

**T.C.**  
**GEBZE TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**SUALTI AKUSTİK SİNYALLER KULLANILARAK**  
**OTOMATİK HEDEF SINIFLANDIRMA**

**İBRAHİM GÖKHAN AKSÜREN**  
**YÜKSEK LİSANS TEZİ**  
**ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**GEBZE**

**2022**

**T.C.**  
**GEBZE TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**SUALTI AKUSTİK SİNYALLER**  
**KULLANILARAK OTOMATİK HEDEF**  
**SINIFLANDIRMA**

**İBRAHİM GÖKHAN AKSÜREN**  
**YÜKSEK LİSANS TEZİ**  
**ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMANI**  
**DR. ÖĞR. ÜYESİ ALİ KÖKSAL HOCAOĞLU**

**GEBZE**  
**2022**

**T.R.**  
**GEBZE TECHNICAL UNIVERSITY**  
**GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES**

**AUTOMATIC TARGET**  
**CLASSIFICATION USING**  
**UNDERWATER ACOUSTIC SIGNALS**

**İBRAHİM GÖKHAN AKSÜREN**  
**A THESIS SUBMITTED FOR THE DEGREE OF**  
**MASTER OF SCIENCE**  
**DEPARTMENT OF ELECTRONICS ENGINEERING**

**THESIS SUPERVISOR**  
**ASSIST. PROF. DR. ALİ KÖKSAL HOCAOĞLU**

**GEBZE**  
**2022**



## YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 16/06/2022 tarih ve 2022/29 sayılı kararıyla oluşturulan jüri tarafından 21/06/2022 tarihinde tez savunma sınavı yapılan İbrahim Gökhan AKSÜREN'in tez çalışması Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

### JÜRİ

ÜYE

(TEZ DANIŞMANI)

: DR. ÖĞR. ÜYESİ ALİ KÖKSAL HOCAOĞLU

ÜYE

: DOÇ. DR. SERDAR SÜER ERDEM

ÜYE

: DOÇ. DR. ALP ERTÜRK

### ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun  
...../...../..... tarih ve ...../..... sayılı kararı.

İMZA/MÜHÜR

## ÖZET

SONAR ile elde edilen sualtı akustik sinyallerin sınıflandırması SONAR operatörleri tarafından yapılmaktadır. Operatörü sualtı akustik sinyallerin sınıflandırılmasında desteklemek için otomatik sınıflandırma algoritmaları kullanılmaktadır.

Bu çalışmada sualtı akustik sinyaller kullanılarak otomatik hedef sınıflandırma gerçekleştirilmiştir. Sualtı ve suüstü gemilerinin uzak mesafelerden tespit edilmesinde ve gürültülerinin analiz edilerek hedef tanıma için kullanılan Alçak Frekans Analiz ve Kaydı (LOFAR, ing. Low Frequency Analysis and Recording) algoritması kullanılarak hedefler sınıflandırılmıştır. Pasif SONAR uygulamalarının önemli aşamalarından biri olan LOFAR algoritması iki farklı şekilde iyileştirilmiş ve yapılan bu değişikliklerin hedef sınıflandırma performanslarına olan katkıları incelenmiştir.

Bu tez çalışması ile önerilen yöntem, mevcut yöntemlere göre, tek frekans aralığı yerine 6 farklı frekans aralığını ayrı ayrı hedef sınıflandırma için kullanırken, 7 farklı frekans aralığında ise SONAR operatörüne LOFAR görüntüsü sunarak yenilikçi bir yaklaşım sergilemektedir. Ayrıca, LOFAR verileri t-SNE algoritması ile görselleştirilmiş ve gemileri boyutlarına göre gruplandırmak yerine gürültü karakteristiklerinin benzerliğine göre gruplandırmanın daha yoğun öbeklerin oluşumuna yol açtığı gözlenmiştir. Önerilen bu yaklaşımlarla hedef sınıflandırma performansının arttığı gösterilmiştir.

**Anahtar Kelimeler: Sualtı Akustiği, Akustik İşaret İşleme, Sualtı Akustik Hedef; Tanıma ve Sınıflandırma, LOFAR Analizi.**

## SUMMARY

The classification of underwater acoustic signals obtained by SONAR is carried out by SONAR operators. Automatic classification algorithms are used to support the operator in the classification of underwater acoustic signals.

In this study, automatic target classification was performed using underwater acoustic signals. The targets were classified using the Low Frequency Analysis and Recording algorithm, which is used for detecting underwater and surface ships from long distances and for target recognition by analyzing their noise. The LOFAR algorithm, which is one of the important stages of passive SONAR applications, is developed and the target classification performances of the two methods are examined.

In this study, while the proposed method uses 6 different frequency ranges separately for target classification, instead of a single frequency range, comparing to existing methods, it presents an innovative approach by presenting a LOFAR image to the SONAR operator in 7 different frequency ranges. Additionally, LOFAR data is visualized by the t-SNE algorithm and it is observed that grouping the ships based on noise characteristics forms more compact clusters compared to groupings based on the sizes of the ships. We show that the proposed approaches improve the performance of target classification.

**Key Words: Underwater Acoustics, Acoustic Signal Processing, Underwater Acoustic Target; Recognition and Classification, LOFAR Analysis.**

## TEŐEKKÜR

BaŐta, bu alıŐmanın oluŐmasının yolunu aan, yardımlarını zaman kavramı gÖzetmeksizin esirgemeyen danıŐmanım Dr. Ali KÖksal HOCAOĐLU'na,

Bütün alıŐmam boyunca bilgi birikimleriyle alıŐmamı yönlendiren deĐerli danıŐmanlarım Erhan ÖZER ve Ali Onur AKAR'a,

alıŐmam süresince, bilgi ve tecrübelerini benimle paylaşan deĐerli alıŐma arkadaşım Gürkan ORHAN'a,

Son olarak yoğun alıŐma dönemi süresince göstermiş olduĐu sonsuz anlayıŐ ve destekten dolayı sevgili babam Yakup AKSÜREN ile sevgili annem Ayla AKSÜREN'e en içten teşekkürlerimi sunarım.

# İÇİNDEKİLER

	<b><u>Sayfa</u></b>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER VE KISALTMALAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xii
TABLolar DİZİNİ	xv
1. GİRİŞ	1
1.1. Tezin Katkısı, Amacı ve İçeriği	2
1.2. Motivasyon	3
1.3. Tezin Organizasyonu	3
2. LİTERATÜR ÖZETİ	5
2.1. Akustik Sensörler	6
2.1.1. Hidrofonlar	6
2.1.2. Hidrofon Dizileri	6
2.1.3. Önyükselticiler	7
2.2. Pasif Görüntüleme Yöntemleri	7
2.2.1. LOFAR	7
2.2.2. DEMON	8
2.2.3. Kerteriz Zaman Ekranı	9
2.3. Platformların Ürettiği Gürültülerin Sınıflandırılması	10
2.3.1. Alçak Frekans Gürültü Kaynakları	10
2.3.1.1. Dinamik Dengesizlik Kaynaklı Gürültüler	10
2.3.1.2. Dürtü Dengesizliği Kaynaklı Gürültüler	10
2.3.1.3. Kavitasyon Gürültüsü	10
2.3.2. Geniş Bant ve Dar Bant Sinyaller	11
2.4. Veri Kümeleri ve Performans Değerlendirme Kriterleri	11
2.4.1. Veri Kümeleri	11
2.4.2. Performans Değerlendirme Kriterleri	14

2.4.3. Yüksek Boyutlu Verilerin Görselleştirilmesi	15
2.5. LOFAR Literatür Araştırması	17
2.6. Sınıflandırma Yöntemleri	20
2.6.1. KNN (K Nearest Neighbours)	20
2.6.2. SVM (Support Vector Machine)	21
2.6.3. Doğrusal Diskriminant Sınıflandırıcı	23
3. LOFAR ALGORİTMASI VE GELİŞTİRİLMESİ	25
3.1. LOFAR	25
3.1.1. LOFAR Görüntülerini Etkileyen Faktörler	27
3.1.2. LOFAR Görüntüsü ile Sinyal Tanıma	28
3.1.3. LOFARGRAM Özellikleri ve Sinyal Değişiklikleri	28
3.1.3.1. Band Genişliği	29
3.1.3.2. Stabilite	29
3.1.3.3. Spektrum	29
3.1.4. LOFARGRAM Sinyal Hatları ile İlgili Terimler	30
3.1.4.1. Temel (Ana) ve Harmonik Frekanslar	30
3.1.5. LOFAR ile Tespit Edilen Dizel Makine Terimleri	31
3.1.5.1. Dizel Makineler ile İlgili Terim Kısaltma ve Anlamları	31
3.1.5.2. Dizel Makine Sinyallerinin LOFARGRAM ile Tespiti	32
3.1.5.3. LOFARGRAM Sinyallerinin Hesaplanması	33
3.2. LOFAR Algoritması	34
3.2.1. Frekans Aralıkları	34
3.2.2. Alçak Geçiren Filtre	35
3.2.3. Yeniden Örnekleme	35
3.2.4. DC Ofset Kaldırma	35
3.2.5. Pencere Fonksiyonu	37
3.2.6. Fourier Dönüşümü	37
3.2.7. Enerji Hesaplanması	38
3.2.8. İki Geçişli Bölünmüş Pencere algoritması	38
3.2.9. Medyan Normalizasyonu	40
3.2.10. Normalizasyon	40
3.2.11. Görüntü Yoğunluğu	41
3.2.12. LOFAR-D Algoritması Akış Şeması	42

3.2.13. LOFAR-DDC Algoritması Geliştirilmesi	43
3.2.13.1. Sayısal Aşağı Dönüşüm	43
3.2.13.2. Sayısal Aşağı Dönüşüm'ün LOFAR Görüntüsüne Etkisi	48
3.2.14. LOFAR Hesaplama Süreleri	48
4. SINIFLANDIRMA, ANALİZ VE SONUÇLAR	52
4.1. ShipEar Veri Kümesi Analiz ve Sonuçları	52
4.1.1. Zaman Frekans Spektrum Analizi	52
4.1.2. Güç Spektrum Yoğunluğu Kestirimi ve Enerji Analizi	53
4.1.3. t-SNE ile Yüksek Boyutlu Verileri Görselleştirilmesi Analizi	57
4.1.4. Sınıflandırma Sonuçları	65
4.2. DeepShip Veri Kümesi Analiz ve Sonuçlar	70
4.2.1. Zaman Frekans Spektrum Analizi	70
4.2.2. Güç Spektrum Yoğunluğu Kestirimi	71
4.2.3. t-SNE ile Yüksek Boyutlu Verileri Görselleştirilmesi Analizi	71
4.2.4. Sınıflandırma Sonuçları	72
4.3. Sentetik Veri Analiz	78
5. SONUÇ	80
KAYNAKLAR	81
ÖZGEÇMİŞ	85
EKLER	86

# SİMGELER VE KISALTMALAR DİZİNİ

## Simgeler ve Açıklamalar

### Kısaltmalar

API	: Application Programming Interface
BTR	: Bearing Time Display
CFR	: Cylinder Firing Rate
CPA	: Closest Point of Approach
CSR	: Crank Shaft Rate
DDC	: Sayısal Aşağı Dönüştürme
DEMON	: Detection Envelope Modulation on Noise
DSH	: Denizaltı Savunma Harbi
DVM	: Destek Vektör Makinası
EFR	: Engine Firing Rate
FFT	: Fast Fourier Transform
HPF	: High Pass Filter
Hz	: Hertz
KNN	: K Nearest Neighbours
LOFAR	: Low Frequency Analysis and Recording
LPF	: Low Pass Filter
MEB	: Münhasır Ekonomik Bölge
PCA	: Principal Component Analysis
RPM	: Revolutions per Minute
SAE	: Stacked Auto Encoder
Sn	: Saniye
SONAR	: Sound Navigation and Ranging
SVM	: Support Vector Machine
t-SNE	: t-Distributed Stochastic Neighbor Embedding
TSPW	: Two-Pass Split Window
WAV	: Waveform Audio File Format

