar [15].

**Tablo 2.2.** Çevresel Gürültüler.

Frekans	Çevresel Gürültü Tipleri
DC – 1 Hz	Sismik, Hidrostatik
1 – 20 Hz	Okyanus Türbülansı
20 – 500 Hz	Uzak Trafik Gürültüsü
500 – 5000 Hz	Yüzey Gürültüsü
5000 Hz	Isıl Gürültü

## 2.5. Veri Setleri

Bu tez çalışması kapsamında açık kaynak veri setleri kullanılmaktadır. Araştırmacılar sualtı akustik veri setlerine askeri gizlilik kapsamında açık kaynak olarak ulaşamamaktadır. Sualtı akustik veri setleri oluşturulmasında kaynak, zaman, araştırmacı bilgi birikim ve tecrübesi sebeplerinden dolayı oldukça maliyetlidir. Açık kaynak verilere ulaşma kısıtlı olması sebebiyle araştırmacılar kendi verileri üreterek sentetik veriler ya da kendi verilerini toplayarak veri seti oluşturmaktadır. Günümüzde makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak otomatik hedef sınıflandırma algoritmaları ile askeri alanda olduğu gibi sivil alanda da deniz trafiği ve kirliliği vb. yönelik çeşitli deneyler yapılması ile veri setlerine açık kaynak olarak ulaşılmaktadır. Bu çalışma kapsamında literatürde yer alan iki veri seti kullanılmış ve analizler gerçekleştirilmiştir. Literatürde yer alan Santos-Dominguez ve arkadaşlarının 2016 yılında ShipEar [16], Muhammed Irfan ve arkadaşlarının 2021 yılında DeepShip [17] veri setleri araştırmacılar için açık kaynak olarak paylaşılmıştır. Veri setlerine ilişkin detaylı bilgi ve analizler ShipEar için Bölüm 4.1’de, DeepShip için Bölüm 4.2’de gösterilmektedir.

## 2.6. Sınıflandırma Yöntemleri

Tez çalışması kapsamında literatürde yer alan yaygın olarak makine öğreniminde kullanılan sınıflandırma yöntemleri kullanılmıştır. Bu öğrenim, insan zekasını taklit etmek amacıyla geliştirilmiş algoritmalara denir. Makine öğrenimi için en önemli parametrelerden biri veri bilimidir. Veri biliminde, bir veri setine ait sınıfları en iyi

ayrımı gerçekleştirmeye sınıflandırma denilmektedir.

Sualtı akustik veriler kullanılarak literatürde yer alan ve yaygın olarak kullanılan sınıflandırma yöntemleri SVM, Naive Bayes, En Yakın Komşu (K-NN – ing. K-Nearest Neighbor)’dur.

- Naive Bayes Sınıflandırıcı:

Naive Bayes istatistiksel sınıflandırıcılar içerisinde yer alan temelinde Bayes teoremi içeren yöntemdir. Bayes sınıflandırıcıları, büyük veri setlerine uygulandığında yüksek doğruluk ve hız sergileyerek yaygın olarak kullanılmaktadır. Bayes teoremi koşullu olasılık teoremi prensibine dayanmaktadır. Veriler için olasılıklar hesaplanarak en yüksek olasılığın olduğu değere göre sınıflandırma işlemi gerçekleştirilir. Şekil 2.13’te sınıflandırma teoremi gösterilmektedir.

The diagram illustrates Bayes' Theorem with the following components:

- Top-left: Hipotezin doğru olduğu verili kanıtın olasılığı (Probability of the hypothesis being true given the evidence)
- Top-right: Hipotezin önceki olasılığı (Prior probability of the hypothesis)
- Center: 
$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$$
- Bottom-left: Kanıtın doğru olması durumunda hipotezin sonsal olasılığı (Posterior probability of the hypothesis given the evidence)
- Bottom-right: Kanıtın doğru olduğuna dair ön olasılık (Prior probability of the evidence)


Arrows indicate the flow of information: from the prior probability of the hypothesis to the joint probability, from the prior probability of the evidence to the joint probability, and from the joint probability to the posterior probability of the hypothesis.

Şekil 2.13. Naive Bayes Sınıflandırma.

- Destek Vektör Makinaları (SVM – Support Vector Machine):

Destek Vektör Makinası (SVM), sınıflandırma ve regresyon problemleri için kullanılabilen kontrollü makine öğrenme algoritmasıdır. SVM, ayrı sınıflara ait veri setleri için sınıflar arasındaki ayrımın maksimum olduğu yerlere hiper düzlemler oluşturur. Böylece sınıfları ayırmak için kullanılan en uygun hiper düzlemi öğrenmektedir. SVM algoritmasının çalışma prensibi, eğitim setine en büyük minimum mesafeyi veren hiper düzlemin bulunmasına dayanmaktadır. SVM kendi içinde Lineer Destek Vektör Makineleri, Lineer Olamayan Destek Vektör Makineleri ve Çok Sınıflı


Destek Vektör Makineleri olarak 3'e ayrılmaktadır. Şekil 2.14'te iki sınıfa ait örnek en uygun hiper düzlem ile ayrılmış maksimum ayırım gösterimi yer almaktadır.



Şekil 2.14. SVM Maksimum ayırım gösterimi.

- KNN (K Nearest Neighbours) Sınıflandırıcı:

KNN algoritması ya da diğer adıyla En Yakın Komşu algoritması makine öğrenim algoritmaları içerisinde en çok bilinen ve kullanılan algoritmalardan biridir. KNN, veri setinde yer alan nesnelere en yakın komşularının birbirine yakın nesnelere farklı uzaklık metrikleri kullanarak benzer olduğunu tahmin ederek sınıflandırmayı gerçekleştirir. Seçilen bir özelliğin kendine en yakın olan özellikler arasındaki yakınlığı kullanarak sınıflandırma yapılır. K değeri örnek olarak 3, 5 veya 7 gibi bir sayı ile ifade edilmektedir. Eşitlik olmaması içinde K değeri tek sayı olarak belirlenmektedir. Çalışma prensibine göre yeni gelen verinin değeriyle K değeri karşılaştırılmaktadır. Yeni gelen veriyle diğer sınıflandırmadaki veriler arasındaki mesafe ölçümü ise literatürde sıkça karşılaşılan Öklid, Manhattan ve Kosinüs uzaklık ölçüm yöntemleri kullanılmaktadır. Şekil 2.15'te görüldüğü gibi K en yakın komşuluk yöntemi ile H yeni sınıfını en yakın sınıflara olan mesafesini kıyaslayarak sınıflandırma gerçekleştirilir.



**Şekil 2.15.** KNN Sınıflandırıcı.

### **2.7. Sınıflandırma Sonucu Performans Değerlendirme Yöntemi**

Akustik veriler kullanılarak DEMON algoritması sonucu elde edilen veriler öznitelik olarak değerlendirilerek hedeflerin, nesnelerin tespit ve sınıflandırılması performansının ölçülebilmesi gerekmektedir. Performans karşılaştırması gerçekleştirilirken aynı veri setini kullanana farklı algoritmalarla karşılaştırma yapmak önemlidir. Bu sebeple literatürde yer alan yaklaşımlardan yararlanılmaktadır. Bu tez çalışmasında makine öğreniminde denetimli öğrenme için sınıflandırma problemi çözümü aranarak performansı görselleştirmek için karışıklık matrisi kullanılmıştır. Karışıklık matrisi, sınıflandırma algoritmasının performansını görselleştirerek tablo formatında sunmaktadır. Sınıflandırma sonrasında kullanılan yöntemlerin performans değerlendirmelerinde karışıklık matrisi örneği Şekil 2.16'da gösterilmektedir.

	<i>Tahmin Sınıfı</i>	
<i>Doğru Sınıf</i>	Doğru Pozitif (True Positive-TP)	Yanlış Negatif (False Negative-FN)
	Yanlış Pozitif (False Positive-FP)	Doğru Negatif (True Negative-TN)

**Şekil 2.16.** Karışıklık Matrisi.

Karışıklık matrisi, doğru sınıflandırılmış TP değerlerini, başka bir sınıfta olması gerekirken ilgili sınıftaki FP değerlerini, ilgili sınıfta olması gerekirken başka bir sınıftaki FN değerlerini ve diğer sınıftaki doğru sınıflandırılmış TN değerlerini temsil eder. Bu değerlere göre sınıflandırma için en sık kullanılan performans ölçütleri Denklem 2.2’de doğruluk (ACC),

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.1)$$

Denklem 2.3’te kesinlik (P),

$$P = \frac{TP}{TP + FP} \quad (2.2)$$

Denklem 2.4’te duyarlılık (Sn),

$$Sn = \frac{TP}{TP + FN} \quad (2.3)$$

Denklem 2.5’te özgüllük (Sp),

$$Sp = \frac{TN}{TN + FP} \quad (2.4)$$

ve Denklem 2.6’da F-skor değerleri hesaplamaları gösterilmektedir [18].

$$F - Skor = 2 \left( \frac{P \cdot Sn}{P + Sn} \right) \quad (2.5)$$

### 3. DEMON

Gürültüde Genlik Modülasyon Tespit İngilizce Detection Envelope Modulation on Noise kısaca Demodulated Noise kelimelerinin baş harfleriyle oluşturularak DEMON olarak adlandırılır. Bir gemide tespit edilen gürültüler çeşitli kaynaklar vasıtasıyla üretilirler. DEMON tespiti sadece dönen bir pervanenin sebep olduğu kavitasyon gürültüsünü dikkate alır. Kavitasyon gürültüsü sonucu genliklerde meydana gelen frekans değişikliklerinin azami tekrarları DEMON analizi sonucu tespit edilir. Frekansında daha az değişiklik olan geniş band gürültüsünü taşıyıcı frekans olarak kullanır. Farklı frekanstaki ses dalgalarının demodüle edilmiş taşıyıcı dalgalardan ayrılmasıyla spektrum analizi yani DEMONgram'da dar band analizi sonucu sergilenmektedir.

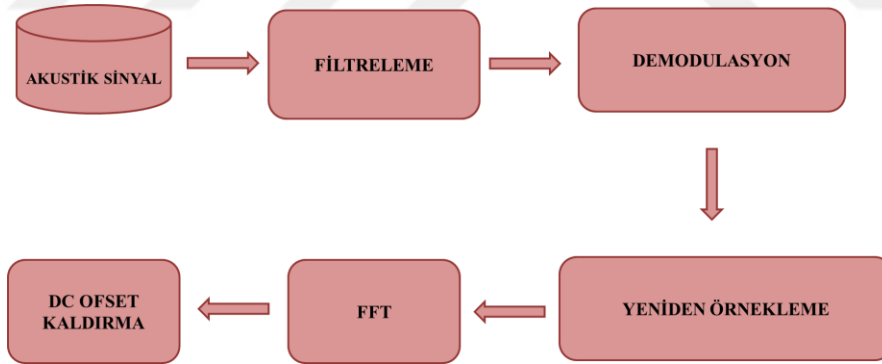
#### 3.1. DEMON Literatür Araştırması

Platformların pervaneleri kaynaklı DEMON hatları düşük frekanslarda ortaya çıkmaktadır ve DEMON algoritması kullanılarak literatürde mevcut çalışmalar arasında benzetim ve kestiriminde sıra istatistiği [19], sürat botlarının akustik imzalarının analizi fiziksel parametreler (şaft ve motor hızı, pervane sayısı ve bıçaklar ve motor ateşleme hızı) detaylı incelemesi [8], DEMON Spektrum analiz teknikleri ve akustik sinyal sınıflandırması için ampirik bilgiye dayalı referans kriteri [20], Stevens Pasif Akustik Sistemi, yüzey gemisi tespitini ve sınıflandırmasını DEMON analizi ile test edilmesi [21] gibi önemli ve güncel çalışmalar arasında yer almaktadır.

DEMON, gürültü üzerinde zarf modülasyonunun algılanması anlamına gelmektedir. Bu işlem, sualtında bulunan nesnelere pasif tespiti için ulaşılabilir en etkili yollardan biridir. Bu analiz, sinyalin zaman alanı modülasyonunun, bant geçiren filtre ile filtrelenerek akustik sualtı sinyalinin hızlı Fourier dönüşümünden tespit edilebileceği uygulamasına dayanmaktadır [22]. DEMON analizi, pervane özelliklerini tespit etmek için kullanılır ve dar bant analizi olan DEMON dar frekans bileşenleri ile gemi

sınıflandırması için kullanılabilir. Bu işleme tekniği, kavitasyon gürültüsünü genel sinyal spektrumundan ayırmaya ve shaft sayısını, dönüş frekansını ve kanatların hızını tahmin etmeye izin verir. Bu teknik, hedef pervane hakkında yeterli bilgi verir ve hedef tespit amacıyla kullanılabilir [23].

Akustik sensörler tarafından kaydedilmiş ve analiz ve incelenmesi gereken birçok ses bileşeni vardır. Hedeflerin imzası olarak kullanılacak ilgili dar bant bölgesinde bulunan düşük frekans ses bileşenlerini seçmek önemlidir. Sualtı ve su üstü savaş platformlarının deniz görevleri angajman, koruma, gözetleme ve refakat görevlerini yerine getirmesi için çevresel kaynaklı dağınk sinyal ortamından hedef imzayı tanımlayan araştırmalardan yararlanılması açısından literatürde mevcut çalışmalardan yararlanılmaktadır. Hedeflere ait parmak izi niteliğinde olan DEMON öznelik olarak değerlendirilmektedir. Bu tekniğin sınırlaması, iyi çalışma becerileri gerektiren bir gürültü bandı seçmede yatmaktadır. Ek olarak, düşük gürültü bağışıklığı bu yöntemin bir başka dezavantajıdır. DEMON işlemenin çıktısı, bir zaman-frekans spektrumu, spektrogramı olan DEMONGRAM'da görselleştirilebilir [24]. Şekil 3.1'de literatürde yer alan genel DEMON algoritmasının akış şeması gösterilmektedir.



**Şekil 3.1.** Literatürde yer alan DEMON algoritması [12].

DEMON analizi aşağıdaki prosedürleri içerir:

- İlgilenilen yön seçimi (Veriniz içinde yön bilgisi içeriyorsa seçim yapılmaktadır fakat Hidrofon ile kaydedilmiş verilerde yön bilgisi tahsis edilemeyeceğini unutmamak gerekir.)
- Sinyalin kavitasyon frekans aralığını kaldırmak için bant geçiren filtreleme
- Sinyalin karesi (Demodulasyon adımıyla içermektedir)

- Arka plan gürültüsünü azaltmak ve hedefi vurgulamak için sinyalin normalleştirilmesi (Normalizasyon adımı aynı zamanda görüntüde uygulanarak DEMONGRAM oluşturulmasında en önemli adımlarda birisidir.)
- Normalleştirilmiş sinyale FFT kullanmak
- DC Ofset kaldırma (Frekans alanında bozulmaları engellemek için kullanılan yöntemdir)

Genel olarak DEMON analizi ve algoritma akışı ile literatürde halihazırda yer alan adımlar yukarıda görülmektedir. Araştırmacıların yapmış olduğu çalışmaların çoğunda açık veri kümesi üzerinde çalışma yapmamışlar ve bu nedenle kıyaslama imkânı bulunmamaktadır. Bu çalışmada ise araştırmacılara açık olan veri setleri kullanılmıştır. Kullanılan veri setleri Bölüm 4'te anlatılmaktadır.