# ŞEKİLLER DİZİNİ

<b><u>Sekil No:</u></b>	<b><u>Sayfa</u></b>
2.1: Silindirik dizinin koordinat sisteminin şematik gösterimi.	7
2.2: DEMON algoritması akış şeması.	8
2.3: DEMON görüntülenmesi.	9
2.4: Pasif SONAR görüntüleme için kerteriz zaman ekranı	9
2.5: Belirli gürültü gruplarının frekans aralığı diyagramı.	11
2.6: Sentetik veri akış şeması.	13
2.7: Örnek sentetik veri LOFAR görüntüsü.	14
2.8: ShipEar veri kümesi tablo 2.1’de yer alan 5 sınıfa ait verilerin farklı frekans aralıklarında t-SNE algoritması kullanılarak elde edilen grafikler.	17
2.9: Genel LOFAR algoritması.	18
2.10: Çalışma akış şeması.	20
2.11: KNN en yakın komşuluk sınıflandırıcı.	21
2.12: Hiper düzlemin oluşturulması.	22
3.1: ShipEar veri kümesi 49 numaralı geminin LOFAR görüntüsü.	26
3.2: ShipEar veri kümesi 49 numaralı geminin hedef hareketleri banyo küveti (bathtub) LOFAR görüntüsü.	28
3.3: Band genişliği.	29
3.4: Stabilité.	29
3.5: Temel (Ana) ve harmonik frekanslar.	30
3.6: İki zamanlı dizel makine CSR ve CFR etkisi.	32
3.7: Dört zamanlı dizel makine CSR ve CFR etkisi.	33
3.8: Farklı sonar uygulamaları için frekans aralıkları.	34
3.9: DC ofset etkisi.	37
3.10: Normalizasyon yapılmamış (solda) ve yapılmış (sağda) LOFAR görüntüsü.	41
3.11: ShipEar veri kümesi 49 numaralı görüntü yoğunluğu değerleri.	42
3.12: ShipEar veri kümesi 49 numaralı geminin kırmızı, mavi ve yeşil kanalları LOFAR görüntüsü.	42

3.13:	LOFAR-D algoritması akış şeması.	43
3.14:	Sayısal aşağı dönüşüm blok diyagramı.	44
3.15:	ShipEar veri kümesi 23 numaralı geminin farklı frekanslarda LOFAR görüntüsü.	45
3.16:	10 Sn ses verisinin farklı örnekleme oranları kullanılarak elde edilen LOFAR görüntüleri.	46
3.17:	Geliştirilen LOFAR-DDC algoritması.	47
3.18:	DDC uygulanmış ve uygulanmamış LOFAR görüntüleri.	48
3.19:	ShipEar ve DeepShip LOFAR hesaplama süreleri grafiği farklı uzunlukta akustik ses verisi için.	49
3.20:	ShipEar ve DeepShip LOFAR hesaplama süreleri grafiği farklı frekans aralığı sabit uzunluktaki akustik ses verisi için.	51
4.1:	Sualtı akustik sinyal spektrum analizi.	53
4.2:	ShipEar veri kümesi motor yat (solda) ve okyanus gemisi (sağda) güç spektrum grafikleri.	54
4.3:	ShipEar veri kümesi benzer karakteristik özelliklerine sahip 3 farklı geminin güç spektrum grafikleri.	54
4.4:	ShipEar veri kümesi 49 numaralı geminin mesafeye bağlı olarak güç spektrum yoğunluğu değişimi ve LOFAR görüntüsü.	55
4.5:	ShipEar veri kümesi ortam gürültüsünün farklı ortam şartları durumunda güç spektrum grafikleri.	55
4.6:	Farklı iki gemi tipi güç spektrum ve enerjilerinin sinyal işleme adımlarının uygulanmadan ve uygulandıktan sonra karşılaştırılması.	56
4.7:	Başarı matrisleri (solda validasyon, sağda test).	57
4.8:	ShipEar veri kümesi tablo 4.1’de yer alan 5 sınıfa ait verilerin farklı frekans aralıklarında t-SNE algoritması kullanılarak elde edilen grafikler.	58
4.9:	ShipEar veri kümesi tablo 4.1’de yer alan 5 sınıfa ait t-SNE algoritması kullanılarak elde edilen grafik.	58
4.10:	ShipEar veri kümesi Tablo 4.1’de yer alan A sınıfa ait t-SNE algoritması kullanılarak elde edilen grafik.	59
4.11:	ShipEar veri kümesi tablo 4.1’de yer alan B sınıfa ait t-SNE algoritması kullanılarak elde edilen grafik.	60

4.12:	ShipEar veri kümesi tablo 4.1’de yer alan C sınıfa ait t-SNE algoritması kullanılarak elde edilen grafik.	60
4.13:	ShipEar veri kümesi tablo 4.1’de yer alan D sınıfa ait t-SNE algoritması kullanılarak elde edilen grafikler.	61
4.14:	ShipEar veri kümesi Tablo 4.1’de yer alan E sınıfa ait t-SNE algoritması kullanılarak elde edilen grafikler.	61
4.15:	ShipEar veri kümesi şekil 4.10-14 bir arada incelenmesi.	62
4.16:	ShipEar veri kümesi 0-100 Hz frekans arası detaylı incelenmesi.	63
4.17:	ShipEar veri kümesi 0-200 Hz frekans arası tablo 4.1’de gemi boyutlarına göre (Solda) ve tablo 4.3’te gemi karakteristik olarak benzer t-SNE kullanılarak yüksek boyutlu LOFAR sinyali özneliğinin görselleştirilmesi.	64
4.18:	ShipEar veri kümesi 0-100 Hz frekans arası tablo 4.1’de gemi boyutlarına göre (Solda) ve tablo 4.3’te gemi karakteristik olarak benzer t-SNE kullanılarak yüksek boyutlu LOFAR sinyali özneliğinin görselleştirilmesi.	64
4.19:	Analiz sonrası akış şeması.	65
4.20:	Yuan vd. ShipEar 10 sınıf.	67
4.21:	Farklı örnekleme frekanslarından oluşan verilerin t-SNE algoritması kullanarak elde edilen grafikleri.	68
4.22:	Tablo 4.9’da yüksek başarı sonuçları kalın işaretli sonuçların başarı matrisleri.	69
4.23:	Sualtı akustik sinyal spektrum analizi.	70
4.24:	DeepShip veri kümesi güç spektrum grafikleri.	71
4.25:	t-SNE algoritması kullanılarak elde edilen a) grafiği b) İrfan ve arkadaşlarının elde ettiği grafikler.	72
4.26:	Tablo 4.10 KNN sınıflandırma başarı matrisleri.	73
4.27:	Tablo 4.10 SVM sınıflandırma başarı matrisleri.	74
4.28:	Tablo 4.10 Naive Bayes sınıflandırma başarı matrisleri.	75
4.29:	Tablo 4.11 KNN sınıflandırma başarı matrisleri.	76
4.30:	Tablo 4.11 SVM sınıflandırma başarı matrisleri.	76
4.31:	Tablo 4.11 Naive Bayes sınıflandırma başarı matrisleri.	77
4.32:	Sentetik veri.	79

# TABLolar DİZİNİ

<b><u>Tablo No:</u></b>	<b><u>Sayfa</u></b>
2.1: ShipEar veri kümesi özeti.	12
2.2: DigitalHyd SR-1hidrofonun özellikleri.	12
2.3: DeepShip veri kümesi özeti.	13
2.4: icListen akıllı hidrofonun özellikleri.	13
2.5: Olası çıktıkların durumları.	15
2.6: Literatürde mevcut çalışmalar ve performansları.	19
3.1: ShipEar ve DeepShip LOFAR hesaplama süreleri karşılaştırması.	49
3.2: ShipEar ve DeepShip LOFAR hesaplama süreleri karşılaştırması.	50
4.1: ShipEar boyuta göre sınıflar.	56
4.2: Enerji hesaplaması yapılarak ortalama enerji, toplam enerji ve maksimum enerji değeri ile sınıflandırma sonuçları.	57
4.3: ShipEar gürültü karakteri benzer sınıflar.	63
4.4: LOFAR-D algoritması ve tablo 4.1'e göre sınıflandırma sonuçları.	65
4.5: LOFAR-D algoritması ve tablo 4.3'ye göre sınıflandırma sonuçları.	66
4.6: LOFAR-DDC algoritması ve tablo 4.1'e göre sınıflandırma sonuçları.	66
4.7: LOFAR-DDC algoritması ve tablo 4.3'e göre sınıflandırma sonuçları.	66
4.8: Tablo 4.6 ve 4.7 başarı matrisleri.	67
4.9: LOFAR-DDC algoritması ve şekil 4.20'ye göre sınıflandırma sonuçları.	68
4.10: LOFAR-DDC algoritması ve tablo 2.3'e göre sınıflandırma sonuçları.	73
4.11: LOFAR-D algoritması ve tablo 2.3'e göre sınıflandırma sonuçları.	75
4.12: İrfan vd. ile karşılaştırmalı deney sonuçları.	77
4.13: Literatür çalışmalarında kullanılan LOFAR algoritması sonuçları.	78

# 1. GİRİŞ

SONAR (Sound Navigation and Ranging), sualtı alanını, ses dalgaları ile hedef ve temasın boyut, uzaklık vb. verilerini, sesin su altında yayılmasını kullanarak su altında ve üstünde haberleşmeyi ve diğer hedef ve temasları tespit etmeyi sağlayan elektronik sistemdir. SONAR sistemleri Aktif SONAR ve Pasif SONAR olarak iki başlık altında gruplandırılabilir Aktif SONAR, belirli ses darbeleri üreterek ve yayılan sesin yansımalarını kullanarak nesnelere algılar. Pasif SONAR ise aktif sonarlardan farklı olarak aktif yayılım yapmaz; gemilerin, denizaltıların veya ortamda bulunan diğer nesnelere ürettiği sesleri dinleyerek nesnelere algılamaya çalışır.

Pasif SONAR, aktif bir ses iletimi yapmamasından dolayı üzerinde bulunduğu geminin yerinin kolayca bulunmasını önlediği için askeri amaçla tercih edilmektedir. Pasif sistemler sahip oldukları veri tabanları sayesinde gemi sınıflarını, eylemleri (geminin süratini, yönünü veya sualtında kullanılan silah türünü) ve hatta belirli gemilerin sınıflarının ve kimliklerinin teşhis edilmesinde kullanılmaktadır.

Bu çalışmada, Pasif SONAR uygulamaları arasında yer alan Alçak Frekans Analiz ve Kaydı (LOFAR, ing. Low Frequency Analysis and Recording) analizi ile pasif sistemler ile elde edilen akustik verilerden sualtı akustik imza elde edilmesi konusu ele alınmıştır. İkinci Dünya Savaşında denizaltıların elde ettiği başarılar sonrasında öncelikle denizaltıları tespit edebilmek amacıyla LOFAR ile ilgili çalışmalar başlamıştır. Bu maksatla farklı tip denizaltıların üretmiş oldukları farklı seslerin elektronik ortamdaki kayıtları kullanılarak bunların görsel analizlerinin yapılması çalışılmıştır. Elde edilen kayıtların görsel analizi 1950 yılından önce icat edilen ses spektrumu analiz cihazı ile yapılması ile konuşma dilinde, LOFAR ya da spektrum analizi olarak kullanılmaktadır.

Geçmişten günümüze gelişen SONAR teknolojisi sayesinde suüstü ve sualtı platformlarının bünyesinde bulunan SONAR ekipmanları ile hedeflere ait kayıt, takip ve analizler kolayca yapılabilmektedir. SONAR ekipmanlarını kullanarak, sualtı akustik sinyallerin sınıflandırılması için en iyi sınıflandırıcı bu amaç için eğitilmiş SONAR operatörleridir. SONAR teknolojisinin gelişmesi ile yüksek kapasiteye sahip ekipmanların artmasına rağmen operatörün bilgi ve tecrübesine bağlı olarak analiz ve sonrasında sınıflandırma yapılması artan düşman tehdidi karşısında yeterli olmamaktadır. Askeri alanda SONAR operatörünün savaş durumlarında dost/düşman

hedefleri sınıflandırmasına destek olması ve en önemlisi deniz çevresinin korunmasında katkı sağlaması literatürde halihazırda yapılan çalışmalar ve bu çalışmaların geliştirilmesi açısından önemli bir yere sahiptir. Bu sebepten, otomatik akustik sınıflandırma sistemleri geliştirilerek operatör üzerindeki yükün azaltılması üzerine çalışılmaktadır.

## 1.1. Tezin Katkısı, Amacı ve İçeriği

Denizcilik sektörü uluslararası ticaret ve küresel ekonominin belkemiğini oluşturmaktadır. Dünya ticaretinin hacim bazında yaklaşık %80'i, değer bazında %70'den fazlası deniz yoluyla taşınmaktadır [1]. Ticaretin yanında, geçmişten günümüze dek önemli bir mücadele sahası oluşturan Doğu Akdeniz Bölgesi, yeni enerji kaynakları ve birbirleriyle çakışan münhasır ekonomik bölgelerin (MEB) ortaya çıkmasıyla birlikte ilan edilen MEB'ler ve bölgeye yapılan askeri tatbikatlar [2] ile askeri alanda ülkelerin deniz güvenliğine olan önemini anlamasını sağlamıştır. Ayrıca, günümüzde deniz trafiği yönetimi, balıkçılık ve deniz çevresinin korunması gibi askeri olmayan amaçlar için de kullanılması bu alanda yapılan çalışmaların önemliliği ile bilime ve literatüre katkı sağlamaktadır.

Bu çalışmada, sualtı akustik sinyaller kullanılarak otomatik hedef sınıflandırma algoritması geliştirilmiştir. Teşhis edilip henüz kimliklendirilememiş bir gemi tespit edilmesi durumunda, algoritma SONAR operatörünün görevini otomatik şekilde yapmaktadır. SONAR operatörünün bilgi ve tecrübesine bağlı olarak gerçekleştireceği sınıflandırmanın otomatik yapılması ile performansın artması, savaş durumlarında hedefin dost/düşman olarak kimliklendirilmesinde hızlı olması sağlamak bu çalışmanın en önemli amacını oluşturmaktadır.

Askeri alanda yapılan çalışmalar sebebiyle elde edilen veri ve bilgiler gizlilik sebebiyle açık kaynak olarak paylaşılamamaktadır. Araştırmacılar genellikle kendi ekipmanları ya da sentetik veriler kullanarak araştırmalarını gerçekleştirmektedir. Askeri alanda yapılan çalışmalar çoğu zaman ekipman, zaman, lojistik ve en önemlisi araştırmacı bilgi birikimlerine yapılan çok maliyetli yatırımdır. Bu sebepler ve ülke menfaatleri düşünülerek gerçek verilerin açık kaynak olarak paylaşılması gerçek veriye ulaşılması ve araştırmacıların bu alanda çalışma yapmasını zorlaştırmaktadır. Son yıllarda sualtı akustik sinyalleri ekipmanlarının yaygınlaşması sivil alanda

yatırımların artmasıyla birlikte sualtı akustik sinyalleri kullanılarak yapılan deęişim tespiti, hedef sınıflandırma, deniz kirlilięi ve trafik yoğunluęu alıřmaları ile eřitli veri kmelerine aık kaynak olarak ulařılabilmektedir.

Bu alıřmada, sualtı akustik sinyaller; sinyal iřleme ve grnt iřleme yntemleri kullanılarak LOFAR analizi sonucu elde edilen grntlerden znelikler ıkarılarak makine ęrenmesi algoritmaları kullanılarak otomatik sınıflandırma gerekleřtirilmiřtir. nerilen yntemlerle literatrdeki alıřmaların karřılařtırması yapılarak en bařarılı hedef sınıflandırma algoritmasının belirlenmesi ve geliřtirilmesi saęlanmıřtır.

Problemin zorluęu sebebiyle literatre bu alıřmanın kazandırılması askeri alanda etkin gcmzn ykselmesi,  tarafı denizlerle evrili olan lkemizin ve Mavi Vatan'ın korunmasının yanında bilime de nemli katkısı olacaktır.

## **1.2. Motivasyon**

Son yıllarda yerli ve milli katma deęeri yksek teknoloji sistemlerin geliřmesi sivil ve askeri alanda bařarılı bir řekilde devam etmektedir. Pasif SONAR uygulamalarından biri olan LOFAR ile hızlı, operatr bilgi ve tecrbelerinden baęımsız otomatik hedef sınıflandırma Milli teknolojiler iin yararlı uygulama alanına sahiptir. Literatrde yer alan aık kaynak veri kmeleri zerinde LOFAR kullanılarak yapılan sınıflandırma arařtırmacılar iin ilgi ekici olmasının yanında askeri alanda alıřan sivil firmaların ilgilendięi nemli bir alıřma alanına girmektedir. Bu tez alıřması kapsamında alıřma motivasyonu, sualtı akustik sinyaller kullanılarak otomatik hedef sınıflandırma problemini sust gemilerinin yanı sıra sualtı iin Denizaltı Savunma Harbi (DSH), mayından sakınma vb. grevleri icra eden platformların milli SONAR sistemleri zerinde alıřabilecek bir algoritma gerekleştirmektir.

## **1.3. Tezin Organizasyonu**

alıřmanın geri kalanı beř blm halinde dzenlenmiřtir. Blm 2'de daha nce yapılmıř alıřmaların kısa bir zeti olarak literatr taraması yapılmıřtır. Blm 3'te sualtı akustik sinyaller kullanılarak otomatik hedef sınıflandırma problemi iin,

LOFAR algoritması ve algoritma geliştirilerek karşılaştırmalı analizi anlatılmıştır. Bölüm 4'te, açık veri kümeleri, sentetik üretilen veriler üzerinde analizler gerçekleştirilmiştir. Devamında açık veri kümeleri üzerinde test edilmesiyle elde edilen deneysel sonuçlar sunulmuştur. Bölüm 5'te sonuç ile tez sonlandırılmıştır.

## 2. LİTERATÜR ÖZETİ

Ses, ilk olarak insanların iletişim için kullanarak işitme hissi olarak tanınsa da fiziksel bir olay olarak gerçekte bir titreşimdir. Konuşma esnasında ses tellerinin titreşmesi veya herhangi bir nesneye vurulması sonucunda titreşim devam ederek kulağımız ile algılarız. Bu da titreşim kaynaklı sesin havada iletildiğinin bir göstergesidir. Titreşimi oluşturan kaynağın etkisinin tek başına yeterli olmayacağı aynı zamanda iletim ortamına bağlı olduğu da unutulmamalıdır. Ses dalgalarının yayılabilmesi için katı, sıvı veya gaz olan ortam şarttır. Kaynak ve ortam ne olursa olsun ses benzer şekilde hareket etmektedir. Ortama bağlı olarak sıcaklık, tuzluluk ve basınç ses hızına etki eden tesirlere sahiptir. Ortamın yoğunluğu artarsa ses hızı artar ve bu sebeple su havaya göre daha yoğun olduğu için ses suda daha hızlı ve daha iyi iletilir.

Günümüz teknolojisinin gelişmesiyle beraber ses tanıma teknolojisi her alanda kullanılmaya başlamıştır. Pocketsphinx, Google' Konuşma API (Application Programming Interface)'si ve diğerleri gibi insan konuşma tanıma odaklı ses sınıflandırmasına çok fazla çaba harcanmıştır. Bu tür uygulamalar ve hizmetler, konuşmayı metne oldukça iyi kalitede tanır, ancak hiçbir çevresel bir ses gibi farklı sesleri veya bu durumda bir deniz gemisinin akustik imzasını belirleyemez [3].

SONAR (Sound Navigation and Ranging), sualtı alanını keşfetmek, haritalamak ve iletişim kurmak için faydalıdır, çevreyi tespit etmek için düşük frekanslı akustik sinyaller kullanır [4]. SONAR sistemleri Aktif SONAR ve Pasif SONAR olarak iki başlık altında gruplandırılabilir Aktif SONAR, belirli ses darbeleri üreterek ve yayılan sesin yansımalarını kullanarak nesnelere algılar. Pasif SONAR ise aktif yayılım yapmayıp gemilerin, denizaltıların veya ortamda bulunan diğer nesnelere ürettiği sesleri dinler.

SONAR sistemleri akustik verileri toplanmasında sensörler kullanır. SONAR ekipmanları ile toplanan veriler sinyal işleme ve görüntü işleme adımları sonrasında operatöre sunulmaktadır. Bu çalışmada giriş bölümünde bahsedildiği üzere pasif SONAR uygulamaları arasında yer alan LOFAR analizi ile otomatik hedef sınıflandırma gerçekleştirilmektedir. LOFAR görüntüsü oluşturulması için SONAR ile kaydedilen ham veri olan akustik ses kayıtları akustik sensörler aşağıda sunulmuştur.

## **2.1. Akustik Sensörler**

Genel olarak sensörler ortamdaki değişiklikleri tespit ederek elektronik cihazlara bilgi sağlayan sistemler olarak ifade edilebilir. Su altında olan değişimleri tespit edilmesi ve bilgilerin saklanması için akustik sensörler kullanılmaktadır. Bu bölümde Pasif SONAR uygulamaları için en çok kullanılan akustik sensörler anlatılmaktadır.

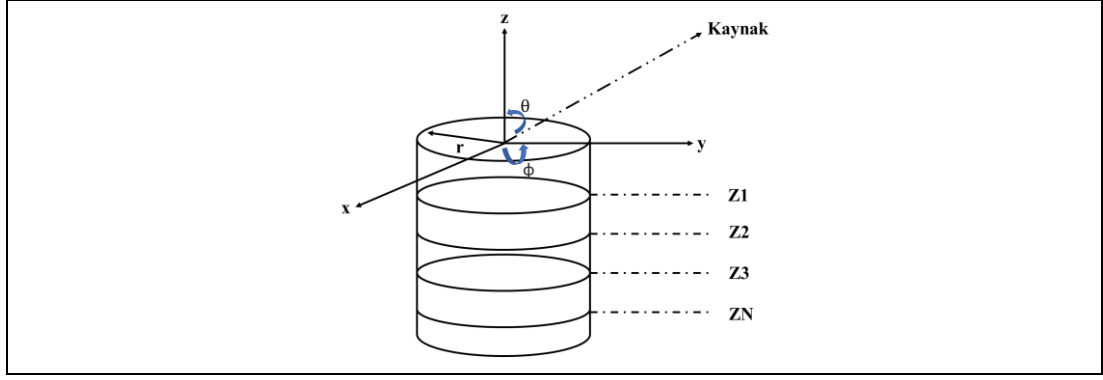
### **2.1.1. Hidrofonlar**

Su altı akustik sinyalleri sesin su altında yaydığı titreşimleri düşük voltaj elektrik akımına dönüştürerek kaydeden su altı mikrofonuna hidrofon denir. Piezoelektrik malzemelerden üretilen hidrofonlar basıncı algılayarak akım olarak iletmektedir. Su altında yayılan ses dalgalarını geniş frekans aralıklarında incelememize olanak sağlamaktadır. Hidrofon kullanarak [5], [6], [7] kendi veri kümelerini oluşturan çalışmalar mevcuttur.