Tablo 3.1'de mevcut açık kaynak olarak ulaşılabilir ShipEar, DeepShip ve gizli veri setleri ile çalışma performansları gösterilmektedir. ShipEar veri setini kullanan,

- Santos, Gaussian Mixture Modelini,
- Yuan, Acoustic, Visual ve Acoustics-Visual,
- Liu, D\_1 + VGG + Acoustic ve D\_1+D2+D3+VGG+acoustic

farklı öznitelik ile denemeler yapmışlar. DeepShip veri setini kullanan Irfan ise,

- Mel-spectrogram,
- CQT,
- MFCC,
- Wavelets,
- Cepstrum
- Gammatone,

farklı özniteliklerini kullanarak denemeler yapmışlardır. Yapılan çalışmalar incelendiğinde farklı yöntemleri ve farklı öznitelik ile elde ettikleri sonuçları Tablo 3.1'de göstermektedir.

**Tablo 3.1.** Literatürde yer alan çalışmalar.

Veri Seti	Mevcut Çalışmalar	Yöntem	Doğruluk (%)
ShipEar	Santos[16]	Gaussian Mixture Model	75.4
	Yuan [25]	Acoustics	62.51
		Visual	82.82
		Acoustics-Visual	89.75
	Liu [26]	D_1 + VGG + Acoustic	80.0
D_1+D2+D3+VGG+Acoustic		82.0	
DeepShip	Irfan [17]	Mel-spectrogram	70.18
		CQT	77.53
		MFCC	59.58
		Wavelets	59.85
		Cepstrum	73.10
		Gammatone	73.59

Literatür sonucu olarak gürültü zarf modülasyonu tespiti, hedef tarafından üretilen akustik işaretlerin tespiti ve sınıflandırılması için SONAR'da kullanılan bir işleme tekniği DEMON'dur. Bu teknik, deniz aracı pervaneleri tarafından üretilen geniş bant kavitasyon gürültüsünü modüle eden frekansları belirlemek için modülasyon analizini kullanır.

Sualtı hedeflerinin tespiti ve sınıflandırılması, pasif bir sonar alıcısının en önemli görevidir. DEMON, gürültüde zarf modülasyonunun tespiti anlamına gelir ve pervane suda döndüğünde, kavitasyon, pervane dönüş frekansı tarafından gürültünün modülasyonu ile sonuçlanır. Kavitasyon gürültüsü dar bantlı bir gürültüdür ve modülasyon, makine tonunun kapladığı bandın üzerindeki daha düşük bantlarda meydana gelir.

Bölüm 3.3.2'de hesaplama formülleri anlatıldığı gibi örnek olarak literatürde analiz aşağıda sunulmuştur.

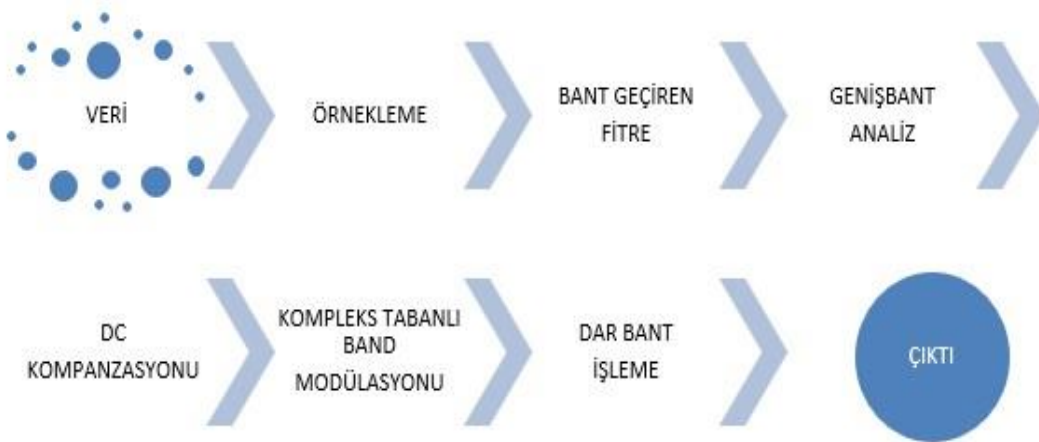
- Şaft hızı: bu şaftın dönme frekansıdır. Örneğin, belirli bir geminin şaft devri dakikada 120 devir ise frekansı  $120/60$  yani 2 Hz'dir. Dolayısıyla iblis ekranında, bu 2Hz'lik bir temel frekans olarak tercüme edilecek ve harmonikler 2Hz'in katları olacaktır. Harmonikler giderek azalır.
- Kanat Hızı: Kanat hızı – Her bir pervane şaftının belirli sayıda kanadı olacaktır.

Şaftın her dönüşü için, bıçak hızı, herhangi bir bıçağın belirli bir noktadan geçme sayısı olacaktır. Bu, kanat sayısı ile çarpılan şaft hızı olacaktır. Örneğimizde, şaftın üç pervane kanadı varsa, kanat hızı  $2*3$  yani 6Hz olacaktır. Kanat frekansı, şaft frekansına kıyasla daha yoğun olacaktır

- Şaft Sayısı: Makine ne kadar bakımlı olursa olsun, aynı devirde (dakikadaki devir sayısı) birden fazla şaftı döndürmek mümkün değildir. Örneğin yukarıdaki örnekte geminin iki şaftı varsa, sıralanan rpm 120 olmasına rağmen 118 rpm ve 122 rpm'de dönebilirler. Böylece şaft hızı 1.96 Hz ve 2.03 Hz olur ve yakın aralıklı olarak gösterilir. Ekranda oluşan çift hatlar daha sonraki harmoniklerde frekans ayrımı arttıkça ikili oluşumu daha belirgin olacaktır. DEMON işlemcinin 1,96 Hz ve 2,03 Hz'yi iki farklı frekans olarak çözmek için yeterli çözünürlüğe sahip olması gerektiğine dikkat edilmelidir [27].

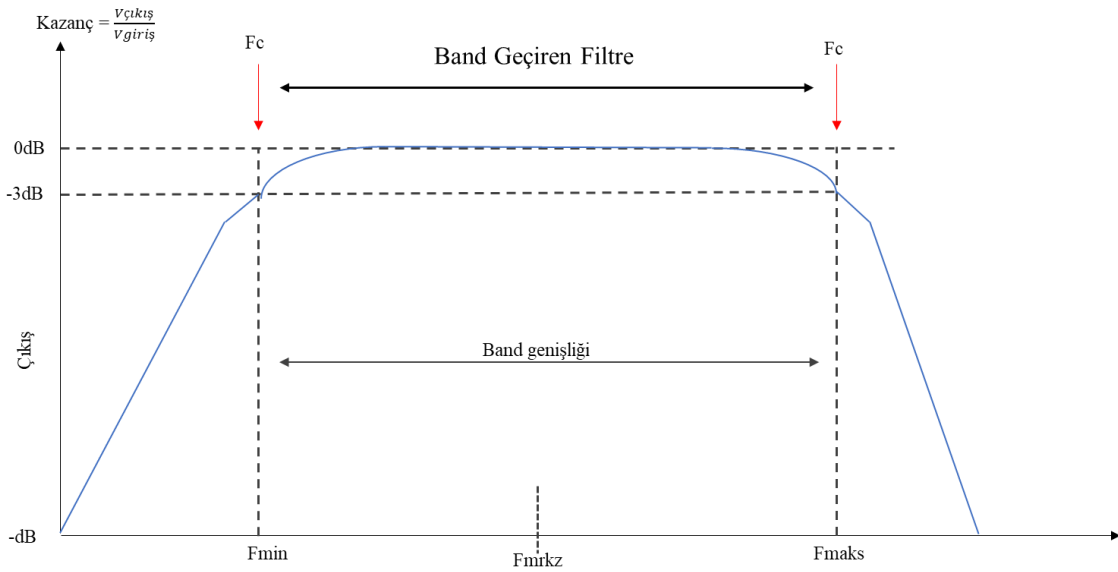
### 3.2. DEMON Algoritması ve Akış Şeması

Tez çalışması kapsamında Şekil 3.2'de gösterilen DEMON algoritması gerçekleştirilmiştir. Literatür çalışmasında yer alan klasik DEMON algoritmalarından ziyade yenilikçi bir DEMON algoritması oluşturularak SONAR sistemlerine entegre edilebilecek hızlı ve yüksek örnekleme frekansına sahip verileri iş yükünü azaltıcı şekilde akustik sinyal işleme adımları kullanılmıştır.



Şekil 3.2. DEMON Algoritması Akış Şeması

- **Örnekleme:** Kullanılan sistemlerdeki veri setlerinde örnekleme frekanslarının farklı olması ve veri boyutlarının büyük olmasından dolayı veri ilk olarak resample işleme uygulanmıştır. Bu şekilde veriler bir standart haline getirilmiştir.
- **Bant Geçiren Filtre:** Geleneksel olarak, gemi gürültüsü, envelope analizinden önce farklı frekans bantlarında bant geçiren filtreden geçirilir. Şekil 3.3'te gösterilen bant geçirilen filtre, frekansları belirli bir aralıkta ileten ve o aralığında dışındaki frekansları zayıflatan bir filtredir.



**Şekil 3.3.** Bant Geçiren Filtre.

- **DC Kompanzasyonu:** Dalga formunun ortalama genliği sıfır olmadığında bir sinyalin DC ofset bozulmasına sahip olduğunu tespit ediyoruz. Normal bir ses, yüksek tepe noktasının düşük tepe noktasına eşit olduğu simetrik bir sinüs sinyalidir. DC kayması olması durumunda sinüs sinyali simetrik değildir ve zaman içindeki ortalama sıfır değildir. Ayrıca, sinyal sessizlik dönemlerinde de sıfır değildir. Bir ses sinyalinin dalga biçimine bakarken bir DC kaymasını fark etmek çok kolaydır. Şekil 3.4'te dalga formu örneğinde, DC kaymalı sinyalin hem konuşma alanlarında hem de sessiz alanlarda ortanın biraz altında görüldüğünü görebilirsiniz. DC kompanzasyonu ile sinyal de anomali tespiti yapılarak, algoritmanın iraksamasını önlenmesi amaçlanmaktadır. Anomali sebebi, analog sinyal dijital değerlere

dönüştürülmeden önce neredeyse her zaman ses zincirinde bir yerde sabit bir voltaj kaymasıdır. Örneğin, voltaj doğrudan hatalı bir ses arabiriminden kaynaklanıyor olabilir veya ses kartına takılı başka bir aygıttan gelebilir. Herhangi bir sapma normalde fark edilemeyecek kadar küçüktür, ancak kusurlu veya düşük kaliteli donanım ile sorun oluşturacak kadar büyük olabilir. Bunun için DC offset düzeltilmesi yapılmıştır. DC kompanzasyonu daha iyi anlaşılması amacıyla bir wav. dosyası Audacity programı ile düzeltilmesi yapıldı. DC offset bulunan kayıt ve DC Offset çıkarıldıktan sonraki ses kaydı Şekil 3.4'te gösterilmektedir.

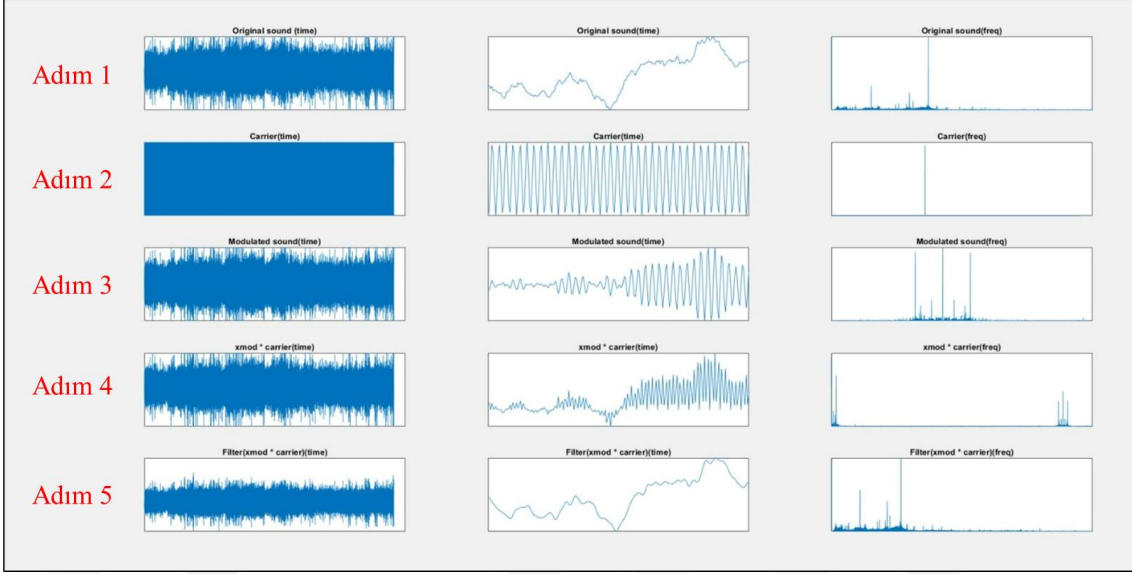


**Şekil 3.4.** Ses Kaydının DC Ofset Uygulanmış Gösterimi.

- **Complex Baseband Modulation:** Bir ses verisinin modüle ve demodüle edilmesidir. Bu kısmı anlatılmasının kolaylaştırmak için bir örnek üzerinden anlatılmaktadır. Complex Baseband Modulation işlemleri için gerçekleştirilen adımlar Şekil 3.5'te gösterilmektedir. DeepShip veri setinin içinden alınan bir wav dosyasında ses verisinden elde edilerek yapılmıştır. Şekil 3.5'te birinci sütunda zaman grafiği, ikinci sütunda ise birinci grafiğin ayrıntılı hali, üçüncü sütunda ise frekans spektrumu gösterilmektedir.

**Tablo 3.2.** Complex Baseband Adımları Şekil 3.4 Açıklanması.

Takip Listesi	Açıklama
<b>Adım 1</b>	Orijinal modüle edilmemiş verilerin grafiğini gösterilmektedir.
<b>Adım 2</b>	Verileri modüle etmek için kullanılacak olan taşıyıcı sinyalin grafiğidir. Bu saf kosinüs sinyalini gösterimidir.
<b>Adım 3</b>	“Sinyal * taşıyıcı” sonucu anlamına gelen modüle edilmiş sinyalin grafiğidir. Spektrum kısmına dikkat edildiğinde sinyal frekansının taşıyıcı frekansı tarafından kaydırıldığı görülmektedir.
<b>Adım 4</b>	Demodülasyon işleminin ilk adımın grafiğidir. Burada, modüle edilmiş sinyalin tekrar taşıyıcı ile çarpılması sonucu elde edilmektedir. Spektrum kısmına bakıldığı zaman spektrumun orijinal sinyalle neredeyse aynı hale geldiği fark edilmektedir.
<b>Adım 5</b>	Demodülasyonun işleminin son çıktısıdır. Bu adımda sinyal, bir alçak geçiren filtre tarafından filtrelenmektedir. Alçak Geçiren filtre uygulanan sinyalin <b>Adım 4</b> ’ün sonucudur.



Şekil 3.5. Complex Baseband Modulation Adımları

### 3.3. SONAR Operatörü DEMON Kullanımı

DEMON bir geniş band gürültüsünün değişimini tespit ve analiz etmek için geliştirilmiştir. DEMON kullanımı için iki şart gerekmektedir. Hedef olan gemiler tarafından taşıyıcı frekans olarak kullanılabilmesi için bir geniş band gürültüsü yaymalıdır ve geniş band gürültüsü maksimum tekrara ulaşmalıdır.

Gemilerin çoğunda geniş band gürültülerinin büyük bir bölümü pervane tarafından üretilir. Dönen pervane kanatları sabit bir şekle sahip olamamaları ve pervane kanatları dönüş yolunu izlerken en alt noktadan en üst noktaya ulaşması esnasında farklı frekanslarda gürültüler üretirler.

Kavitasyon seviyesi pervanenin dönüş hızına bağlı olarak değişmektedir. Pervanenin dönüş hızı arttıkça kavitasyonda artmaktadır. Ayrıca derinliğe bağlı olarak kavitasyon değişecek bu hıza göre ters orantılı olarak derinlik arttıkça kavitasyon azalmakta fakat derinlik azaldıkça kavitasyon artmaktadır. Bu yorumlara bağlı olarak yüksek süratli gemilerin sığ sularda olan kavitasyonunun yüksek olması tespitinin daha kolay ve ayırt edici DEMON analizi yorumunu göstermektedir.

SONAR operatörü DEMON analizi ile hedefleri sınıflandırma ve kimliklendirme işlemlerini gerçekleştirmektedir. Bu işlemleri gerçekleştirirken bilgi ve tecrübesine bağlı olarak yorumlama katarak hedefleri sınıflandırmakta ve aşağıda sunulan terimler

ile sonuca ulaşmaktadır. Bu tez çalışması kapsamında DEMON çıktıları kullanılarak sınıflandırma otomatik olarak gerçekleştirilmiş ve SONAR operatörünün yapmakta olduğu işlemler otomatik olarak gerçekleştirilmesi sağlanmaktadır.


### 3.3.1. DEMON Terimleri ve Açıklamaları

Bu bölümde DEMON ile ilgi terimler ve açıklamaları verilmektedir. Bu terimler ile SONAR operatörü hedefe ait bilgiler elde ederek sınıflandırma işlemi gerçekleştirmektedir. Elde edilen bu bilgiler hedefe ait parmak izi olarak değerlendirilerek hedef tespit ve kimliklendirilme işlemi gerçekleştirilmektedir.

- Pervane Şaft Oranı (Propeller Shaft Rate – PSR): Gemi pervanesi dönüşü ile şaft aynı olup pervane şaftının 1 saniye içinde belli bir referans noktasında geçiş sayısı veya kısaca 1 saniyede pervane şaftının dönüş sayısıdır. Pervane şaftının dönüşünden kaynaklı oluşan titreşimler gürültü yaratmaktadır ve bu PSR frekansını meydana getirmektedir.
- Pervane Şaftı Dönüş Sayısı (Propeller Shaft Revolutions – RPM): Pervane şaftının 1 dakika içindeki toplam dönüş sayısıdır. PSR frekansının 60 ile çarpımı sonucu pervane devri (RPM) hesaplanabilmektedir. PSR frekansının doğruluk oranı pervane devrinin bulunmasında en büyük etkidir ve SONAR operatörü için en önemli sınıflandırma parametresi olarak değerlendirilmektedir.
- Kanat Sayısı (Number of Blade – NOB): Pervane üzerindeki toplam kanat sayısıdır.
- Kanat Oranı (Blade Rate – BR): Bir referans noktasından 1 saniyede geçen toplam pervane kanat sayısıdır. Referans noktasından 1 saniye içinde geçen kanat sayısına göre BR frekansı üretilmektedir.
- Bir Deniz Mili İçin Şaft Dönüş Oranı (Turn per Knots – TPK): Bir geminin bir deniz mili mesafeyi gidebilmesi için yapması gereken şaft dönüş sayısının adedi olarak tanımlanmaktadır. Bu değer her gemi için farklı değere sahip olduğu için sınıflandırmada diğer önemli parametreler arasında yer almaktadır.

Şekil 3.6’da Pervane, şaft görüntüsü ve 4 kanat sayısı belirgin olarak gösterilmektedir. Şekilde yer alan pervane şaftının 1 saniye içinde referans noktasından 4 kez döndüğü

varsayılır ise PSR 4 Hz olarak DEMONgram’da gözükmesi beklenir. Aynı zamanda referans noktasından 4 kez dönmesi 4 kanat için 1 saniyede 16 kanatın referans noktasından geçmesi 16 Hz BR frekansını meydana getirecektir.



Şekil 3.6. Gemi Pervane ve Şaft Örneği [28].

### 3.3.2. DEMON Hesaplama Formülleri

DEMON analizi ile DEMONgram’da tespit edilen en önemli parametreler PSR, BR ve NOB’dur. Elde edilen bu parametreler ile SONAR operatörü hedef hakkında bilgi edinerek tecrübe ve bilgisine bağlı olarak sınıflandırma işlemini gerçekleştirmektedir. Bu bölümde PSR, BR ve NOB hesaplamaları gösterilmektedir.

Denklem 3.1 kullanılarak 1200 RPM’e sahip geminin 60 Sn. ’ye bölünmesi ile PSR frekansı 20 Hz olarak hesaplanmaktadır. Ya da DEMONgram üzerinde belirlenen PSR frekans hattının değerine göre tam tersten pervane devri hesaplanabilir.

$$PSR = \frac{RPM}{60} \quad (3.1)$$

DEMONgram üzerinden belirlenen PSR ve BR frekans değerleri ile Denklem 3.2’de gösterilen NOB değeri hesaplanmaktadır.

$$NOB = \frac{BR}{PSR} \quad (3.2)$$


Yukarıda verilen hesaplamalar ile SONAR operatörü ayrıca gemilerin sürat bilgisini elde edebilmektedir. Sınıflandırma sürecinde sürat bilgisi operatöre hedef hakkında bir ipucu vermesini sağlamaktadır. Sürat bilgisi o esnada hedefin ticari, sivil ya da askeri hedef bilgisini yansıtabilmektedir. Denklem 3.3'te TPK değeri bilinen bir geminin sürat bilgisi hesaplaması gösterilmektedir.

$$SÜRAT = \frac{RPM}{TPK} \quad (3.3)$$

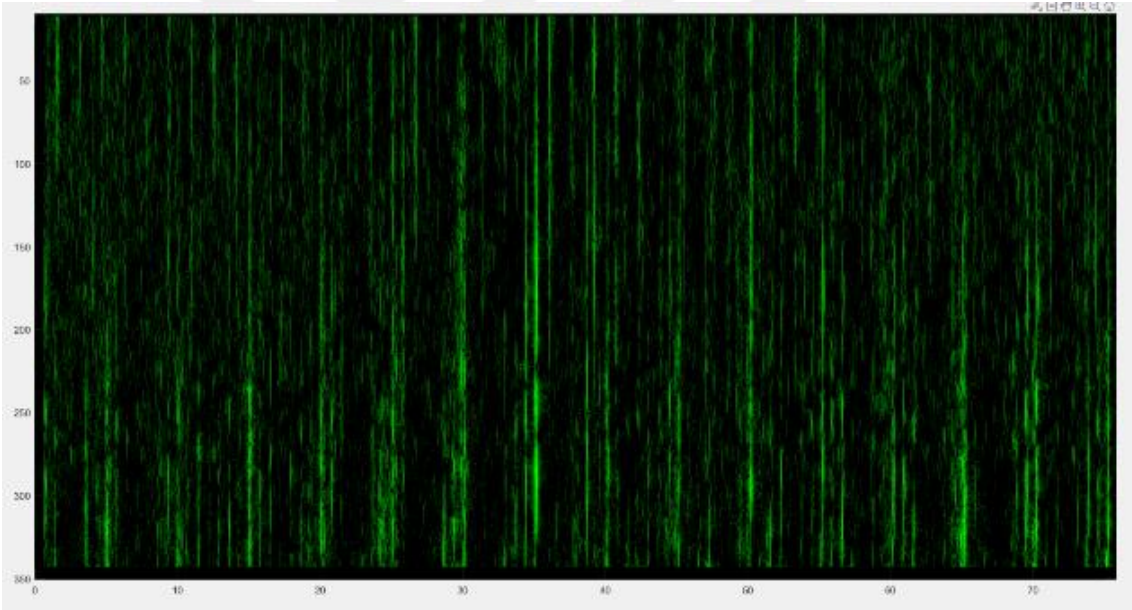
SONAR operatörü DEMONgram üzerinde hedefe ait PSR değerini 2 Hz belirlediği varsayılırsa Denklem 3.1 kullanılarak pervane devri 120 hesaplanmaktadır. TPK değeri 10 olarak bildiği bir hedefin sürat bilgisini Denklem 3.3 kullanarak 12 knots olarak hesaplayabilmektedir.

### 3.3.3. DEMON Görüntüsü Kullanımı

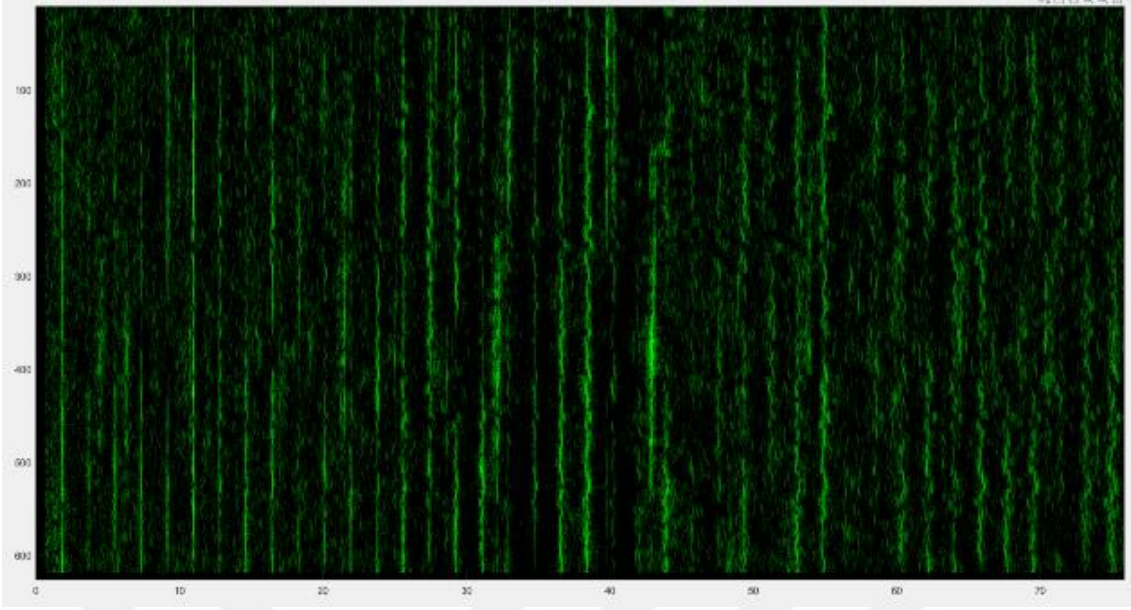
Bölüm 3.2'de yer alan algoritma sonucunda elde edilen DEMON çıktıları kullanılarak oluşturulan DEMONgram görüntüleri aşağıda sunulmuştur. Bu çıktılar sayesinde yukarıda gösterilen DEMON terimleri ve hesaplamaları kullanılarak gemilerin shaft sayısı, pervane kanat adeti ve rpm değerlerine ulaşılabilmektedir. Şekil 3.7-10 sırasıyla Deepship veri setinden alınan 4 tip geminin DEMONgram görüntüleri yatay frekans dikey eksen zamanı gösterilmekte olup farklı tip gemilerin farklı görüntüleri olduğu görülmektedir. Bu sebeple gemi sınıflandırmasında DEMON analizi sonucu çıktıların kullanılması hem SONAR operatörüne karar destek sistemi olarak yardımcı olması hem de otomatik yapması ile önemli bir gemi parmak izi olarak değerlendirilmektedir.




**Şekil 3.7.** Kargo Gemisi DEMON Görüntüsü.



**Şekil 3.8.** Yolcu Gemisi DEMON Görüntüsü.



Şekil 3.9. Tanker Gemisi DEMON Görüntüsü.



Şekil 3.10. Romorkör Gemisi DEMON Görüntüsü.


## 4. AKUSTİK VERİ SETİ

### 4.1. Shipear Veri Toplama ve Analizi

Shipear veri setinin kayıtları, 2012-2013 yılları arasında, kuzeybatı İspanya'daki İspanyol Atlantik kıyılarından farklı bölgelerinden toplanmıştır. Kayıtların genel çoğunluğu, Ria de Vigo'da bulunan Vigo limanında (4214.50 K 00843.40 B) ve

yakında alınmıştır. Bu bölgenin dip derinliği yaklaşık olarak 45 m'dir. Dünyanın en büyük balıkçı limanlarından biridir ve aynı zamanda yoğun mal ve yolcu trafiğine sahiptir. Liman trafiğinin yoğunluğu ve çeşitliliğinden yararlanarak, balıkçı tekneleri, deniz gemileri, çeşitli büyüklükteki feribotlar, konteyner, ro-ros, römorkörler, kılavuz tekneler dahil olmak üzere birçok farklı türdeki geminin (yatlar, küçük yelkenli tekneler vb.) rıhtımdan kaydı yapılmıştır. [16].

Kayıtlar için MarSensing Lda tarafından üretilen Şekil 4.1'de gösterilen digitalHyd SR-1 cihazı kullanılmıştır. Bu kompakt kayıt cihazı, 193,5 dB re 1V/1 uPa nominal hassasiyete ve 1 Hz–28 kHz frekans aralığında alışı yapabilen bir hidrofona içerir. Amplifikatör sınırlama ile, 100 Hz'lik (sığ sularda ortam gürültüsünü en aza indiren) yüksek geçiş kesme frekansına sahip bir ön amplifikatörden ve ardından kullanımdan önce beklenen ses seviyelerine göre ayarlanabilen programlanabilir bir kazanç amplifikatöründen oluşur. Cihaz ayrıca 52734 Hz örnekleme hızına sahip 24 bit A/D sigma-delta dönüştürücü içerir. Veriler, 16 GB'lık bir SD kartta 5 dakika süreli WAV formatındaki dosyalarda saklanır.