### **2.1.2. Hidrofon Dizileri**

Birden fazla hidrofon kullanılarak akustik sinyallerin hangi yönden geldiği tespit edilebilir. Birden fazla hidrofonun bir araya gelmesiyle elde edilen hidrofon dizileri olarak adlandırılır. Diziler ile hedefin açısı hesaplanarak temas halinde kerteriz bilgisi sunan LOFAR görüntüleme tekniği ile bilgiler elde edilmektedir.

Su altı için kullanılan silindirik diziler hedef tespiti birkaç silindirik diziden oluşur ve sol-sağ belirsizliğe sahip çizgi dizilerine ve yukarı-aşağı belirsizliğe sahip dairesel dizilere göre avantajlara sahiptir [8]. Şekil 2.1’de hedefe ait kerteriz bilgisi sağlayabilen silindirik dizilere ait koordinat şeması gösterilmektedir [8]. Kaynak (Source) gelen sinyali Z dairesel dizilmiş hidrofonlar ile elde edilmektedir.



Şekil 2.1: Silindirik dizinin koordinat sisteminin şematik gösterimi.

### 2.1.3. Önyükselticiler

Ses dalgalarının titreşimleri sualtı mikrofonları ile düşük voltaj elektrik akımına dönüştürerek kaydedilir ve sinyal seviyeleri mikro volt olan düşük seviyelerdedir. Akustik sinyal işlemenin gerçekleştirilmesi için düşük seviyedeki yükseltmek için önyükselticiler kullanılmaktadır.

## 2.2. Pasif Görüntüleme Yöntemleri

Akustik sinyalleri kullanarak analiz etmek ve bilgi çıkarımı için kavitasyon (DEMON ing. Detection Envelope Modulation on Noise) ve alçak frekans analiz ve kaydı (LOFAR ing. Low Frequency Analysis and Recording) analiz yöntemi ile düşük frekans bandında meydana gelen hareketliliklerin analizi yapılabilmektedir [9]. Yapılan analizler ile akustik sinyaller görüntülenmektedir aşağıda görüntüleme için yöntemler açıklanmaktadır. Bu yöntemler daha çok Pasif SONAR uygulamalarında kullanıldığı için pasif görüntüleme olarak bilinmektedir.

### 2.2.1. LOFAR


LOFAR denizaltılar ve su üstü gemilerinin uzak mesafelerden tespit edilmesine ve gürültülerinin analiz edilerek sınıflandırılmasına imkan sağlar. Analiz sonucunda gürültüler sonucu zaman-frekans ile temsil edilmesi sonucunda hatları/tonelleri pasif sonar uygulamalarında LOFARGRAM ile incelenebilmektedir. LOFAR geniş bantlı

hedef gürültü spektrumunda baskın olan düşük frekanslı ve ayırık tonalların daha detaylı tespiti ve analizi için kullanılır [10].

Gemilerin akustik izlerine katkı sağlayan gemi makineleri dar bant karakteristiğe sahip mekanik kaynaklı gürültülerdir ve temelde iki çeşittir. Biri, geminin itki sisteminden kaynaklanan, diğeri ise yardımcı makinelerin ürettiği gürültüdür [11]. Makinalar tarafından üretilen gürültüler makinanın karakteristik özelliğini taşıdığından sınıflandırma için önemli bir ipucudur ve hedefe ait parmak izi olarak tanımlanır. LOFAR analizi, sonar operatörlerinin sonar dalga verileri üzerindeki hedef makinelerin frekans bilgilerini görsel olarak tanımlayabilmelerini sağlar [12]. Görüntü elemanları olarak geniş bantlı analizler için kerteriz (bearing) ve dar bantlı analizler için LOFAR görüntüleri kullanılır. LOFAR geniş bantlı hedef gürültü spektrumunda baskın olan düşük frekanslı ve ayırık tonalların daha detaylı tespiti ve analizi için kullanılır [10]. Ayrıntılı LOFAR anlatımı Bölüm 3'te yapılmaktadır.


### 2.2.2. DEMON

DEMON, suüstü ve sualtı hedef pervanesinin kaviteasyon gürültüsü yani sulatında kabarcıklarının oluşumu ve bunların ani olarak patlaması ile oluşan fiziksel olayı üzerinde çalışan dar bantlı bir analizdir. Elde edilen parametreler hedef pervaneler hakkında ayrıntılı bilgi sağladığından (pervane gürültüsü her hedef için karakteristiktir), genellikle verimli algılama sağlanır [13]. Çünkü Kabarcık oluşumu periyodik olduğundan, yüksek frekans kabarcıklar tarafından üretilen gürültü genlik modüle edilir. Yüksek frekanslı gürültünün zarfındaki tonlar, pervanesinin dönüş ve bıçak geçiş hızlarında ve harmoniklerinde bulunur [14]. DEMON algoritması akış şeması Şekil 2.2'de verilmiştir [13].



Şekil 2.2: DEMON algoritması akış şeması.

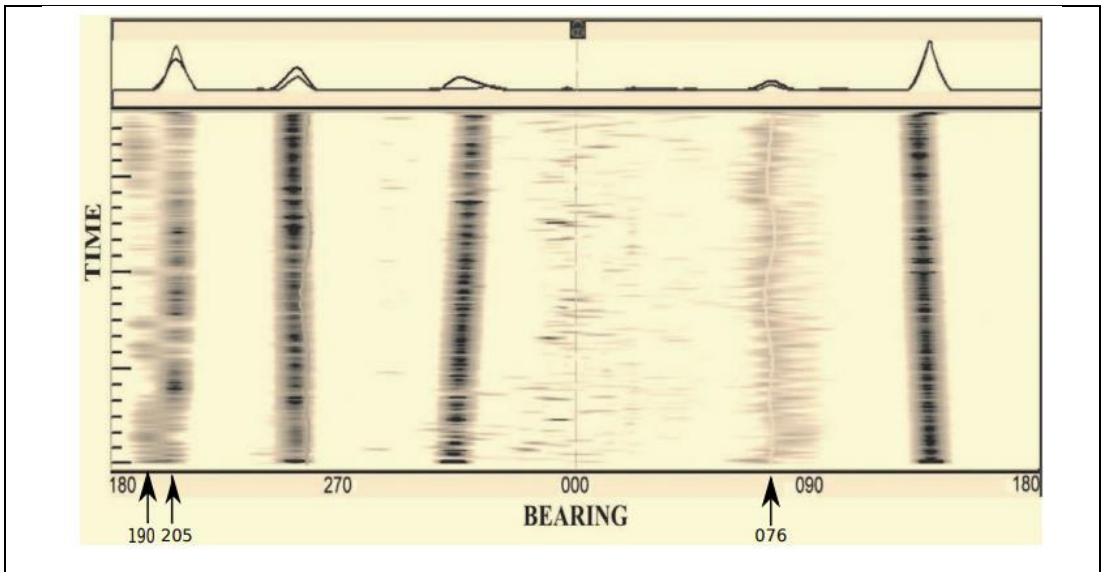
Dar band analizi olan DEMON şelalesi ile görüntülenebilmektedir. Akustik sinyallerde hedefin pervaneden kaynaklanan DEMON hatları Şekil 2.3'te görülmektedir [15].



Şekil 2.3: DEMON görüntülenmesi.

### 2.2.3. Kerteriz Zaman Ekranı

BTR (BTR ing. Bearing Time Display), akustik sinyalin zaman bağılı olarak hidrofondan elde edilen kerteriz açısı hesabı sonucu hedefin yönünü belirlemek için kullanılmaktadır. BTR’de her bir çizgi, kerterizi enerjinin belirli bir zamanında bir örneğe karşılık gelmektedir. Şekil 2.4’te görüldüğü gibi BTR’de yatay eksen konumu (-180 derece ile 180 derece) ve dikey eksen zamanı temsil etmektedir [16].



Şekil 2.4: Pasif SONAR görüntüleme için kerteriz zaman ekranı.

## **2.3. Platformların Ürettiği Gürültülerin Sınıflandırılması**

LOFAR'ın ana görevi olan platformların yaymış olduğu gürültüleri tespit ve analiz etmektir. Bu gürültüler genelde yardımcı makine, gemi üzerinde bulunan cihaz ve sistemler, ana tahrik sistemi elemanları tarafından üretilirler ve bu bölümde alçak frekans gürültü kaynakları açıklanmaktadır.

### **2.3.1. Alçak Frekans Gürültü Kaynakları**

Seyir halinde bulunan suüstü ya da sualtı platformları seyir imkanlarını yerine getirmek için kendi bünyesinde bulunan cihaz ve sistemleri çalıştırmak zorundadır. Bu cihaz ve sistemler gürültü kaynakları olarak karşımıza çıkmaktadır. Genel olarak gemilerin cihaz ve sistemlerinin üretmiş olduğu gürültüler üç başlık altında tanımlanabilir.

#### **2.3.1.1. Dinamik Dengesizlik Kaynaklı Gürültüler**

Gemi bünyesinde çalışan yardımcı makine, cihaz ve sistemler hareketlerinden kaynaklı titreşimler gemi teknesine çarparak deniz ortamında yayılırlar. Yardımcı sistemlerin titreşimlerinin düşük olması sebebiyle geç tespit edilebilir ya da tespit edilemeyebilirler.

#### **2.3.1.2. Dürtü Dengesizliği Kaynaklı Gürültüler**

Gemi ana tahrik sistem elemanları olan ana makinelerden kaynaklı üretilen gürültülerdir. Dizel makinelerin çalışmasına göre yüksek titreşim üreterek makine tonelleri yani LOFAR hatlarının oluştururlar.

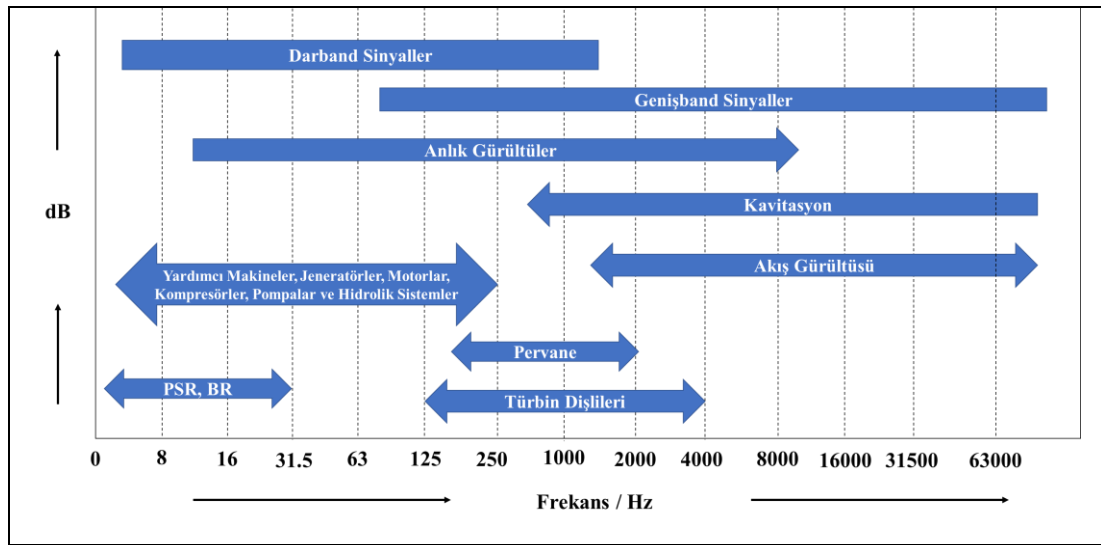
#### **2.3.1.3. Kavitasyon Gürültüsü**

Sıvı içerisinde yüksek süratle dönen pervaneler arkasında alçak basınç oluşturmaktadır. Sıvıda yer alan gazlar bu alçak basınçta ani olarak patlaması ile kavite

etkisini oluşturarak gürültü meydana getirmektedir. Kaviteasyon platformların sürat ve derinliği ile orantılı olarak tespit edilmelerine sebep olmaktadır.