Şekil 4.1. digitalHyd SR-1

**Tablo 4.1.** digitalHyd SR-1 Teknik Özellikleri.

Özellikleri	Değeri
Bant Genişliği	1 Hz – 28kHz
Hassasiyeti	- 193,5dBV re. $\mu$ Pa.
Örnekleme Frekansı	52734 Hz
Güç	3.7 Vdc, 3600mAh
Dahili Depolama	256 GB
Maksimum Derinlik	100 m

Hidrofonlar alttan sabitlenmiş ve dikeyliği sağlamak amacıyla bir yüzey şamandırasına bağlanmıştır (Şekil 4.2.). Hidrofonların dipten yüksekliği, bağlama noktasındaki su derinliğine göre seçilmiştir. Mümkün olduğunda, kaydın dinamik aralığını en üst düzeye çıkarmak için farklı derinliklerde ve farklı kazançlara sahip 3 hidrofon kullanıldı. Çok sığ alanlarda (10 m'nin altındaki derinliklerde) 1 veya 2 hidrofon ile kayıtlar yapılmıştır.



**Şekil 4.2.** Hidrofonların Yerleşimi [16].

Kayıtlarda hem antropojenik hem de doğal arka plan gürültüsü ve ayrıca deniz memelileri tarafından ara sıra seslendirmeler mevcuttur. Her kayıt için, hidrofon, hedeflenen geminin sesini mümkün olan en iyi kalitede yakalayacak, yani bu yoğun trafik alanından kaçınılmaz olarak geçen diğer gemilerin ürettiği gürültüyü en aza indirmeye çalışacak şekilde yerleştirilmiştir. Verilerde farklı gemi hızı seslerini ve yavaşma veya yavaşma manevralarına karşılık gelen kavitasyon seslerini yakalamak için rıhtımlardan yerleştirilen hidrofonlar tarafından yapılan kayıtlarla seçilmiştir. Liman altyapısına çarpan dalgalarla açıklanan yüksek arka plan gürültüsü sıklıkla duyulur. Veri tabanına, bu doğal arka plan gürültüsü kaynaklarını daha sonra karakterize etmek amacıyla elde edilen 4 adet rüzgâr, yağmur, dalga ve akıntı sesi kayıt da bulunmaktadır. Kayıtlar, aşırı arka plan gürültüsü, yanıltıcı veya gemi gürültü kaynakları hakkında belirsiz bilgiler içeren kayıtlar ortadan kaldırıldı. Nihai veritabanında 90 kayıt yer aldı.

ID	Name	Type	Pic	Location	Date	H. G. D.	Video	Channel depth	Wind	AIS ID	Distance	Atmospheric and oceanographic data	Duration	Notes
48	Musael boat1	Musael boat		Vigo sea loch - Zone 1 	2019.07.23 12:00:00	(12.242,16,64) (8,5,6,7,7)	0	15	10.5	764	Available	50-100	0:11	Zone 1 - in front of Moais. Recording with better gain without clipping is preferred. Other signals available: 10 signal, for sale.
54	Pirata de Salvora	Passenger		Vigo sea loch - Zone 1 	2019.07.23 12:04:00	(12.242,16,64) (8,5,6,7,7)	0	15	10.5	764	Available	50-100	1:08	Zone 1 - in front of Moais. Recording with better gain without clipping is preferred. Other signals available: 10 signal, leaving the port. Less speed than the other.
58	Sailboat	Sailboat		Vigo sea loch - Zone 1 	2019.07.23 12:20:00	(12.242,16,64) (8,5,6,7,7)	0	15	10.5	764	Available	>100	0:49	Zone 1 - in front of Moais. Recording with better gain without clipping is preferred. Other signals available: 10 signal, red light passing without engine really close. Considerable background noise.

Şekil 4.3. ShipsEar Veritabanındaki Ekran Görüntüsü [16]

Tablo 4.1’de Shipear veri setine ait 90 kayıt süre ve kayıt numaraları gösterilmektedir. 11 tip gemi ve ortam gürültülerinin yer aldığı veri setinde farklı ortam koşullarında Hidrofon ile alınmış kayıtlar mevcuttur.

**Tablo 4.2.** ShipEar Veri Seti Özellikleri.

Gemi Tipi	Kayıt No	Toplam Süre
Dredger	80,93,94,95,96	04:22
Fishboat	73,74,75,76	08:34
Motorboat	21,39,45,26,27,33,50,51,77,79,72,70	16:54
Mussel Boat	46,47,48,49,66	12:10
Natural Ambient Noise	85,86,87,88,89,90,91,92,81,83,82,84	19:00
Ocean Linear	16,24,25,23,69	11:07
Passenger	10,14,6,7,13,11,12,17,8,9,38,40,43,42,41, ,36,34,35,32,54,53,62,63,67,60,65	64:24
Pilot Ship	29,30	02:18
RORO	18,19,20,58,78	25.13
Sailbot	37,56,57	01:51
Trawler	28	02:43
Tugboat	15,31	03:26

Santos ve arkadaşlarının hazırlamış olduğu Shippear veri setini sınıflandırma için gemi boyutuna göre 5 sınıf olarak değerlendirmektedir. Literatürde yer alan [10], [26], [29] çalışmalar incelendiğinde Shippear veri setini gemi boyutuna göre 5 sınıf değerlendirmiş ve Tablo 4.2’de 5 sınıf tablo özellikleri gösterilmektedir.

**Tablo 4.3.** Shippear Gemi Boyutuna göre 5 Sınıf.

Sınıf	Gemi Tipi	Gemi Sayısı
A	Balıkçı tekneleri, troller, midye tekneleri, römorkörler ve taraklar	17
B	Motorlu tekneler, pilot tekneler ve yelkenli tekneler	19
C	Yolcu feribotları	30
D	Okyanus gemileri ve Ro-Ro gemileri	12
E	Arka plan gürültü kayıtları	12

## 4.2. Deepship Veri Toplama ve Analizi

DeepShip adlı veri seti 2016-2018 yılları arasında Kanada'nın en işlek Vancouver limanının yakında toplanmıştır. Veri seti dört sınıfa ait 265 farklı gemiden oluşan 47 saatlik sualtı kayıtlarından oluşan bir sualtı akustik veri setidir. Veri seti, gemi sinyallerinin yanı sıra doğal arka plan gürültüsüne, deniz memelisi gürültüsüne ve insan tarafından başlatılan herhangi bir aktivitenin gürültüsü de bulunmaktadır. Verinin toplandığı bölgenin sualtı tabakası ise, silt ve kum tortularından oluşmaktadır.

Kayıtlar için Ocean Sonic tarafından üretilen Şekil 4.4'te gösterilen icListen AF cihazı kullanılmıştır. icListen AF hidrofona ait teknik özellikler Tablo 4.3'te belirtilmektedir. icListen akıllı hidrofona, 1 Hz bant genişliğine sahip geniş bantlı bir dijital ultra çıkışlı hidrofondur. Ayrıca bu cihazın içinde, ön amplifikatör, filtreler, dönüştürücüler ve veri bağlantı birimleri bulunmaktadır. Bu cihaz sayesinde gerçek zamanlı olarak alınan verileri doğrudan dijital çıkışla işleyebilen kompakt bir cihazdır.



Şekil 4.4. icListen AF Hidrafonu


**Tablo 4.4.** icListen AF Teknik Özellikleri.

Özellikleri	Değeri
Bant Genişliği	1 Hz – 12kHz
Dinamik Menzil	120 dB
Hassasiyeti	- 170dBV re. $\mu$ Pa.
Örnekleme Frekansı	32 kHz
Güç	12-24 Vdc, 0.8W
Çıkış Arayüzü	Ethernet
Dahili Depolama	32 GB
Kasa Mazemesi ve	Plastik – 200m
Maksimum Derinlik	Titanyum – 3500m

Tablo 4.4'te DeepShip veri setine ait gemi tipleri ve kayıt süre gösterilmektedir. 4 farklı gemi tipinin yer aldığı veri setinde farklı ortam koşullarında Hidrofon ile alınmış kayıtlar mevcuttur. Kayıtlar toplanırken Şekil 4.5'te gösterilen konfigürasyon uygulanmış ve hidrofon yaklaşık 140 metre derinliğe yerleştirilmiştir.

**Tablo 4.5.** DeepShip Veri Seti Özellikleri.

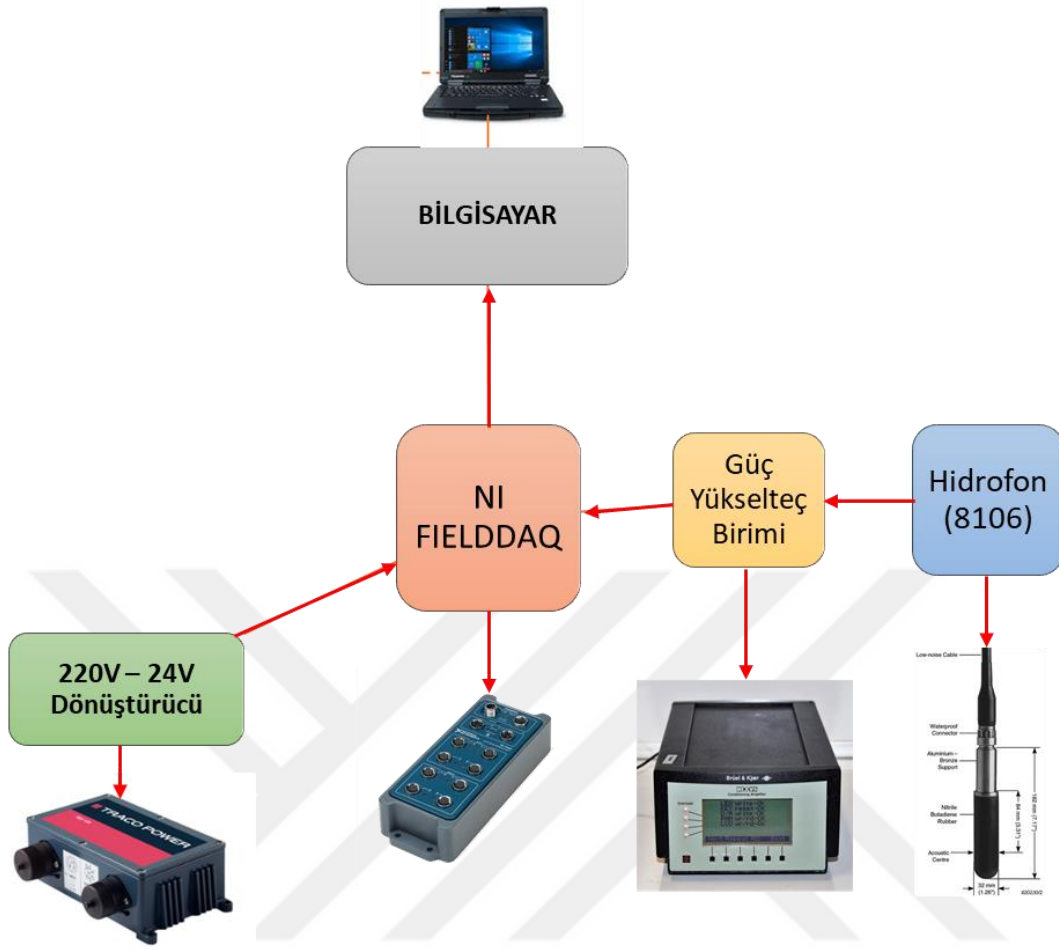
Gemi Tipi	Adet	Toplam Süre	Toplam Kayıt	Süre Başına Kayıt
Kargo Gemisi	69	10 Saat 40 Dk	110	180 – 610 sn
Römorkör	17	11 Saat 17 Dk	70	180 – 1140 sn
Yolcu Gemisi	46	12 Saat 22 Dk	193	06 – 1530 sn
Tanker	133	12 Saat 45 Dk	240	06 – 700 sn




Şekil 4.5. icListen AF hidrofön ile sualtı kayıtları için genel kurulum.

### 4.3. Veri Toplama ve Ön Hazırlık

ShipEar ve DeepShip veri toplama yöntemleri incelenip tez çalışmasında benzer bir sistem kurulumu gerçekleştirilmiştir. Saha çalışmalarına başlanmadan önce test sisteminin oluşturulması ve doğruluğu kontrol edilmesi çalışmaları ile sistem kontrol edilmiştir. Sistem kurulum şeması Şekil 4.6'da, laboratuvar ortamında kurulum Şekil 4.7'de gösterilmektedir.



Şekil 4.6. Sistem kurulum şeması.



Şekil 4.7. Laboratuvar ortamında sistem kurulum şeması.

Veri toplama için; hidrofona (bruel & kjaer 8106), ön yükselteç birimi, NI-Fielddaq, 220V-24V dönüştürücü ve sinyal üretici kullanmıştır. Kullanılan hidrofona teknik özellikleri Tablo 4.5’te verilmiştir.

**Tablo 4.6.** Bruel & Kjaer 8106 Teknik Özellikleri.

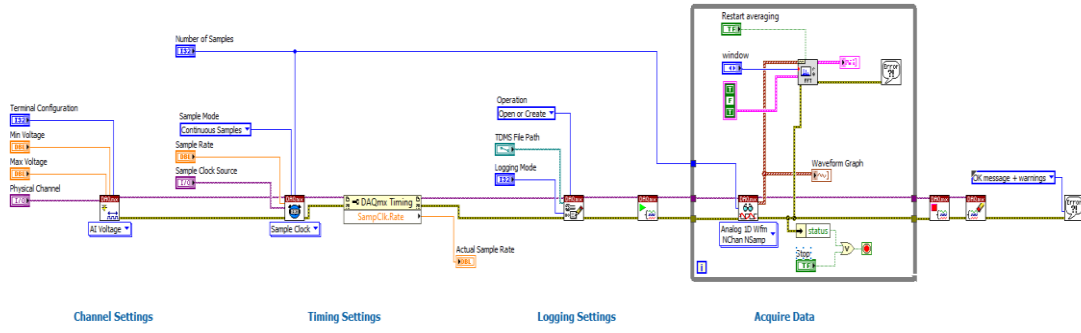
Özellikleri	Değerleri
Frekans Aralığı	3 Hz – 80kHz
Alış Hassasiyeti	-173dB re 1 V/ $\mu$ Pa
Maksimum Derinlik	1000m
Dayanıklı Yapıya Sahip	Evet
Eşdeğer gürültü seviyesi	Deniz durumu sıfırının çok altında

Bilgisayar ile güç yükselteci arasında National Instrument ürünü olan NI-FieldDaq (Şekil 4.8) kullanılmıştır.