### 2.3.2. Geniş Bant ve Dar Bant Sinyaller

Alçak frekans gürültü kaynakları altında bulunan üç başlık iki ana grupta yer almaktadır. Denizaltılar ve suüstü gemileri 0 kHz'den başlayıp alçak frekans bandı içinde kalan ve ayırt edici dar ve geniş bant gürültüleri yaymaktadırlar. Şekil 2.5'te belirli gürültü gruplarının frekans aralığı diyagramı görülmektedir [17].



Şekil 2.5: Belirli gürültü gruplarının frekans aralığı diyagramı.

## 2.4. Veri Kümeleri ve Performans Değerlendirme Kriterleri

Bu bölümde kullanılan açık kaynak veri kümeleri özellikleri ve performans değerlendirme kriterleri açıklanmaktadır.

### 2.4.1. Veri Kümeleri

Askeri alanda yapılan çalışmalar sebebiyle elde edilen veri ve bilgiler gizlilik sebebiyle açık kaynak olarak paylaşılamamaktadır. Araştırmacılar genellikle kendi ekipmanları ya da sentetik veriler kullanarak araştırmalarını gerçekleştirmektedir. Askeri alanda yapılan çalışmalar çoğu zaman ekipman, zaman, lojistik ve en önemlisi

araştırmacı bilgi birikimlerine yapılan çok maliyetli yatırımdır. Bu sebepler ve ülke menfaatleri düşünülerek gerçek verilerin açık kaynak olarak paylaşılması gerçek veriye ulaşılması ve araştırmacıların bu alanda çalışma yapmasını zorlaştırmaktadır. Son yıllarda sualtı akustik sinyalleri ekipmanlarının yaygınlaşması sivil alanda yatırımların artmasıyla birlikte sualtı akustik sinyalleri kullanılarak yapılan değişim tespiti, hedef sınıflandırma, deniz kirliliği ve trafik yoğunluğu çalışmaları ile çeşitli veri kümelerine açık kaynak olarak ulaşılabilir.

#### •ShipsEar

Bir sualtı gemisi gürültü veritabanı: ShipEar [6] veri kümesi 11 tip farklı gemiden oluşan ve ortam gürültülerinden oluşan 90 adet kayıt içermektedir. Farklı hava koşullarını içermesi, otomatik kimliklendirme sistemi (Automatic Identification System-AIS) bilgilerini içermesi en büyük avantajları olarak değerlendirilmektedir. Otomatik kimliklendirme sistemi kullanılarak hedef takibi algoritmaları geliştirilmesine katkı sağlayacağı düşünülmektedir. Veri kümesine ait bilgilerin bulunduğu internet sitesi: (<http://atlantic.uvigo.es/underwaternoise/>) analizi kolaylaştırmaktadır. En az 9 saniye en fazla 11 dakikadan oluşan kayıtlar digitalHyd SR-1 marka hidrofona kullanılarak alınmıştır.

Tablo 2.1: ShipEar veri kümesi özeti.

Sınıf	Gemi Tipi	Gemi Sayısı	Kayıt Başına Süre (Sn.)
A	Balıkçı tekneleri, troller, midye tekneleri, römorkörler ve taraklar	17	1729
B	Motorlu tekneler, pilot tekneler ve yelkenli tekneler	19	1435
C	Yolcu feribotları	30	4054
D	Okyanus gemileri ve ro-ro gemileri	12	2041
E	Arka plan gürültü kayıtları	12	923

Tablo 2.2: DigitalHyd SR-1hidrofona özellikleri.

Karakteristik	Değerler
Bant genişliği	1 Hz ila 25.8 kHz / 1 Hz ila 51.6 kHz
Dinamik Aralık	46.3 dB
Duyarlılık	-193.5 dB re 1V/1 uPa
Örnekleme frekansı	52734 Hz
Dahili Depolama	16 GB

#### •DeepShip

DeepShip [7] veri kümesi 265 farklı geminin 4 sınıf oluşturularak 47 saat 4 dakika kayıt süresi ile arařtırmacılar için açık kaynak yüksek kayıt süresine sahip en büyük veri kümesidir. icListen smart marka Hidrofon kullanılarak kayıtlar alınmıştır.

Tablo 2.3: DeepShip veri kümesi özeti.

Gemi Tipi	Gemi Sayısı	Toplam Zaman	Toplam Kayıt	Kayıt Başına Süre (Sn.)
Kargo Gemisi	69	10 saat 40 dakika	110	180-610
Römorkör	17	11 saat 17 dakika	70	180-1140
Yolcu Gemisi	46	12 saat 22 dakika	193	06-1530
Tanker	33	12 saat 45 dakika	240	06-700

Tablo 2.4: icListen akıllı hidrofonun özellikleri.

Karakteristik	Değerler
Bant genişliği	1 Hz ila 12 kHz
Dinamik Aralık	120 dB
Duyarlılık	- 170 dBV re. $\mu$ Pa
Örnekleme frekansı	32 kHz
Güç Giriş	12-24 Vdc, 0.8 W
Dahili Depolama	32 GB

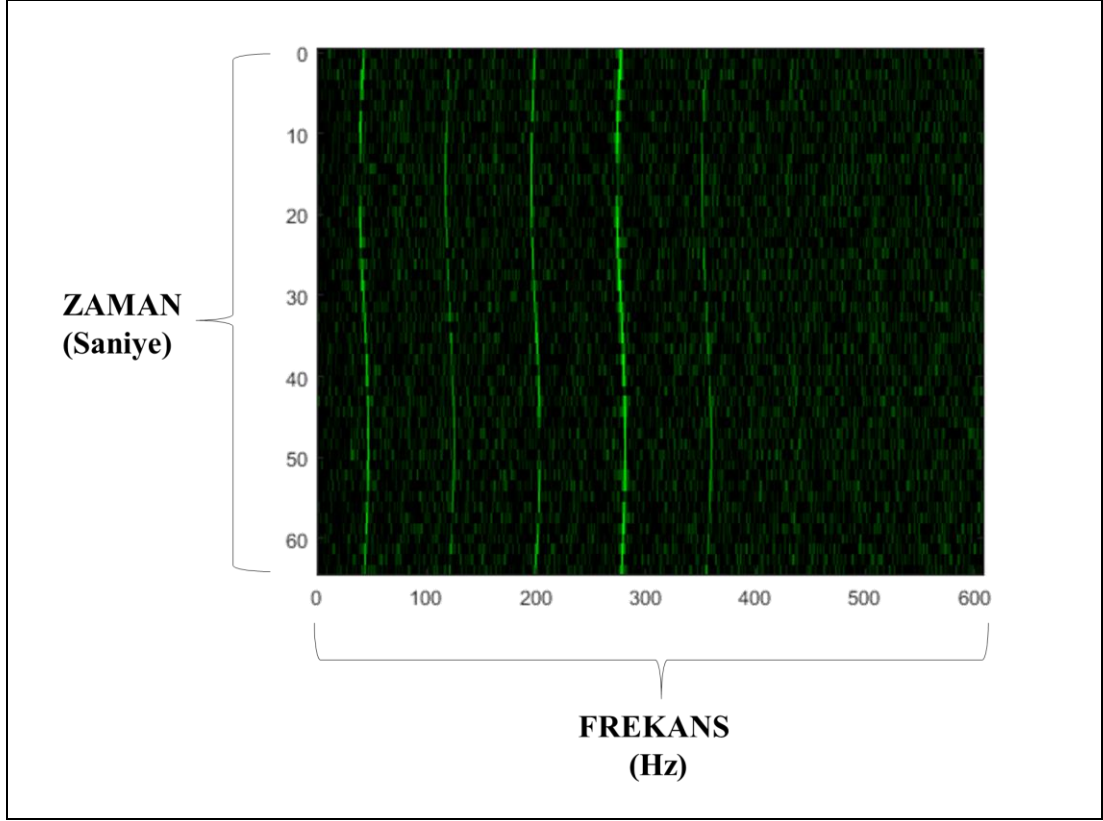
#### •Sentetik Veri Kümesi

Bu veri kümesi, başlangıç parametreleri kullanıcı tarafından belirlenerek sinüs dalgaları ile sentetik veriler oluşturulmuştur. Şekil 2.6’da sentetik veri akış şeması gösterilmektedir.



Şekil 2.6: Sentetik veri akış şeması.

Elde edilen sentetik veriler gerçek verilere benzer gemi sesleri ile 4 sınıf oluşturularak farklı gemi makine, cihaz ve sistem durumlarını içeren senaryolar oluşturulmuştur. Şekil 2.7’de örnek sentetik veri ile LOFAR algoritması kullanılarak görüntü elde edilmiştir. LOFAR Algoritması ve geliştirilmesi Bölüm 3’te anlatılmıştır.



Şekil 2.7: Örnek sentetik veri LOFAR görüntüsü.

## 2.4.2. Performans Değerlendirme Kriterleri

Bir nesne tespit algoritmasının performansının etkili şekilde ölçülmesi, farklı algoritmalarla objektif olarak karşılaştırma yapabilmek için önemlidir. Bu yüzden literatürde yer alan farklı yaklaşımlardan yararlanılmıştır. Başarı matrisleri, sınıflandırıcı için çıktı sınıf sayısı olarak elde edilir yani pozitif veya negatiftir. İki tür hata mümkündür. Hedef sınıf, hedef olmayan sınıf olarak veya hedef olmayan sınıf, hedef sınıf olarak yanlış etiketlenebilir. Eğer hedef sınıflandırıcıda doğru sınıflandırılırsa doğru pozitif (DP) olarak, Hedef olmayan, hedef olmayan olarak sınıflandırılırsa doğru negatif (DN) olarak, eğer sınıflandırıcı hedefi, hedef olmayan olarak sınıflandırılırsa yanlış negatif (YN) olarak ve son olarak sınıflandırıcı hedef olmayana, hedef olarak sınıflandırır ise yanlış doğru (YD) olarak adlandırılır. Tablo 2.5'te görüldüğü üzere bütün olası çıktılar görülmektedir.

Tablo 2.5: Olası çıktıların durumları.

		Gerçek	
		Doğru	Yanlış
Tahmin	Doğru	Doğru Pozitif	Yanlış Pozitif
	Yanlış	Yanlış Negatif	Doğru Negatif

$$\text{Doğru Pozitif Oranı} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (2.1)$$

$$\text{Yanlış Pozitif Oranı} = \frac{\text{Yanlış Pozitif}}{\text{Yanlış Pozitif} + \text{Doğru Negatif}} \quad (2.2)$$

$$\text{Doğru Negatif Oranı} = \frac{\text{Doğru Negatif}}{\text{Yanlış Pozitif} + \text{Doğru Negatif}} \quad (2.3)$$

$$\text{Yanlış Negatif Oranı} = \frac{\text{Yanlış Negatif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (2.4)$$

Doğru pozitif oranları sistemin nesnenin ortamda bulunduğu kareleri doğru olarak tespit etme oranıdır. Doğru negatif oranları ise sistemin nesnenin ortamda bulunmadığı kareleri doğru olarak tespit etme oranıdır. Bu oranlar ise Denklem 2.1-2.4 kullanılarak hesaplanmaktadır.