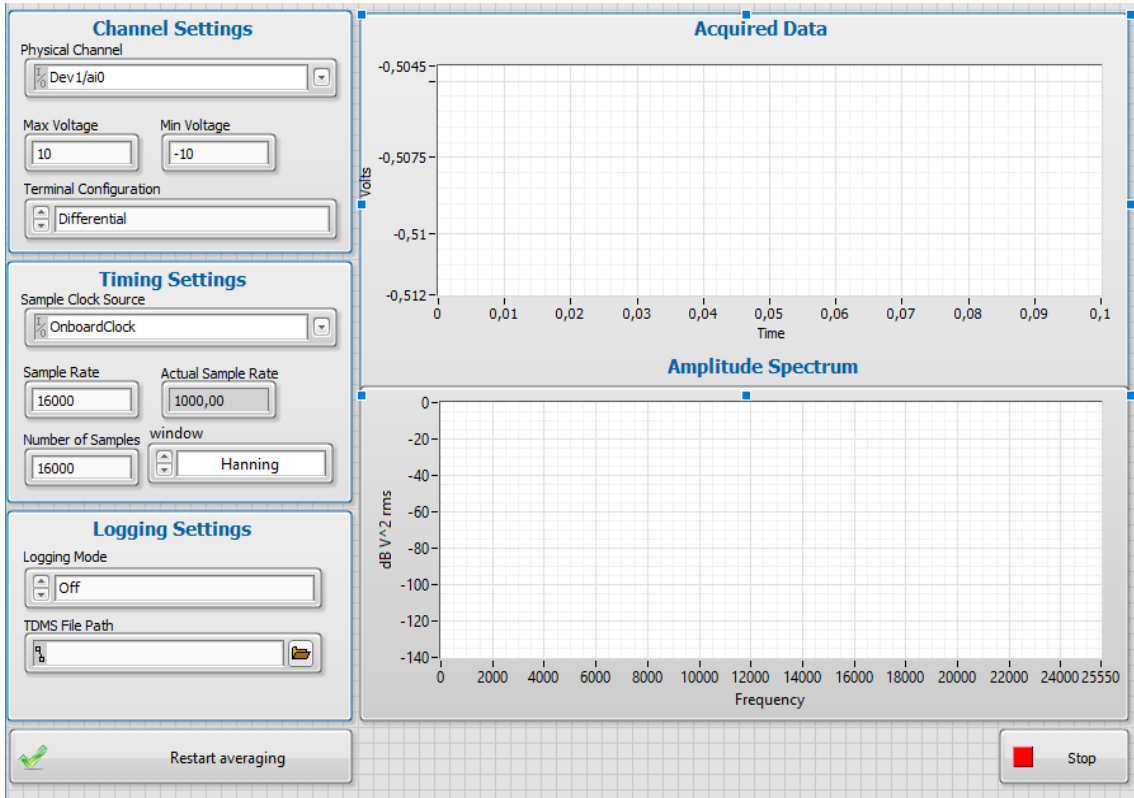


**Şekil 4.8.** National Instrument ürünü NI-FieldDaq

National Instrument ürünü kullanılması sebebiyle Labview arayüzünde kod geliştirilmiştir. Geliştirilen yazılıma ait blok diyagram ve kullanıcı arayüz ekranı şekil 4.9-10’da sunulmuştur.




Şekil 4.9. Labview blok şeması.



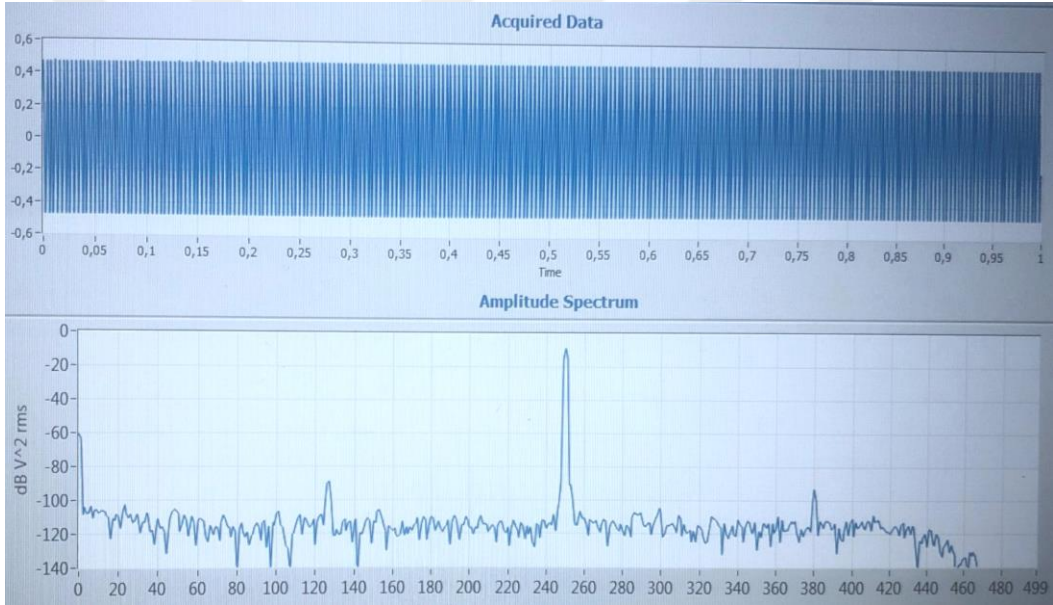
Şekil 4.10. Labview arayüzü.

Sistemin doğruluğu test etmek için ilk senaryo olarak hidrofon ve ön yükselteç kısımları çıkartılarak sistem direk sinyal üreticine bağlanmıştır. Sinyal üreticiden verilen kontrollü sinyaller sonucu yazılımın doğru çalıştığı doğrulanarak Şekil 4.11’de gösterilmektedir.




**Şekil 4.11.** Sinyal üretici ile 250 Hz sinyal üretilmesi.

Şekil 4.11’de sinyal üretici ile kurulan sistem ile Şekil 4.10’da gösterilen labview arayüzü doğrulanarak sistemin çalıştığı gösterilerek Şekil 4.12 elde edilmiştir.




**Şekil 4.12.** Sinyal üretici ile sistemin doğrulanması.

Havuz ortamında hidrofona kontrollü sinyal verilir sistem kontrol edilmiştir. Şekil 4.13’te hidrofona havuza daldırılarak sistemin doğruluğu kontrol edilerek, kayıtlar alınmıştır.



**Şekil 4.13.** Sinyal üretici ile sistemin doğrulanması.

Havuzza daldırılan hidrofona örneklem frekansı 16 kHz olduğu Şekil 4.14'te görülmektedir.



**Şekil 4.14.** Havuz ortamında hidrofona ile sistemin doğrulanması.

#### 4.4. MARMARA-1 Veri Toplama ve Ön Hazırlık

Kurulan sistemin doğruluğu gerçekleştirilerek saha ortamından veriler toplanmıştır. Saha ortamında 220V besleme olmadığı için 12V aküler ile besleme yapılarak sistem kurularak Şekil 4.15'te gösterilmektedir.



Şekil 4.15. Saha ortamında kurulan sistem.

Saha ortamında ticari gemilerin kayıtları alınarak veri seti oluşturulmuştur. Şekil 4.16'da sahadan veri toplanırken kurulan sistem ve konumlandırma işlemi gösterilmektedir.



Şekil 4.16. Saha ortamında veri toplama.

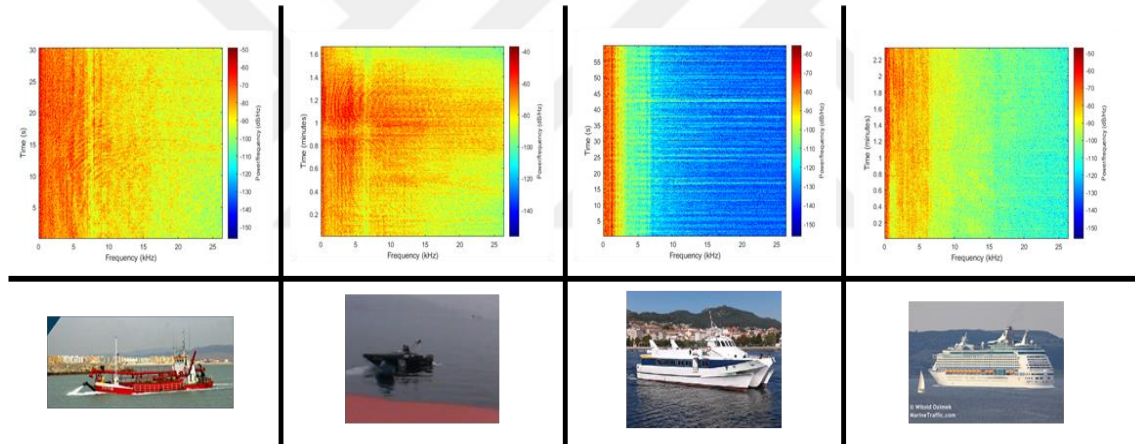
## 5. ANALİZ VE SINIFLANDIRMA SONUÇLARI

Bu bölümde veri setlerine ait analizler ve sonuçları gösterilmektedir. Veri setlerine ait sinyallerin zaman frekans alanında spektrumlarının incelenmesi, güç spektrum yoğunluğu (PSD – ing. Power Spectrum Density) analizi ve sınıflandırma sonuçları karışıklık matrisi gösterimleri yer almaktadır.

### 5.1. Shipear Veri Seti Sonuçları

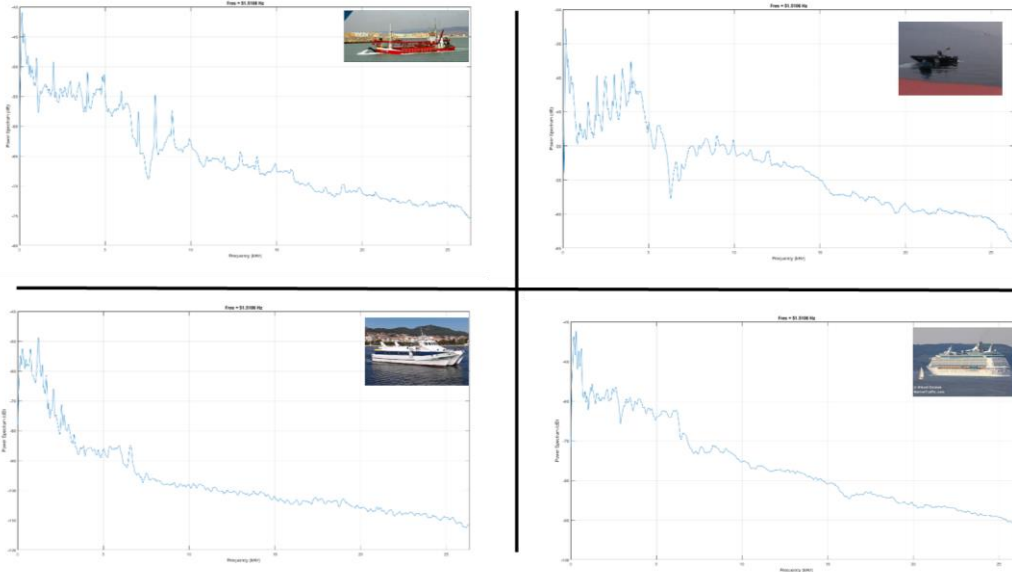
- Frekans – Zaman analizi: Akustik sinyallerin frekans aralıklarının yoğun olduğu bölgeler gözlemlenerek sınıflandırma yapılabileceğini göstergesi olarak akustik sinyallerin spektogramları aşağıda görüldüğü gibidir.

Şekil 5.1’de farklı sınıflara ait gemilerin spektogramı görüntüleri gösterilmektedir.



Şekil 5.1. Shipear veri seti farklı sınıfların spektogramı görüntüsü.

- Güç spektrum yoğunluğu analizi: Gemilerden yayılan gürültülü sinyallerin frekans alanındaki enerji dağılımlarını analiz edilmiştir. Gemilerden yayılan gürültüler ile güç spektrum yoğunluğu analizi ile geminin karakteristik özellikleri hakkında önemli bilgiler elde edilebilir. Şekil 5.2’de görüldüğü üzere farklı gemi sınıflarına ait gemilerin güç spektrumlarının farkı görülmektedir.



**Şekil 5.2.** Shipear veri seti farklı sınıfların güç spektrum yoğunluğu grafiği.

Farklı sınıfların frekans zaman grafiğini ifade edildiği ve frekans dağılımları sınıflandırma için ayırt edici olduğu görülmektedir.

Tablo 5.1’de shipear veri setine ait validasyon başarısı gösterilmektedir. Shipear veri seti farklı sınıflandırıcılar ile test edilmektedir. DEMON verisi öznitelik olarak kullanılarak farklı frekans değerleri arasında ve verilerin farklı uzunlukları birbiriyle karşılaştırılmaktadır.

**Tablo 5.1.** Shipear Sınıflandırma Sonuçları.

Model Tipi	Veri Uzunluğu / Saniye			
	10 Saniye		20 Saniye	
	Frekans Aralıkları / Hz			
	0-76	0-152	0-76	0-152
KNN	%59,8	%71,1	%71,7	%77,7
NN	%59,7	%70,4	%70,4	%74,2
SVM	%59	%68,7	%67,2	%70,9

Tablo 5.2-3-4’te sırasıyla sınıflandırıcı karışıklık matrisleri gösterilmektedir.