### 2.4.3. Yüksek Boyutlu Verilerin Görselleştirilmesi

t-SNE (t-Distributed Stochastic Neighbor Embedding), yüksek boyutlu verileri görselleştirmek kullanılan algoritmadır. Algoritma yüksek boyutlu verileri birbirine benzerliklerine göre yakın olanları düşük noktalara düşürerek görselleştirmeyi sağlamaktadır. t-SNE işlevi, yüksek boyutlu verilerden düşük boyutlu nokta oluşturarak yüksek boyutta görselleştirilemeyen veriyi düşük boyutta görselleştirilmesini sağlamaktadır.

Van der Maaten ve Hinton araştırmacılarının geliştirmiş olduğu t-SNE algoritması [18] adımları aşağıda sunulmuştur.

Yüksek boyutlu noktalar arasındaki ikili mesafeler hesaplanarak  $d(x_i, x_j)$  ile gösterilmektedir. Her bir yüksek boyutlu nokta  $i$  için bir standart sapma,  $\sigma_i$  oluşturulur, böylece her noktanın şaşkınlığı (perplexity) önceden belirlenmiş bir seviyede olur.  $i$  verilen  $j$ 'nin koşullu olasılığı Denklem 2.5'te tanımlanır.

$$p_{j|i} = e^{(-d(x_i, x_j)^2 / 2\sigma_i^2)} / \sum_{k \neq i} e^{(-d(x_i, x_k)^2 / 2\sigma_i^2)}, p_{i|i} = 0 \quad (2.5)$$

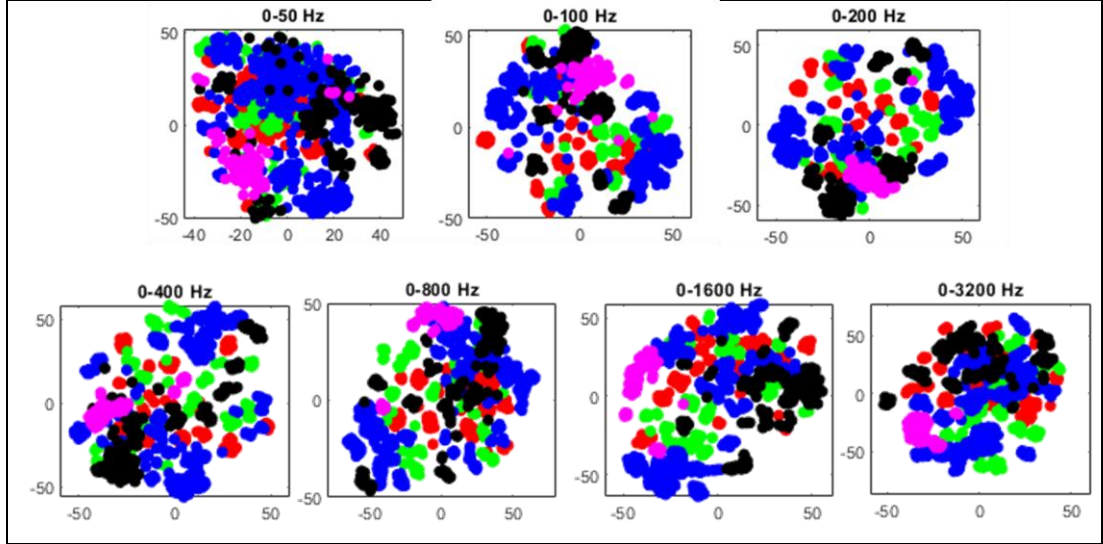
Koşullu olasılıkları simetrik olarak ortak olasılık  $p_{ij}$  Denklem 2.6'da hesaplanır.

$$p_{ij} = \frac{p_{j|i} + p_{i|j}}{2N} \quad (2.6)$$

$P_i$ ,  $x_i$  veri noktası verilen diğer tüm veri noktaları üzerindeki koşullu olasılık dağılımını temsil eder. Dağılımın karmaşıklığı Denklem 2.7'de gösterilmektedir.

$$karmaşıklık(P_i) = 2^{H(P_i)} \quad H(P_i) = - \sum_j p_{j|i} \log_2(p_{j|i}). \quad (2.7)$$

Yüksek boyutlu uzaydaki bir Gauss dağılımı ile düşük boyutlu uzaydaki  $t$  dağılımı arasındaki Kullback-Leibler farklılığını en aza indirmek için düşük boyutlu noktaları yinelemeli olarak güncellenerek hesaplama gerçekleştirilir. Her veri noktasına iki veya üç boyutlu bir haritada konum vererek yüksek boyutlu verileri görselleştiren t-SNE adlı yeni bir tekniği ile görselleştirme yapılır [18]. Bu çalışma kapsamında Şekil 2.8'de ShipEar veri kümesi Tablo 2.1'de yer alan 5 sınıfa ait t-SNE algoritması kullanılarak verilerin farklı frekans aralıklarında elde edilen grafikler gösterilmektedir. Görselleştirme ile verilerin dağılımları analiz için Bölüm 4'te gösterilmektedir. Yüksek boyutlu veri görselleştirmesini kullanarak literatürde mevcut çalışmalar arasında [7], [19] yer almaktadır.



Şekil 2.8: ShipEar veri kümesi tablo 2.1’de yer alan 5 sınıfa ait verilerin farklı frekans aralıklarında t-SNE algoritması kullanılarak elde edilen grafikler.

## 2.5. LOFAR Literatür Araştırması

LOFAR algoritması kullanılarak literatürde mevcut çalışmalar arasında temel bileşen analizi ile [20], nöral sınıf algılama kapasitesinin artırılması [21], bağımsız bileşen analizine dayalı [13], [16], yenilik dedektör elde etmek için tek sınıf SVM [22], yenilik tespiti için yığılmış otomatik kodlayıcılar (SAE) [23] yer almaktadır.

Akustik sensörler tarafından kaydedilmiş ve ele alınması gereken birçok ses bileşeni vardır. Hedeflerin imzası olarak kullanılacak ilgili düşük frekanslı ses bileşenlerini seçmek önemlidir. Sualtı ve suüstü savaş platformlarının deniz görevleri olan angajman, koruma, gözetleme ve refakat görevlerini yerine getirmesi için çevresel kaynaklı dağınık sinyal ortamından hedef imzayı tanımlayan araştırmalardan yararlanılması açısından literatürde mevcut çalışmalardan yararlanılmaktadır. Hedeflere ait parmak izi niteliğinde olan LOFAR öznelik olarak değerlendirilmektedir.

Bu yöntem, ham ses verileriyle dönüştürülen LOFAR spektrumunun özelliklerini çıkararak hedefi tanımlar [24]. Literatürde yer alan çalışmalar ve analizleri sonucu elde edilen bilgiler ile gerçekleştirilerek, geliştirilmektedir.

Sualtı akustik hedef tanıma için [25], [26], [27] çalışmaları spektogramı kullanarak analizler yapılmıştır. İlgili çalışmaların LOFAR algoritmasıyla bazı benzerlikleri bulunmaktadır ancak doğrudan bir LOFAR algoritması kullanımı söz

konusu değildir. Farklardan biri, bu çalışmalarda kısa süreli Fourier dönüşümü kullanılmıştır. Bu çalışmada ise LOFAR algoritmasında Fourier dönüşümü doğrudan uygulanmıştır. William Soares ve arkadaşlarının [20] yapmış olduğu çalışmada kendi kaydetmiş olduğu 22050 Hz örnekleme frekansına sahip verileri kullanmışlardır. Gemi gürültülerindeki anlamlı verinin 2.87 kHz olarak değerlendirip ön işlemler gerçekleştirmişlerdir. Ön işlem aşamasında ilk olarak 22050 Hz'den 7350 Hz'e yeniden örnekleyerek 2048 noktalı Fourier dönüşümünü kullanmaktadırlar. 2048 noktanın 1024 noktasına sınırlandırarak operatöre sadece 800 noktasını göstermesi elde edilen önemli kazanımlar arasında yer almaktadır. Sınıflandırma için 800 noktadan sadece 400 nokta kullanması veri kaybına yol açtığı açıkça görülmektedir.

Literatür araştırmasında SONAR operatörüne makine gürültüsünü sağlayan ve DC'den 15.625 Hz'ye kadar uzanan bir geniş bant analizidir [10]. Literatür çalışmalarında kullanılan genel LOFAR algoritması Şekil 2.9'da görülmektedir [10].



Şekil 2.9: Genel LOFAR algoritması.

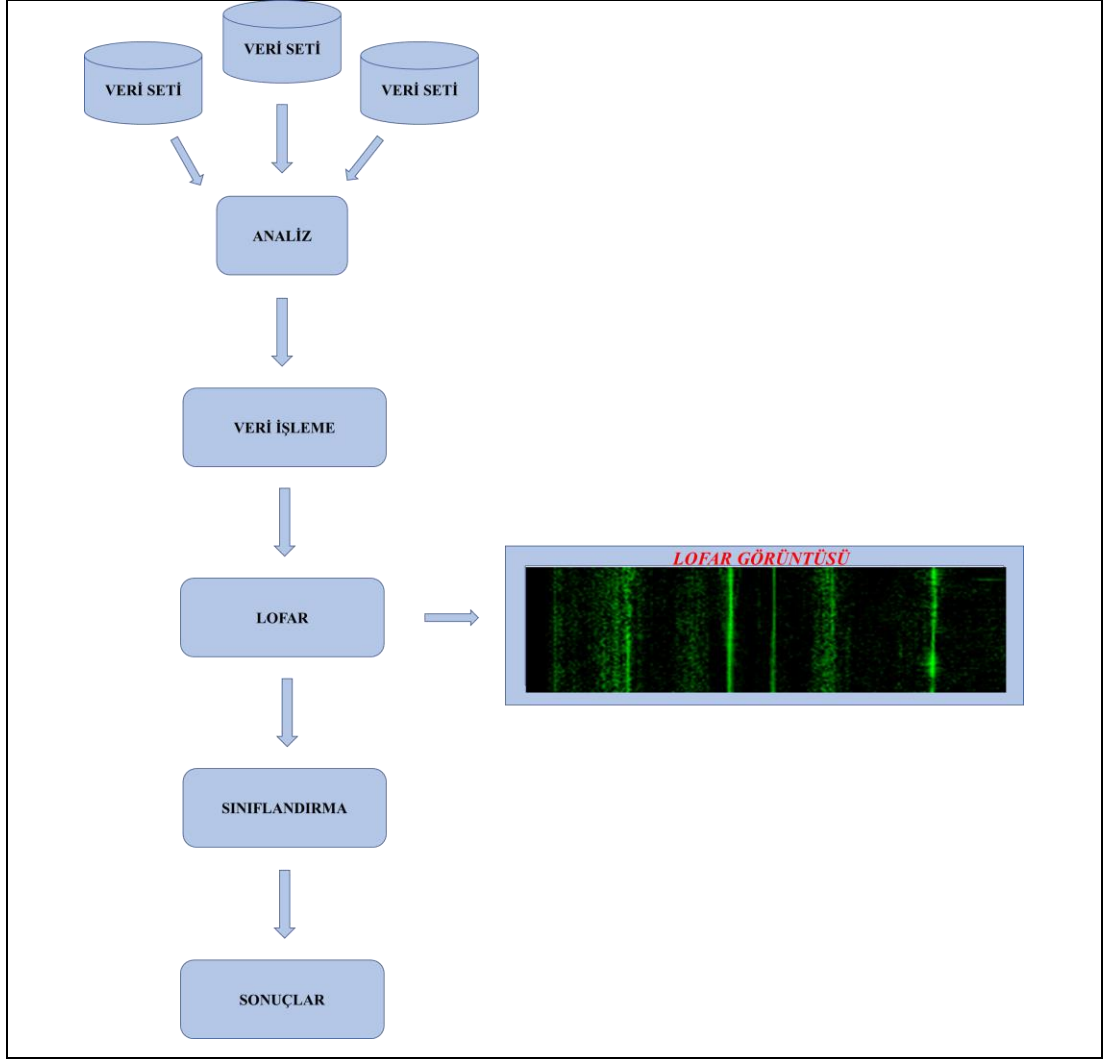
Mello ve arkadaşları azaltılmış bir örnekleme frekansı (7.35 kHz) elde etmek için ardışık 1.024 noktalı bloklara (üst üste binmeden) bir kırılım uygulanması, yayılan gürültü [23], DC ile 2.87 kHz aralığında genlik spektrumunu elde etmek için işlenerek [20] LOFAR için 0-2.87 Hz frekansları arasında çalışmışlardır. Farklı sonar uygulamaları frekans aralıklarında askeri pasif sonar uygulamalarının 10Hz – 25kHz aralığında olduğuna değinmesi [28] bu frekans aralıklarının önemi ve doğruluğunu gözler önüne sermektedir.