**Tablo 5.2.** Shipear KNN Karışıklık Matrisleri.

Sınıflandırma Sonuçları																																																																																																	
<table border="1" style="width: 100%; border-collapse: collapse; text-align: center;"> <thead> <tr> <th colspan="6">Model 2 (Cosine KNN)</th> </tr> </thead> <tbody> <tr> <td rowspan="5" style="writing-mode: vertical-rl; transform: rotate(180deg);">True Class</td> <td>CLASSA</td> <td>73</td> <td>11</td> <td>44</td> <td>14</td> <td>3</td> </tr> <tr> <td>CLASSB</td> <td>16</td> <td>32</td> <td>53</td> <td>11</td> <td>7</td> </tr> <tr> <td>CLASSC</td> <td>30</td> <td>23</td> <td>250</td> <td>23</td> <td>7</td> </tr> <tr> <td>CLASSD</td> <td>26</td> <td>7</td> <td>41</td> <td>116</td> <td></td> </tr> <tr> <td>CLASSE</td> <td>7</td> <td>3</td> <td>15</td> <td>8</td> <td>48</td> </tr> <tr> <td></td> <td>CLASSA</td> <td>CLASSB</td> <td>CLASSC Predicted Class</td> <td>CLASSD</td> <td>CLASSE</td> <td></td> </tr> </tbody> </table>					Model 2 (Cosine KNN)						True Class	CLASSA	73	11	44	14	3	CLASSB	16	32	53	11	7	CLASSC	30	23	250	23	7	CLASSD	26	7	41	116		CLASSE	7	3	15	8	48		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE		<table border="1" style="width: 100%; border-collapse: collapse; text-align: center;"> <thead> <tr> <th colspan="6">Model 2 (Cosine KNN)</th> </tr> </thead> <tbody> <tr> <td rowspan="5" style="writing-mode: vertical-rl; transform: rotate(180deg);">True Class</td> <td>CLASSA</td> <td>89</td> <td>6</td> <td>38</td> <td>7</td> <td>5</td> </tr> <tr> <td>CLASSB</td> <td>5</td> <td>37</td> <td>59</td> <td>4</td> <td>14</td> </tr> <tr> <td>CLASSC</td> <td>7</td> <td>21</td> <td>294</td> <td>4</td> <td>7</td> </tr> <tr> <td>CLASSD</td> <td>4</td> <td>8</td> <td>39</td> <td>138</td> <td>1</td> </tr> <tr> <td>CLASSE</td> <td>3</td> <td>2</td> <td>17</td> <td></td> <td>59</td> </tr> <tr> <td></td> <td>CLASSA</td> <td>CLASSB</td> <td>CLASSC Predicted Class</td> <td>CLASSD</td> <td>CLASSE</td> <td></td> </tr> </tbody> </table>					Model 2 (Cosine KNN)						True Class	CLASSA	89	6	38	7	5	CLASSB	5	37	59	4	14	CLASSC	7	21	294	4	7	CLASSD	4	8	39	138	1	CLASSE	3	2	17		59		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE	
Model 2 (Cosine KNN)																																																																																																	
True Class	CLASSA	73	11	44	14	3																																																																																											
	CLASSB	16	32	53	11	7																																																																																											
	CLASSC	30	23	250	23	7																																																																																											
	CLASSD	26	7	41	116																																																																																												
	CLASSE	7	3	15	8	48																																																																																											
	CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE																																																																																												
Model 2 (Cosine KNN)																																																																																																	
True Class	CLASSA	89	6	38	7	5																																																																																											
	CLASSB	5	37	59	4	14																																																																																											
	CLASSC	7	21	294	4	7																																																																																											
	CLASSD	4	8	39	138	1																																																																																											
	CLASSE	3	2	17		59																																																																																											
	CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE																																																																																												
KNN 0-76 Hz (10 Saniye)					KNN 0-152 Hz (10 Saniye)																																																																																												
<table border="1" style="width: 100%; border-collapse: collapse; text-align: center;"> <thead> <tr> <th colspan="6">Model 1 (Wide Neural Network)</th> </tr> </thead> <tbody> <tr> <td rowspan="5" style="writing-mode: vertical-rl; transform: rotate(180deg);">True Class</td> <td>CLASSA</td> <td>73</td> <td>12</td> <td>24</td> <td>16</td> <td>1</td> </tr> <tr> <td>CLASSB</td> <td>8</td> <td>26</td> <td>50</td> <td>11</td> <td>1</td> </tr> <tr> <td>CLASSC</td> <td>21</td> <td>16</td> <td>243</td> <td>11</td> <td>3</td> </tr> <tr> <td>CLASSD</td> <td>12</td> <td>3</td> <td>24</td> <td>140</td> <td></td> </tr> <tr> <td>CLASSE</td> <td>2</td> <td>4</td> <td>5</td> <td>2</td> <td>55</td> </tr> <tr> <td></td> <td>CLASSA</td> <td>CLASSB</td> <td>CLASSC Predicted Class</td> <td>CLASSD</td> <td>CLASSE</td> <td></td> </tr> </tbody> </table>					Model 1 (Wide Neural Network)						True Class	CLASSA	73	12	24	16	1	CLASSB	8	26	50	11	1	CLASSC	21	16	243	11	3	CLASSD	12	3	24	140		CLASSE	2	4	5	2	55		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE		<table border="1" style="width: 100%; border-collapse: collapse; text-align: center;"> <thead> <tr> <th colspan="6">Model 2 (Cosine KNN)</th> </tr> </thead> <tbody> <tr> <td rowspan="5" style="writing-mode: vertical-rl; transform: rotate(180deg);">True Class</td> <td>CLASSA</td> <td>82</td> <td>7</td> <td>26</td> <td>6</td> <td>5</td> </tr> <tr> <td>CLASSB</td> <td>3</td> <td>45</td> <td>35</td> <td>6</td> <td>7</td> </tr> <tr> <td>CLASSC</td> <td>4</td> <td>17</td> <td>269</td> <td>1</td> <td>3</td> </tr> <tr> <td>CLASSD</td> <td>3</td> <td>5</td> <td>30</td> <td>141</td> <td></td> </tr> <tr> <td>CLASSE</td> <td>1</td> <td>2</td> <td>9</td> <td></td> <td>56</td> </tr> <tr> <td></td> <td>CLASSA</td> <td>CLASSB</td> <td>CLASSC Predicted Class</td> <td>CLASSD</td> <td>CLASSE</td> <td></td> </tr> </tbody> </table>					Model 2 (Cosine KNN)						True Class	CLASSA	82	7	26	6	5	CLASSB	3	45	35	6	7	CLASSC	4	17	269	1	3	CLASSD	3	5	30	141		CLASSE	1	2	9		56		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE	
Model 1 (Wide Neural Network)																																																																																																	
True Class	CLASSA	73	12	24	16	1																																																																																											
	CLASSB	8	26	50	11	1																																																																																											
	CLASSC	21	16	243	11	3																																																																																											
	CLASSD	12	3	24	140																																																																																												
	CLASSE	2	4	5	2	55																																																																																											
	CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE																																																																																												
Model 2 (Cosine KNN)																																																																																																	
True Class	CLASSA	82	7	26	6	5																																																																																											
	CLASSB	3	45	35	6	7																																																																																											
	CLASSC	4	17	269	1	3																																																																																											
	CLASSD	3	5	30	141																																																																																												
	CLASSE	1	2	9		56																																																																																											
	CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE																																																																																												
KNN 0-76 Hz (20 Saniye)					KNN 0-152 Hz (20 Saniye)																																																																																												

**Tablo 5.3.** Shipear NN Karışıklık Matrisleri.

Sınıflandırma Sonuçları																																																																																																	
<table border="1" style="width: 100%; border-collapse: collapse; text-align: center;"> <thead> <tr> <th colspan="6">Model 3 (Wide Neural Network)</th> </tr> </thead> <tbody> <tr> <td rowspan="5" style="writing-mode: vertical-rl; transform: rotate(180deg);">True Class</td> <td>CLASSA</td> <td>63</td> <td>13</td> <td>41</td> <td>25</td> <td>3</td> </tr> <tr> <td>CLASSB</td> <td>13</td> <td>42</td> <td>47</td> <td>11</td> <td>6</td> </tr> <tr> <td>CLASSC</td> <td>34</td> <td>33</td> <td>228</td> <td>28</td> <td>10</td> </tr> <tr> <td>CLASSD</td> <td>15</td> <td>8</td> <td>33</td> <td>132</td> <td>2</td> </tr> <tr> <td>CLASSE</td> <td>3</td> <td>7</td> <td>12</td> <td>6</td> <td>53</td> </tr> <tr> <td></td> <td>CLASSA</td> <td>CLASSB</td> <td>CLASSC Predicted Class</td> <td>CLASSD</td> <td>CLASSE</td> <td></td> </tr> </tbody> </table>					Model 3 (Wide Neural Network)						True Class	CLASSA	63	13	41	25	3	CLASSB	13	42	47	11	6	CLASSC	34	33	228	28	10	CLASSD	15	8	33	132	2	CLASSE	3	7	12	6	53		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE		<table border="1" style="width: 100%; border-collapse: collapse; text-align: center;"> <thead> <tr> <th colspan="6">Model 3 (Wide Neural Network)</th> </tr> </thead> <tbody> <tr> <td rowspan="5" style="writing-mode: vertical-rl; transform: rotate(180deg);">True Class</td> <td>CLASSA</td> <td>84</td> <td>9</td> <td>26</td> <td>19</td> <td>7</td> </tr> <tr> <td>CLASSB</td> <td>16</td> <td>35</td> <td>46</td> <td>12</td> <td>10</td> </tr> <tr> <td>CLASSC</td> <td>14</td> <td>29</td> <td>264</td> <td>19</td> <td>7</td> </tr> <tr> <td>CLASSD</td> <td>8</td> <td>10</td> <td>25</td> <td>145</td> <td>2</td> </tr> <tr> <td>CLASSE</td> <td>3</td> <td>6</td> <td>12</td> <td>5</td> <td>55</td> </tr> <tr> <td></td> <td>CLASSA</td> <td>CLASSB</td> <td>CLASSC Predicted Class</td> <td>CLASSD</td> <td>CLASSE</td> <td></td> </tr> </tbody> </table>					Model 3 (Wide Neural Network)						True Class	CLASSA	84	9	26	19	7	CLASSB	16	35	46	12	10	CLASSC	14	29	264	19	7	CLASSD	8	10	25	145	2	CLASSE	3	6	12	5	55		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE	
Model 3 (Wide Neural Network)																																																																																																	
True Class	CLASSA	63	13	41	25	3																																																																																											
	CLASSB	13	42	47	11	6																																																																																											
	CLASSC	34	33	228	28	10																																																																																											
	CLASSD	15	8	33	132	2																																																																																											
	CLASSE	3	7	12	6	53																																																																																											
	CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE																																																																																												
Model 3 (Wide Neural Network)																																																																																																	
True Class	CLASSA	84	9	26	19	7																																																																																											
	CLASSB	16	35	46	12	10																																																																																											
	CLASSC	14	29	264	19	7																																																																																											
	CLASSD	8	10	25	145	2																																																																																											
	CLASSE	3	6	12	5	55																																																																																											
	CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE																																																																																												
NN 0-76 Hz (10 Saniye)					NN 0-152 Hz (10 Saniye)																																																																																												

Model 1 (Wide Neural Network)						Model 3 (Wide Neural Network)							
True Class	CLASSA	73	12	24	16	1	True Class	CLASSA	78	9	18	19	2
	CLASSB	8	26	50	11	1		CLASSB	9	30	41	13	3
	CLASSC	21	16	243	11	3		CLASSC	14	11	259	6	5
	CLASSD	12	3	24	140			CLASSD	8	5	19	147	
	CLASSE	2	4	5	2	55		CLASSE		2	12	1	53
		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE			CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE
NN 0-76 Hz (20 Saniye)						NN 0-152 Hz (20 Saniye)							

**Tablo 5.4.** Shipear SVM Karışıklık Matrisleri.

Sınıflandırma Sonuçları													
True Class	Model 1 (Quadratic SVM)						Model 1 (Quadratic SVM)						
	CLASSA	48	9	58	28	2	CLASSA	75	4	44	20	2	
	CLASSB	6	26	82	5		CLASSB	12	32	63	10	2	
	CLASSC	17	13	281	20	2	CLASSC	7	12	309	5		
	CLASSD	8	7	50	125		CLASSD	8	6	38	138		
CLASSE	4	3	38	4	32	CLASSE	3	1	32	3	42		
		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE			CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE
SVM 0-76 Hz (10 Saniye)						SVM 0-152 Hz (10 Saniye)							
True Class	Model 1 (Quadratic SVM)						Model 1 (Quadratic SVM)						
	CLASSA	56	6	49	15		CLASSA	65	5	36	20		
	CLASSB	1	13	75	7		CLASSB	3	18	63	9	3	
	CLASSC	6	3	281	4		CLASSC	2	6	283	3		
	CLASSD	4	3	39	133		CLASSD	3	3	35	138		
CLASSE	1		37		30	CLASSE		1	30		37		
		CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE			CLASSA	CLASSB	CLASSC Predicted Class	CLASSD	CLASSE
SVM 0-76 Hz (20 Saniye)						SVM 0-152 Hz (20 Saniye)							

## TEST SONUÇLARI

Shipear veri seti test sonuçları Tablo 5.5'te gösterilmektedir. Farklı sınıflandırıcılarda farklı veri uzunlukları olan 10 sn ve 20 sn veriler ve farklı frekans aralıklarında test edilerek başarı doğrulukları elde edilmiştir. Tablo 5.5'te görüldüğü üzere KNN sınıflandırıcı 0-152 Hz frekans aralığında 20 sn veriler kullanılarak en yüksek başarı olan %79,58 elde edilmektedir.

**Tablo 5.5.** Shipear Sınıflandırma Sonuçları.

Model Tipi	Veri Uzunluğu / Saniye			
	10 Saniye		20 Saniye	
	Frekans Aralıkları / Hz			
	0-76	0-152	0-76	0-152
KNN	%58,37	%76,08	%73,30	%79,58
NN	%63,64	%72,25	%72,77	%76,44
SVM	%59,33	%68,42	%65,97	%73,30

EarShip çalışması kapsamında en iyi sonucun KNN ulaşılmıştır. En iyi sonucun sonuçları Tablo-5.6'da detaylandırılmıştır.

**Tablo 5.6.** Shipear 20 sn 0-152Hz Verisi KNN Sonuçları

İSİM	SINIF				
	A	B	C	D	E
Doğru Pozitif	23	12	66	36	15
Yanlış Pozitif	9	12	7	9	2
Yanlış Negatif	1	7	21	3	7
Doğru Negatif	158	160	97	143	167
Hassasiyet	0,71875	0,5	0,90411	0,8	0,88235
Duyarlılık	0,95833	0,63158	0,75862	0,92308	0,68182
Özgüllük	0,94611	0,93023	0,93269	0,94079	0,98817
Doğruluk	0,79581	0,79581	0,79581	0,79581	0,79581
F-Skor	0,82143	0,5581	0,825	0,85714	0,76923

Tablo 5.7-8-9'da shipear veri setine ait validasyon karışıklık matrisleri gösterilmektedir. Shipear veri seti farklı sınıflandırıcılar ile test edilmektedir. DEMON verisi öznitelik olarak kullanılarak farklı frekans değerleri arasında ve verilerin farklı uzunlukları birbiriyle karşılaştırılmaktadır.