Bahsi geçen çalışmaların çoğunda araştırmacılara açık veri kümesi üzerinde çalışılmamıştır ve bu nedenle kıyaslama imkanı bulunmamaktadır. Bu çalışmada ise araştırmacılara açık olan veri kümeleri kullanılmıştır. Kullanılan veri kümeleri Bölüm 2.5.1'de anlatılmaktadır. Açık veri kümesi kullanan çalışmaların performansı Tablo 2.6'da gösterilmektedir. Tablo 2.6'da mevcut açık kaynak olarak ulaşılabilir ShipEar, DeepShip ve gizli veri kümeleri ile çalışma performansları gösterilmektedir. Y1, Y2, Y3, Y4, Y5 ve Y6 farklı yöntemleri ve farklı öznitelik ile denenerek sonuçları denediklerini göstermektedir.

Tablo 2.6: Literatürde mevcut çalışmalar ve performansları.

Veri Kümesi	Mevcut Çalışmalar	Yöntem	Doğruluk (%)
ShipEar	Santos vd. [6]	Y1	75.4
	Yuan vd. [19]	Y1	62.51
		Y2	82.82
		Y3	89.75
	Liu vd. [29]	Y1	80.0
		Y2	82.0
DeepShip	Irfan vd. [7]	Y1	70.18
		Y2	77.53
		Y3	59.58
		Y4	59.85
		Y5	73.10
		Y6	73.59
Brezilya Donanması	Mello vd. [23]	Y1	85.0
Admiral Paulo Moreira Marine Research Institute	De Moura vd. [22]	Y1	77.90

Bu çalışmada askeri pasif sonar uygulaması olarak operatöre destek olması amacıyla otomatik sınıflandırma çalışması yapılmıştır. Sualtı akustik ses verisine sırasıyla dijital sinyal işleme ve görüntü işleme adımları uygulanarak LOFAR görüntüsü ve sinyali elde edilmiştir. Şekil 2.10'da çalışma akış şeması gösterilmektedir. Açık kaynak ve üretilen sentetik veriler kullanılarak veriler üzerinde analizler ve sonrasında farklı sınıflandırıcılar ile sonuç çalışmalarından oluşmaktadır.



Şekil 2.10: Çalışma akış şeması.


## 2.6. Sınıflandırma Yöntemleri

Bu çalışma kapsamında farklı sınıflara ait hedefler için literatürde mevcut bilinen sınıflandırıcılar kullanılmıştır. Bu bölümde kullanılan sınıflandırma yöntemleri olan KNN (K Nearest Neighbours), SVM (Support Vector Machine) yöntemleri açıklanmıştır.

### 2.6.1. KNN (K Nearest Neighbours)

K en yakın komşuluk yöntemi sınıflandırma ve regresyon problemleri için kullanılan makine öğrenme algoritmasıdır. KNN, veri kümesi oluşturarak nesnelere

veri kümesindeki en yakın komşularının sınıflarına farklı uzaklık metrikleri kullanarak sınıflandırmaktadır. KNN birbirine yakın hedeflerin benzer olduğunu tahmin ederek sınıflandırmayı gerçekleştirir. Şekil 2.11’de görüldüğü gibi K en yakın komşuluk yöntemi ile P yeni sınıfını en yakın sınıflara olan mesafesini kestirerek sınıflandırma gerçekleştirilir.

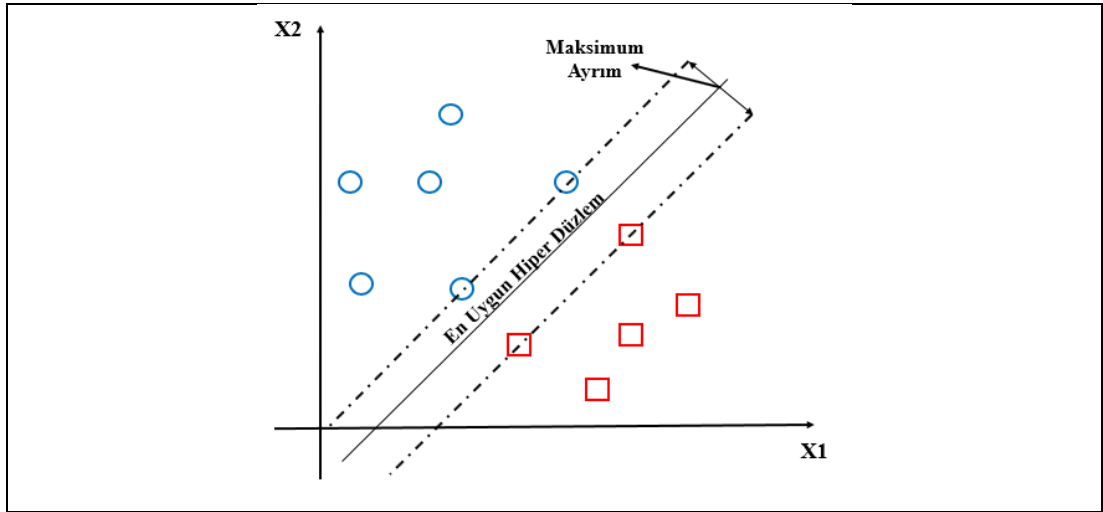


Şekil 2.11: KNN en yakın komşuluk sınıflandırıcısı.

En yakın komşuyu bulmak için Öklid, şehir bloğu, kosinüs ve Chebyshev gibi mesafe ölçümleri kullanılır. Bu çalışmada kosinüs mesafe ölçümü kullanılmıştır. En yakın komşuluk katsayısı farklı değerlerde denenerek en yüksek başarımlı sonuç bulunmuştur.

## 2.6.2. SVM (Support Vector Machine)

Türkçe ismi Destek Vektör Makinası (DVM), sınıflandırma ve regresyon problemleri için kullanılabilen kontrollü bir makine öğrenme algoritmasıdır. DVM, iki ayrı sınıfın veri kümeleri verildiğinde, iki sınıf arasındaki ayrımın maksimum olduğu yerlerde bir hiper düzlem oluşturur. Böylece DVM, iki sınıfı ayırmak için kullanılacak en uygun hiper düzlemi öğrenir. DVM algoritmasının çalışması, eğitim örneklerine en büyük minimum mesafeyi veren hiper düzlemin bulunması prensibine dayanmaktadır. Bu nedenle, optimal ayırıcı hiper düzlem, eğitim verisinin ayrımını Şekil 2.12’de görüldüğü gibi en üst düzeye çıkarır [30].



Şekil 2.12: Hiper düzlemin oluşturulması.

Hiper düzlem, Denklem 2.8'de görüldüğü gibi ifade edilmektedir.

$$f(\mathbf{x}) = \beta_0 + \beta^T \mathbf{x} \quad (2.8)$$

$\beta$ , ağırlık vektörü olarak bilinir. En uygun hiper düzlem,  $\beta$  ve  $\beta_0$ 'ın ölçeklendirilmesi ile sonsuz sayıda farklı yollarla ifade edilebilmektedir. Hiper düzlem, olası tüm ifadeler arasından Denklem 2.9 ile verilen şartı sağlayacak şekilde seçilir.

$$|\beta_0 + \beta^T \mathbf{x}| = 1 \quad (2.9)$$

Burada  $\mathbf{x}$ , hiper düzleme en yakın eğitim örneklerini, destek vektörleri temsil eder. Bir  $\mathbf{x}$  noktası ile hiper düzlem arasındaki mesafe  $d$  kullanılarak hesaplanır. Destek vektörlere olan uzaklık Denklem 2.10'daki gibi gösterilmektedir.

$$d = d_{\text{destek vektör}} = \frac{|\beta_0 + \beta^T \mathbf{x}|}{\|\beta\|} = \frac{1}{\|\beta\|} \quad (2.10)$$

Şekil 4.2'de marjın yani maksimum ayırımın en yakın örneklere olan uzaklığın iki katı olduğu görülmektedir ve gösterilen  $M$ 'yi maksimize edilmesi, Denklem 2.11'de verilen  $L(\beta)$  fonksiyonunun en aza indirgenmesi ile aynı anlama gelmektedir.

$$M = \frac{2}{\|\beta\|}, \min L(\beta) = \frac{1}{2} \|\beta\|^2, \quad y_i(\beta_0 + \beta^T x) \geq 1, \quad \forall_i \quad (2.11)$$

Burada  $y_i$  eğitim örneklerinin etiketlerinin her birini temsil etmektedir [30], [31]. SVM, veriyi sadeleştirme yaparak istatistiksel öğrenme teorisi kullanarak veri üzerinde kestirim yapmaktadır. Basit ve hızlı olarak kullanılabilir ayrıca doğrusal olmayan yüksek boyutlu verileri sınıflandırmak için kullanılmaktadır.

### 2.6.3. Doğrusal Diskriminant Sınıflandırıcı

Doğrusal diskriminant analizi, mucidi R. A. Fisher'in adını taşıyan Fisher diskriminantı olarak da bilinir [32]. Diskriminant analizi, hızlı, doğru ve yorumlanması kolay olduğu için denemesi gereken popüler bir sınıflandırma algoritmasıdır. Diskriminant analizi geniş veri kümeleri için iyi sonuçlar vermektedir. Diskriminant analizi, farklı sınıfların farklı Gauss dağılımlarına dayalı veriler ürettiğini varsayar. Bir sınıflandırıcıyı eğitirken her sınıf için bir Gauss dağılımının parametrelerini tahmin eder. Doğrusal Diskriminant (Linear Discriminant) ile sınıflar arasında doğrusal sınırlar oluşturur. R. A. Fisher tarafından geliştirilen bir sınıflama metodu, basit olmasına rağmen kompleks problemlerde iyi sonuçlar üreten bir model olarak tanımlanmaktadır. Doğrusal Diskriminant, hedefler arasında en iyi şekilde ayıran değişkenleri lineer bir kombinasyonunu aramaya dayanır. Fisher diskriminantının çoklu sınıflar için giriş alanının boyutsallığının  $D$ , sınıfları  $K$  ile ifade edilir ve Denklem 2.12 tanımlanır. Burada  $W$  ağırlık vektörleri,  $x$  verileri ve  $y$  vektörü elde edilir.

$$y = W^T x \quad (2.12)$$

Kovaryans matris Denklem 2.13'te görüldüğü gibidir.  $m$ , toplam veri kümesinin ortalamasıdır.

$$S_w = \sum_{k=1}^K S_k, \quad S_k = \sum_{n \in C_k} (x_n - m_k)(x_n - m_k)^T \quad K > 2 \quad (2.13)$$

Y için bir eşik koyarsak ve  $y > -w_0$  sınıf  $C_1$  ve aksi halde sınıf  $C_2$  olarak iki sınıf için sınıflandırılır ve çoklu sınıflar için uygulanabilir [33].