**Tablo 5.7.** Shipear KNN Karışıklık Matrisleri.

Sınıflandırma Sonuçları													
True Class	CLASSA	18	1	14	3		CLASSA	24	6	5	1		
	CLASSB	5	7	13	2	1	CLASSB	1	12	11	1	3	
	CLASSC	9	1	60	8	2	CLASSC	1	2	73		4	
	CLASSD	10	1	8	26		CLASSD		2	6	35	2	
	CLASSE	4		3	2	11	CLASSE			5		15	
		Predicted Class							Predicted Class				
KNN 0-76 Hz (10 Saniye)					KNN 0-152 Hz (10 Saniye)								
True Class	CLASSA	26	1	5			CLASSA	23	1	7	1		
	CLASSB	2	12	6	1	3	CLASSB	1	12	6	1	4	
	CLASSC	5	8	54		6	CLASSC		3	66	1	3	
	CLASSD	2	2	7	34		CLASSD		3	6	36		
	CLASSE		1	2		14	CLASSE			2		15	
		Predicted Class							Predicted Class				
KNN 0-76 Hz (20 Saniye)					KNN 0-152 Hz (20 Saniye)								

**Tablo 5.8.** Shipear NN Karışıklık Matrisleri.

Sınıflandırma Sonuçları													
True Class	CLASSA	19	4	6	6	1	CLASSA	24	3	2	6	1	
	CLASSB	1	12	10	4	1	CLASSB	4	12	8	2	2	
	CLASSC	8	7	58	6	1	CLASSC	4	4	67	5		
	CLASSD	4	5	6	30		CLASSD	4	3	4	33	1	
	CLASSE	1	3	1	1	14	CLASSE		1	2	2	15	
		Predicted Class							Predicted Class				
NN 0-76 Hz (10 Saniye)					NN 0-152 Hz (10 Saniye)								

True Class	CLASSA	23	2	4	3		True Class	CLASSA	20	4	6	1	1
	CLASSB	2	7	13	2			CLASSB	4	8	9	1	2
	CLASSC	4	1	59	7	2		CLASSC	2	1	67	2	1
	CLASSD	4		7	34			CLASSD	4		4	37	
	CLASSE		1			16		CLASSE	1	1	1		14
		CLASSA	CLASSB	CLASSC	CLASSD	CLASSE			CLASSA	CLASSB	CLASSC	CLASSD	CLASSE
		Predicted Class							Predicted Class				
NN 0-76 Hz (20 Saniye)							NN 0-152 Hz (20 Saniye)						

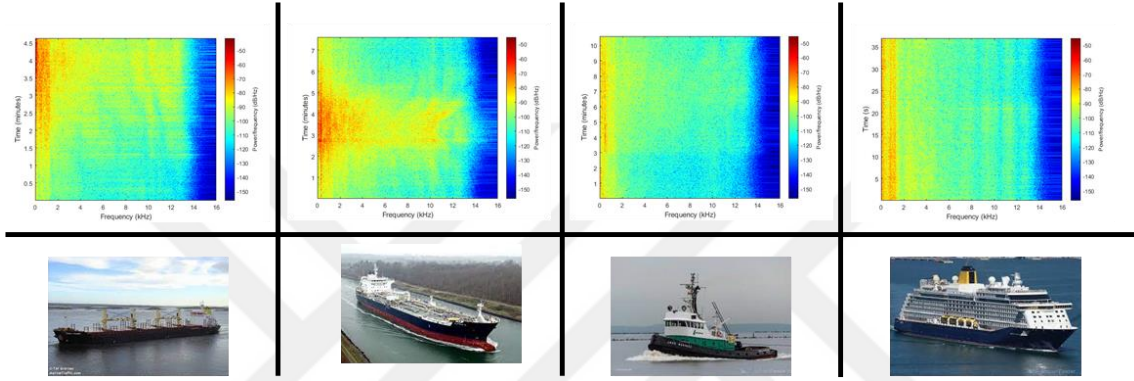
**Tablo 5.9.** Shipear SVM Karışıklık Matrisleri.

Sınıflandırma Sonuçları													
True Class	CLASSA	16	1	14	5		True Class	CLASSA	23	2	6	5	
	CLASSB	1	4	20	3			CLASSB	3	8	14	2	1
	CLASSC	5	7	64	4			CLASSC	4	2	72	2	
	CLASSD	3	1	9	32			CLASSD	4	1	11	29	
	CLASSE	1	2	8	1	8		CLASSE			9		11
		CLASSA	CLASSB	CLASSC	CLASSD	CLASSE			CLASSA	CLASSB	CLASSC	CLASSD	CLASSE
		Predicted Class							Predicted Class				
SVM 0-76 Hz (10 Saniye)							SVM 0-152 Hz (10 Saniye)						
True Class	CLASSA	18		10	4		True Class	CLASSA	22	2	7	1	
	CLASSB	2	2	19	1			CLASSB	1	5	16	1	1
	CLASSC	1		69	3			CLASSC		1	69	3	
	CLASSD	2	1	14	28			CLASSD		1	12	32	
	CLASSE		1	7		9		CLASSE			5		12
		CLASSA	CLASSB	CLASSC	CLASSD	CLASSE			CLASSA	CLASSB	CLASSC	CLASSD	CLASSE
		Predicted Class							Predicted Class				
SVM 0-76 Hz (20 Saniye)							SVM 0-152 Hz (20 Saniye)						

## 5.2. Deepship Veri Seti Sonuçları

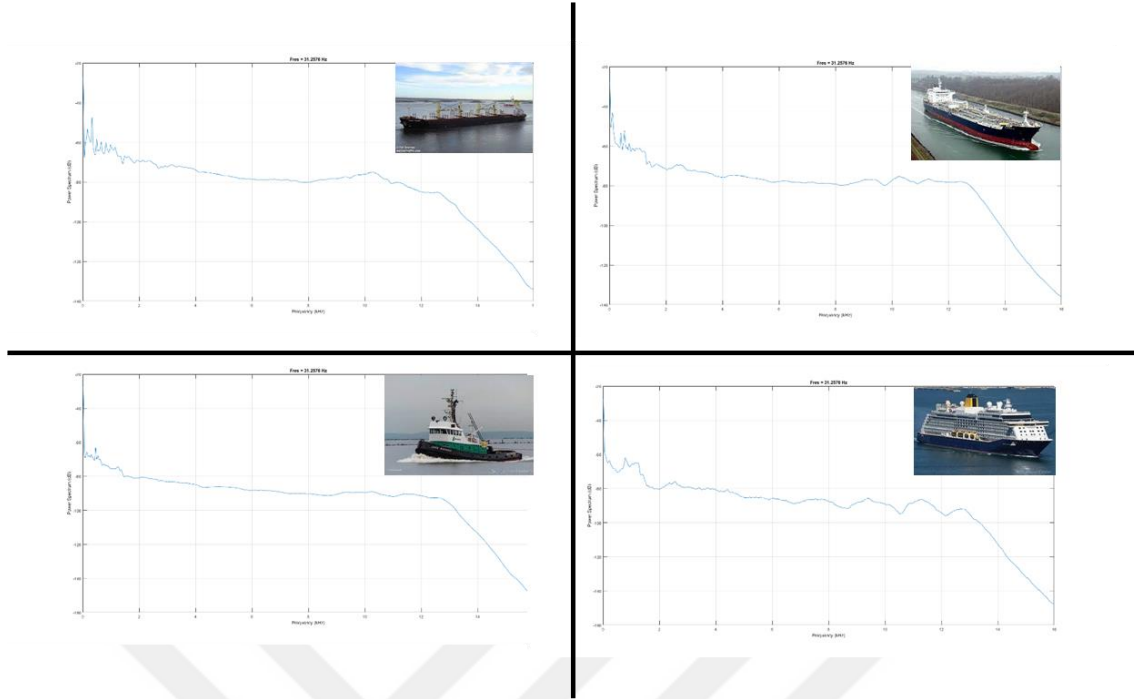
- Frekans – Zaman analizi: Akustik sinyallerin frekans aralıklarının yoğun olduğu bölgeler gözlemlenerek sınıflandırma yapılabileceğini göstergesi olarak akustik sinyallerin spektogramları aşağıda görüldüğü gibidir.

Şekil 5.1’de farklı sınıflara ait gemilerin spektogramı görüntüleri gösterilmektedir. Farklı sınıfların frekans zaman grafiğini ifade ettiği ve frekans dağılımları sınıflandırma için ayırt edici olduğu görülmektedir.



Şekil 5.3. Deepship veri seti farklı sınıfların spektogramı görüntüsü.

- Güç spektrum yoğunluğu analizi: Gemilerden yayılan gürültülü sinyallerin frekans alanındaki enerji dağılımlarını analiz edilmiştir. Gemilerden yayılan gürültüler ile güç spektrum yoğunluğu analizi ile geminin karakteristik özellikleri hakkında önemli bilgiler elde edilebilir. Şekil 5.2’de görüldüğü üzere farklı gemi sınıflarına ait gemilerin güç spektrumlarının farkı görülmektedir.



**Şekil 5.4.** Deepship veri seti farklı sınıfların güç spektrum yoğunluğu grafiği.

Farklı sınıfların frekans zaman grafiğini ifade edildiği ve frekans dağılımları sınıflandırma için ayırt edici olduğu görülmektedir. Fakat Deepship veri setinde Güç spektrum yoğunluğu analizi incelendiğinde ayırım daha zor fark edildiği görülmektedir bu da veri setinin Shipear veri setine göre daha zor sınıflandırma sağlayacağı öngörülmektedir.

Tablo 5.9’da Deepship veri setine ait validasyon başarısı gösterilmektedir. Deepship veri seti farklı sınıflandırıcılar ile test edilmektedir. DEMON verisi öznitelik olarak kullanılarak farklı sınıflandırıcılar, farklı frekans değerleri ve verilerin farklı uzunlukları birbiriyle karşılaştırılmaktadır. Validasyon başarısı KNN sınıflandırıcısında 0-152 Hz aralığında 60 sn veriler kullanılarak en yüksek doğruluk olan %80,1 elde edilmiştir.

**Tablo 5.10.** Deepship Sınıflandırma Sonuçları.

Model Tipi	Veri Uzunluğu / Saniye			
	30 Saniye		60 Saniye	
	Frekans Aralıkları / Hz			
	0-76	0-152	0-76	0-152
KNN	%77,6	%78,1	%78,2	%80,1
NN	%66,6	%67,3	%67,6	%69
SVM	%66	%67,8	%68,4	%70

Tablo 5.11-12-13'te Deepship veri setine ait validasyon karışıklık matrisleri gösterilmektedir. Deepship veri seti farklı sınıflandırıcılar ile test edilmektedir. DEMON verisi öznitelik olarak kullanılarak farklı frekans değerleri arasında ve verilerin farklı uzunlukları birbiriyle karşılaştırılmaktadır.

**Tablo 5.11.** Deepship KNN Karışıklık Matrisleri.

Sınıflandırma Sonuçları										
		Model 1 (Cosine KNN)				Model 1 (Cosine KNN)				
True Class	CLASSA	599	25	226	135	CLASSA	621	23	201	140
	CLASSB	49	772	112	197	CLASSB	60	776	76	218
	CLASSC	54	10	950	15	CLASSC	46	7	931	45
	CLASSD	22	53	43	932	CLASSD	24	56	23	947
		Predicted Class				Predicted Class				
KNN 0-76 Hz (30 Saniye)					KNN 0-152 Hz (30 Saniye)					
		Model 1 (Cosine KNN)				Model 1 (Cosine KNN)				
True Class	CLASSA	507	26	189	118	CLASSA	533	24	158	125
	CLASSB	44	650	94	149	CLASSB	41	657	62	177
	CLASSC	48	9	801	10	CLASSC	32	5	795	36
	CLASSD	13	47	39	860	CLASSD	11	54	23	871
		Predicted Class				Predicted Class				
KNN 0-76 Hz (60 Saniye)					KNN 0-152 Hz (60 Saniye)					

**Tablo 5.12.** Deepship NN Karışıklık Matrisleri.

Sınıflandırma Sonuçları										
		<b>Model 2 (Wide Neural Network)</b>		<b>Model 1 (Wide Neural Network)</b>						
True Class	CLASSA	510	124	192	159	CLASSA	483	125	214	163
	CLASSB	128	722	75	205	CLASSB	128	729	83	190
	CLASSC	154	86	745	44	CLASSC	143	95	747	44
	CLASSD	73	135	26	816	CLASSD	67	107	14	862
		Predicted Class				Predicted Class				
NN 0-76 Hz (30 Saniye)					NN 0-152 Hz (30 Saniye)					
		<b>Model 3 (Wide Neural Network)</b>		<b>Model 2 (Wide Neural Network)</b>						
True Class	CLASSA	86	27	58	29	CLASSA	115	17	42	37
	CLASSB	19	156	11	48	CLASSB	26	146	17	45
	CLASSC	23	27	161	7	CLASSC	27	14	168	8
	CLASSD	16	23	4	196	CLASSD	16	24	6	193
		Predicted Class				Predicted Class				
NN 0-76 Hz (60 Saniye)					NN 0-152 Hz (60 Saniye)					

**Tablo 5.13.** Deepship SVM Karışıklık Matrisleri.

Sınıflandırma Sonuçları										
		<b>Model 1 (Quadratic SVM)</b>		<b>Model 2 (Quadratic SVM)</b>						
True Class	CLASSA	483	148	184	160	CLASSA	509	142	187	147
	CLASSB	105	776	60	189	CLASSB	114	795	62	159
	CLASSC	164	135	696	34	CLASSC	147	127	718	37
	CLASSD	72	155	21	802	CLASSD	79	134	16	821
		Predicted Class				Predicted Class				
SVM 0-76 Hz (30 Saniye)					SVM 0-152 Hz (30 Saniye)					

		Model 1 (Quadratic SVM)				Model 3 (Quadratic SVM)			
True Class	CLASSA	103	23	37	47	127	22	31	31
	CLASSB	25	163	10	37	23	167	10	34
	CLASSC	25	19	159	14	44	21	142	10
	CLASSD	12	32	4	191	16	25	3	196
		Predicted Class				Predicted Class			
		SVM 0-76 Hz (60 Saniye)				SVM 0-152 Hz (60 Saniye)			

## TEST SONUÇLARI

Tablo 5.13'te Deepship veri setine ait farklı sınıflandırıcılarda test sonuçları gösterilmektedir. KNN sınıflandırıcı kullanılarak 60 sn veriler ile 0-152 Hz frekans aralığında %84,12 doğruluk elde edilmiştir.

**Tablo 5.14.** Deepship Sınıflandırma Sonuçları.

Model Tipi	Veri Uzunluğu / Saniye			
	30 Saniye		60 Saniye	
	Frekans Aralıkları / Hz			
	0-76	0-152	0-76	0-152
KNN	%80,69	%82,38	%81,62	%84,12
NN	%69,07	%69,17	%73,63	%71,53
SVM	%66,92	%69,54	%71,53	%72,73

DeepShip çalışması kapsamında en iyi sonucun KNN ulaşılmıştır. En iyi sonucun sonuçları Tablo-5.6'da detaylandırılmıştır.

**Tablo 5.15.** DeepShip 60 sn 0-152Hz Verisi KNN Sonuçları.

İSİM	SINIF			
	A	B	C	D
Doğru Pozitif	183	191	228	240
Yanlış Pozitif	54	75	14	16
Yanlış Negatif	18	13	60	68
Doğru Negatif	746	722	699	677
Hassasiyet	0,77215	0,71805	0,94215	0,9375
Duyarlılık	0,91045	0,93627	0,79167	0,77922
Özgüllük	0,9325	0,9059	0,98036	0,97691
Doğruluk	0,84116	0,84116	0,84116	0,84116
F-Skor	0,83562	0,81277	0,86038	0,85106

Tablo 5.16-16-17’de Deepship veri setine ait test karışıklık matrisleri gösterilmektedir. Deepship veri seti farklı sınıflandırıcılar ile test edilmektedir. DEMON verisi öznitelik olarak kullanılarak farklı frekans değerleri arasında ve verilerin farklı uzunlukları birbiriyle karşılaştırılmaktadır.

**Tablo 5.16.** Deepship KNN Karışıklık Matrisleri.

Sınıflandırma Sonuçları										
True Class	CLASSA	163	6	44	32	CLASSA	178	4	34	29
	CLASSB	14	199	29	48	CLASSB	13	212	18	47
	CLASSC	8	1	253	4	CLASSC	9	1	246	10
	CLASSD	7	8	5	246	CLASSD	7	11	5	243
		CLASSA	CLASSB	CLASSC	CLASSD		CLASSA	CLASSB	CLASSC	CLASSD
Predicted Class					Predicted Class					
KNN 0-76 Hz (30 Saniye)					KNN 0-152 Hz (30 Saniye)					
True Class	CLASSA	168	4	41	24	CLASSA	183	4	34	16
	CLASSB	7	187	26	46	CLASSB	10	191	19	46
	CLASSC	11	2	227	2	CLASSC	7	1	228	6
	CLASSD		14	7	235	CLASSD	1	8	7	240
		CLASSA	CLASSB	CLASSC	CLASSD		CLASSA	CLASSB	CLASSC	CLASSD
Predicted Class					Predicted Class					
KNN 0-76 Hz (60 Saniye)					KNN 0-152 Hz (60 Saniye)					

**Tablo 5.17.** Deepship NN Karışıklık Matrisleri.

Sınıflandırma Sonuçları										
True Class	CLASSA	122	24	53	46	CLASSA	115	30	57	43
	CLASSB	32	199	21	38	CLASSB	31	201	17	41
	CLASSC	36	20	203	7	CLASSC	30	16	208	12
	CLASSD	19	27	7	213	CLASSD	19	28	5	214
		CLASSA	CLASSB	CLASSC	CLASSD		CLASSA	CLASSB	CLASSC	CLASSD
Predicted Class					Predicted Class					
NN 0-76 Hz (30 Saniye)					NN 0-152 Hz (30 Saniye)					
True Class	CLASSA	142	15	51	29	CLASSA	130	25	45	37
	CLASSB	29	176	18	43	CLASSB	28	178	19	41
	CLASSC	23	11	201	7	CLASSC	25	20	188	9
	CLASSD	14	20	4	218	CLASSD	13	20	3	220
		CLASSA	CLASSB	CLASSC	CLASSD		CLASSA	CLASSB	CLASSC	CLASSD
Predicted Class					Predicted Class					
NN 0-76 Hz (60 Saniye)					NN 0-152 Hz (60 Saniye)					

**Tablo 5.18.** Deepship SVM Karışıklık Matrisleri.

Sınıflandırma Sonuçları										
True Class	CLASSA	113	33	48	51	CLASSA	123	29	50	43
	CLASSB	28	211	10	41	CLASSB	27	211	11	41
	CLASSC	43	32	181	10	CLASSC	39	24	194	9
	CLASSD	15	37	5	209	CLASSD	18	30	4	214
		CLASSA	CLASSB	CLASSC	CLASSD		CLASSA	CLASSB	CLASSC	CLASSD
Predicted Class					Predicted Class					
SVM 0-76 Hz (30 Saniye)					SVM 0-152 Hz (30 Saniye)					

True Class	CLASSA	138	26	39	34	True Class	CLASSA	147	17	39	34
	CLASSB	24	187	16	39		CLASSB	21	195	15	35
	CLASSC	31	27	177	7		CLASSC	35	31	169	7
	CLASSD	15	21	6	214		CLASSD	13	23	3	217
Predicted Class					Predicted Class						
SVM 0-76 Hz (60 Saniye)					SVM 0-152 Hz (60 Saniye)						

### 5.3. MARMARA-1 Veri Seti Analizi ve Bulgular

Tablo 5.17’de gösterilen literatürde yer alan veri setlerini ilave olarak eğitilen makine öğrenmesini doğrulamak için Balıkesir/Erdek bölgesinden veri toplanmıştır.

**Tablo 5.19.** Literatürde yer alan veri setleri.

DeepShip				
Sınıf	Kargo	Yolcu Gemisi	Römorkör	Tanker
Süre	38400 sn	44520 sn	40620 sn	45900 sn

ShipEar					
Sınıf	A	B	C	D	Ortam Gürültüsü
Süre	1729 sn	1228 sn	1098 sn	2041 sn	923 sn

Veri toplama olayı maliyetli olmasından dolayı sadece test etmek maksadıyla kısıtlı veri toplanabilmiştir. Toplanan verilere ilişkin detaylar Tablo 5.18’de yer almaktadır.

**Tablo 5.20.** Marmara veri seti.

Marmara Veri Seti				
Sınıf	Kargo	Yolcu Gemisi	Römorkör	Tanker
Süre	360 sn	360 sn	480 sn	360 sn

Tablo 5.19’da toplanan veri seti Deepship veri seti eğitimi ile elde edilen farklı sınıflandırıcı modelleri ile test edilerek sınıflandırma sonuçları gösterilmektedir. En başarılı frekans aralığı ve kaydedilen veri uzunluğu 60 sn ile test edilmiştir.

**Tablo 5.21.** Marmara veri seti Sınıflandırma Sonuçları.

Model Tipi	Veri Uzunluğu / Saniye
	60 Saniye
	Frekans Aralıkları / Hz
	0-152
Veri Seti	Marmara
KNN	%76,92

Tablo 5.20’de Marmara veri seti sınıflandırma sonuçlarına ait karışıklık matrisi gösterilmektedir.

**Tablo 5.22.** Marmara KNN Karışıklık Matrisleri.

Sınıflandırma Sonuçları					
True Class	CLASSA	5			1
	CLASSB	1	3	1	1
	CLASSC	1	1	6	
	CLASSD				6
		CLASSA	CLASSB	CLASSC	CLASSD
		Predicted Class			
KNN 0-152 Hz (60 Saniye)					

## 6. SONUÇ

Bu çalışmada DEMON algoritması ile üretilen veriler öznitelik olarak değerlendirilerek sınıflandırma gerçekleştirilmiştir. Açık kaynak 2 farklı veri seti üzerinde DEMON algoritması test edilerek validasyon ve test doğrulukları elde edilmiştir. Validasyon doğrulukları elde edilirken 10 katlamalı çapraz validasyon (10-fold cross validation) yöntemi ile edilerek eğitimde kullanılmayan test verileri ile test edilerek sonuçlar elde edilmiştir. Literatürde araştırmacıların çalıştığı tek frekans aralığı yerine iki farklı

frekans aralığında sınıflandırma performansları incelenmiştir. Farklı frekans aralıkları yanında verilerin uzunluklarının etkisi de gözlemlenmesi için iki ayrı veri seti uzunluklarına bağlı olarak Shipear veri seti için 10 ve 20 sn, Deep ship veri seti için 30 ve 60 sn veriler kullanılarak sınıflandırma performansları incelenmiştir. Sonuç olarak, DEMON algoritması kullanılarak elde edilen öznelilikler sınıflandırılmış ve test sonuçları incelendiğinde 20 sn ve 60 sn veriler kullanılması 10 ve 30 sn verilere göre daha iyi sonuç verdiği gözlemlenmiştir. Frekans aralıkları incelendiğinde 0-152 Hz arası sonuçların 0-76 Hz sonuçlara göre daha başarılı olması beklenildiği gibi çıkmıştır.



## KAYNAKLAR

- [1] L. D. Vinci, "SOUND AND RANGING BETWEEN SHIPS":.
- [2] R. J. Urick, "Principles of underwater sound", s. 408.
- [3] H. Medwin ve C. S. Clay, *Fundamentals of acoustical oceanography*. Boston: Academic Press, 1998.
- [4] M. Karataş, "Bistatik ve multistatik su altı sensör ağlarının optimizasyonu", 2012.
- [5] W. H. Munk, "Sound channel in an exponentially stratified ocean, with application to SOFAR", *J. Acoust. Soc. Am.*, c. 55, sy 2, ss. 220-226, Şub. 1974, doi: 10.1121/1.1914492.
- [6] H. Yılmaz, S. Alkoy, ve C. Duran, "Su altı akustik cihazların (Transducer/Hidrofon) tasarlanması, üretilmesi ve karakterizasyonu", *undefined*, ss. 1-57, May. 2010.
- [7] C. Yang, S. Zhou, ve G. Zhang, "Underwater Cylindrical Acoustic Array Structure Design Scheme", *IOP Conf. Ser. Mater. Sci. Eng.*, c. 677, sy 2, s. 022095, Ara. 2019, doi: 10.1088/1757-899X/677/2/022095.
- [8] A. Pollara, A. Sutin, ve H. Salloum, "Improvement of the Detection of Envelope Modulation on Noise (DEMON) and its application to small boats", içinde *OCEANS 2016 MTS/IEEE Monterey*, Monterey, CA, USA, Eyl. 2016, ss. 1-10. doi: 10.1109/OCEANS.2016.7761197.
- [9] G. J. Lowes, J. Neasham, R. Burnett, B. Sherlock, ve C. Tsimenidis, "Passive Acoustic Detection of Vessel Activity by Low-Energy Wireless Sensors", *J. Mar. Sci. Eng.*, c. 10, sy 2, s. 248, Şub. 2022, doi: 10.3390/jmse10020248.
- [10] X. Luo ve Y. Feng, "An Underwater Acoustic Target Recognition Method Based on Restricted Boltzmann Machine", *Sensors*, c. 20, sy 18, s. 5399, Eyl. 2020, doi: 10.3390/s20185399.
- [11] V. dos S. Mello, N. N. de Moura, ve J. M. de Seixas, "Novelty Detection in Passive Sonar Systems using Stacked AutoEncoders", içinde *2018 International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro, Tem. 2018, ss. 1-7. doi: 10.1109/IJCNN.2018.8489559.
- [12] N. N. de Moura, J. M. de Seixas, ve R. Ramos, "Passive Sonar Signal Detection and Classification Based on Independent Component Analysis", içinde *Sonar Systems*, N. Kolev, Ed. InTech, 2011. doi: 10.5772/18286.
- [13] A. D. Waite, *Sonar for practising engineers*, 3rd ed. Wiley, 2002.
- [14] M. J. Crocker, Ed., *Handbook of acoustics*. New York: Wiley, 1998.
- [15] E. J. Harland, S. A. S. Jones, ve T. Clarke, "SEA 6 Technical report: Underwater ambient noise", s. 48.
- [16] D. Santos-Domínguez, S. Torres-Guijarro, A. Cardenal-López, ve A. Pena-Gimenez, "ShipsEar: An underwater vessel noise database", *Appl. Acoust.*, c. 113, ss. 64-69, Ara. 2016, doi: 10.1016/j.apacoust.2016.06.008.
- [17] M. Irfan, Z. Jiangbin, S. Ali, M. Iqbal, Z. Masood, ve U. Hamid, "DeepShip: An underwater acoustic benchmark dataset and a separable convolution based autoencoder for classification", *Expert Syst. Appl.*, c. 183, s. 115270, Kas. 2021, doi: 10.1016/j.eswa.2021.115270.
- [18] "Karışıklık Matrisi - genel bakış | ScienceDirect Konuları". <https://www.sciencedirect.com/topics/engineering/confusion-matrix> (erişim 27 Kasım 2022).
- [19] S. Ozen, M. Oner, M. A. Cavuslu, A. C. Ilguy, O. Tatar, ve Y. H. Basaran,

- “Simulation and estimation of underwater acoustical tonals emanating from naval platforms”, içinde *2013 21st Signal Processing and Communications Applications Conference (SIU)*, Haspolat, Nis. 2013, ss. 1-4. doi: 10.1109/SIU.2013.6531347.
- [20] M. A. R. Hashmi ve R. H. Raza, “Novel DEMON Spectra Analysis Techniques and Empirical Knowledge Based Reference Criterion for Acoustic Signal Classification”, *J. Electr. Eng. Technol.*, Ağu. 2022, doi: 10.1007/s42835-022-01167-3.
- [21] A. Sutin vd., “Stevens Passive Acoustic System for underwater surveillance”, içinde *2010 International WaterSide Security Conference*, Carrara, Italy, Kas. 2010, ss. 1-6. doi: 10.1109/WSSC.2010.5730286.
- [22] “Cyclostationarity Based Sonar Signal Processing | Elsevier Enhanced Reader”. <https://reader.elsevier.com/reader/sd/pii/S1877050916315095?token=7D013E8D14A5D7815A1DE26DADA167DB89E9CB237DDE1D69820D66ED3B9A920431DBDCBE3E2C27E20A4BA7E32A8FD6E&originRegion=eu-west-1&originCreation=20221203151256> (erişim 03 Aralık 2022).
- [23] K. W. Chung, A. Sutin, A. Sedunov, ve M. Bruno, “DEMON Acoustic Ship Signature Measurements in an Urban Harbor”, *Adv. Acoust. Vib.*, c. 2011, ss. 1-13, May. 2011, doi: 10.1155/2011/952798.
- [24] D. Neupane ve J. Seok, “A Review on Deep Learning-Based Approaches for Automatic Sonar Target Recognition”, *Electronics*, c. 9, sy 11, s. 1972, Kas. 2020, doi: 10.3390/electronics9111972.
- [25] F. Yuan, X. Ke, ve E. Cheng, “Joint Representation and Recognition for Ship-Radiated Noise Based on Multimodal Deep Learning”, *J. Mar. Sci. Eng.*, c. 7, sy 11, s. 380, Eki. 2019, doi: 10.3390/jmse7110380.
- [26] F. Liu, H. Ding, D. Li, T. Wang, Z. Luo, ve L. Chen, “Few-shot Learning with Data Enhancement and Transfer Learning for Underwater Target Recognition”, içinde *2021 OES China Ocean Acoustics (COA)*, Harbin, China, Tem. 2021, ss. 992-994. doi: 10.1109/COA50123.2021.9519853.
- [27] Deepa. B, Anoop. M, V. P. S, ve Sooraj. K. Ambat, “Performance Evaluation of the DEMON Processor for Sonar”, içinde *2022 IEEE Region 10 Symposium (TENSYP)*, Tem. 2022, ss. 1-6. doi: 10.1109/TENSYP54529.2022.9864381.
- [28] “Pervane Şaft Ve Dümen Sistemleri.pdf”. Erişim: 05 Ağustos 2022. [Çevrimiçi]. Erişim adresi: [http://www.megep.meb.gov.tr/mte\\_program\\_modul/moduller\\_pdf/Pervane%20%C5%9Eaft%20Ve%20D%C3%BCmen%20Sistemleri.pdf](http://www.megep.meb.gov.tr/mte_program_modul/moduller_pdf/Pervane%20%C5%9Eaft%20Ve%20D%C3%BCmen%20Sistemleri.pdf)
- [29] F. Hong, C. Liu, L. Guo, F. Chen, ve H. Feng, “Underwater Acoustic Target Recognition with ResNet18 on ShipsEar Dataset”, içinde *2021 IEEE 4th International Conference on Electronics Technology (ICET)*, Chengdu, China, May. 2021, ss. 1240-1244. doi: 10.1109/ICET51757.2021.9451099.

## ÖZGEÇMİŞ

Gürkan ORHAN, 2010 yılında Gelibolu Anadolu Lisesi'ni tamamladı ve ardından başladığı Balıkesir Üniversitesi Mühendislik Mimarlık Fakültesi Elektrik Elektronik Mühendisliği Bölümünü 2014 yılında başarıyla tamamladı. 2020 yılında yüksek lisans eğitimine Marmara Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalında başladı. İlgili alanları arasında Sayısal İşaret İşleme, Akustik Sinyal İşleme, Görüntü İşleme ve Makine Öğrenmesi yer almaktadır. Meslek hayatı dışında ekonomi ve finans alanlarına ilgi duymaktadır.