Bu çalışma kapsamında kullanılan grup sınıflandırma (ensemble classifier) için alt uzay diskriminant sınıflandırıcıları topluluğu (ensemble subspace discriminant classifier) kullanılmaktadır. Grup metodu için alt uzay, öğrenme tipi diskriminant kullanılmaktadır.

### 3. LOFAR ALGORİTMASI VE GELİŞTİRİLMESİ

İkinci Dünya Savaşında denizaltıların elde ettiği başarılar sonrasında uzak mesafelerden öncelikle denizaltıları tespit etmek amacıyla LOFAR ile ilgili ilk çalışmalar 1950 yılında başlamıştır. Bu maksatla farklı tip denizaltıların üretmiş oldukları farklı seslerin elektronik ortamdaki kayıtlarının alınarak bunların görsel analizlerinin yapılmasına çalışılmıştır. Elde edilen bu kayıtların görsel analizi 1950 yılından önce icat edilen ses spektrum analiz cihazı ile yapılması nedeniyle bu işlem konuşma dilinde LOFAR ya da spektrum analizi olarak adlandırılmıştır.

LOFAR alçak frekans analizi ve kaydının kısaltmasıdır. LOFAR denizaltılar ve su üstü gemilerinin uzak mesafelerden tespit edilmesine ve gürültülerinin analiz edilerek sınıflandırılmasına imkan sağlar. Analiz sonucunda gürültüler sonucu zaman-frekans ile temsil edilmesi sonucunda hatları/tonelleri pasif sonar uygulamalarında LOFARGRAM ile incelenebilmektedir.

Su üstü gemileri ve denizaltılar, 0 Hz den başlayıp alçak frekans bandı içinde kalan ayırt edilebilen geniş band gürültüleri yayarlar. LOFAR'ın ana görevi bu ayırt edilebilen gürültüleri tespit ve analiz etmektir. Bu gürültüler genelde ana tahrik sistemi elemanları (dizeller ve türbinler) ve yardımcı makinalar (jeneratörler, AC/DC makinalar) tarafından üretilirler. Ana tahrik sistemi tarafından üretilen bu gürültülerin alçak frekansta olması uzak mesafelerden tespit edilmesini sağlar. Ayrıca makinalar tarafından üretilen gürültüler makinanın karakteristik özelliğini taşıdığından sınıflandırma için önemli bir ipucudur ve hedefe ait parmak izi olarak tanımlanır.

#### 3.1. LOFAR

Alınan gemi gürültüsü frekans alanına dönüştürülür ve zamana karşı kısa süreli güç spektrumları olarak görüntülenir. Buna LOFARGRAM, düşük frekans analizi ve kaydının kısaltmasıdır. Belirli bir zaman aralığı için yalnızca tek bir hedef görüntülenebilir [28]. Şekil 3.1'de görüldüğü üzere ShipEar veri kümesine ait 49 numaralı geminin LOFAR görüntüsü yer almaktadır. Yatay eksen frekans, dikey eksen zamanı temsil ederken görüntü üzerinde koyu hatlar genlikleri göstermektedir.

- Frekans

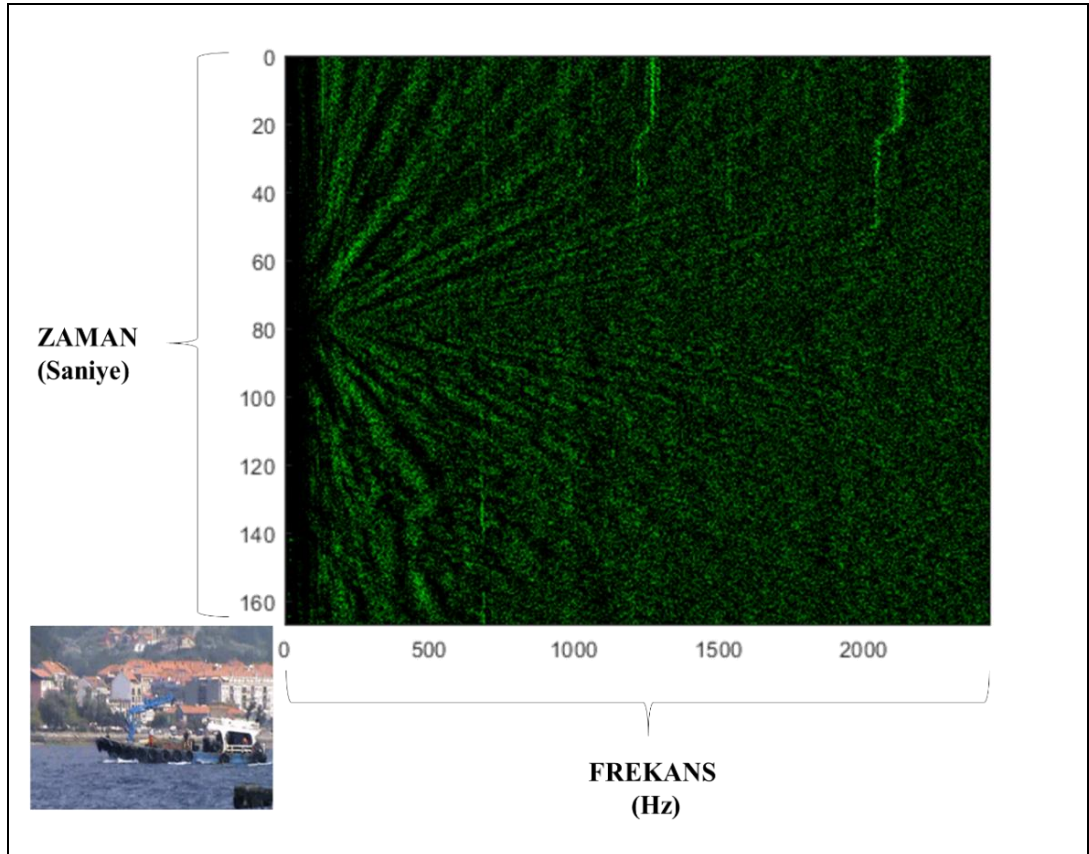
LOFARGRAM üzerinde sağdan sola doğru artan yatay spektrumdur.

- Genlik

LOFARGRAM, frekansa ilave olarak sesin genliğini de gösterir. Ses enerjisinin genliği büyüdükçe LOFARGRAM üzerindeki hat daha koyu şekilde gözükmetedir. LOFARGRAM'da hedefe ait LOFAR hattının tespit edebilmek için genliğinin çevre gürültüsünden daha büyük olması gerekmektedir.

- Zaman

LOFARGRAM kaydının bilgi güncelleştirilmesi yukarıdan aşağı doğru yapıldığında son bilgi en aşağıda yer alan bilgidir.



Şekil 3.1: ShipEar veri kümesi 49 numaralı geminin LOFAR görüntüsü.

### 3.1.1. LOFAR Görüntülerini Etkileyen Faktörler

LOFAR görüntülerini ortam gürültüleri, hedefin hareketleri (sürat değişimi, cihaz ve sistemlerinin açık/kapalı durumları, hedefin yönü (yaklaşma/uzaklaşma) ve doppler etkileri etkilemektedir.

- Doppler Etkisi

Kaynak ve sensör arasındaki nispi hareketten kaynaklanan etkiyi ifade etmektedir. Ses kaynağı sensöre doğru hareket ediyorsa zaman içinde kaynağın ürettiğinden daha fazla saykılı alacaktır. Kaynak uzaklaşıyorsa tersi bir durum olacaktır.

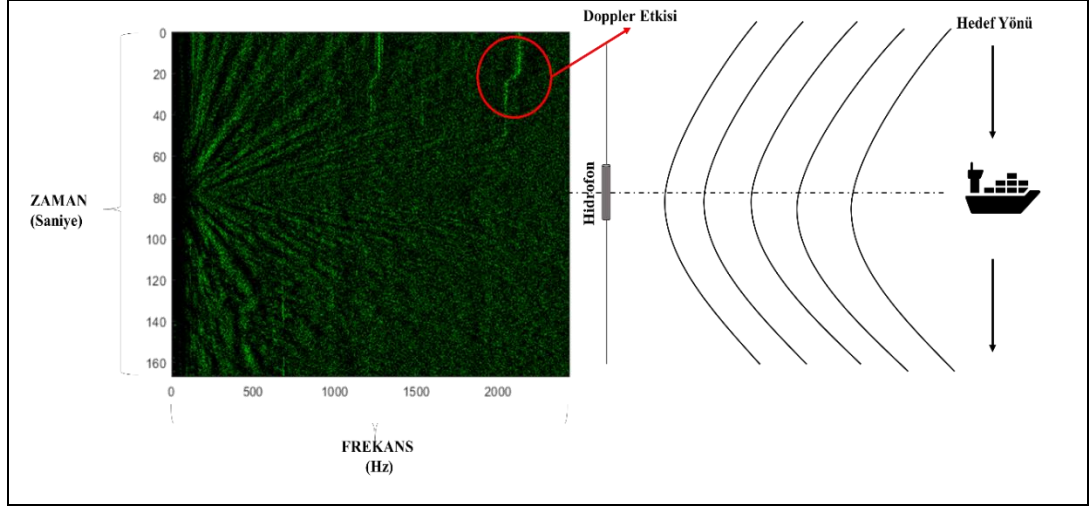
- Hedefin Hareketleri

Hedefin hareketlerinden kaynaklı LOFAR görüntüleri etkilenmektedir. Hedefin, hidrofona yakın, uzak ya da hidrofona paralel, dikey olarak hareket etmesi durumlarında LOFAR görüntülerinden anlaşılabilir. Zaman farklılıklarında hedefin hidrofona en yakın olduğu durum LOFAR görüntülerinden tespit edilebilmektedir.

- Çevre Etkileri

Rüzgâr, dalga durumu, yağış ve deniz trafiği gibi farklı ortamsal etkiler LOFAR görüntülerini etkileyebilmektedir.

Şekil 3.2’de görüldüğü gibi hedefin hidrofona paralel hareket etmesi sonucunda azami yaklaşma mesafesi (CPA ing. Closest Point of Approach) 80. saniyede (yatay kesikli çizgi) en yakın olduğu ve bu hareketinden dolayı LOFAR görüntüsünde banyo küveti etkisi yarattığı görülmektedir. Ayrıca kırmızı ile gösterilen Doppler etkisi görülmektedir.



Şekil 3.2: ShipEar veri kümesi 49 numaralı geminin hedef hareketleri banyo küveti (bathtub) LOFAR görüntüsü.

### 3.1.2. LOFAR Görüntüsü ile Sinyal Tanıma

Akustik ses sinyalinin LOFAR görüntüsü elde edilerek operatör tarafından incelenmesi sonucunda hedefin sınıfı tespit edilebilmektedir. Operatörün bilgi, beceri ve tecrübesi ile sınıflandırma sonucu başarılı ya da başarısız olmaktadır. LOFAR görüntüleri üzerinde bulunan hatlar ile sinyal tanıma yapılarak benzer karakteristik özelliklerini taşıyan gemiler eşleştirilmesi sonucunda sınıflandırma gerçekleştirilmektedir.


Hedefe ait frekans hatlarının LOFAR görüntüleri üzerinde sergilenmesi sonucunda operatör frekans hatlarının ölçülmesi, tekrar eden sinyal gruplarını tespit etmesi, hatların belirlenmesi ve belirgin hatların tespit edilmesi işlemleri gerçekleştirerek sinyal tanıma işlemini sağlamaktadır.

### 3.1.3. LOFARGRAM Özellikleri ve Sinyal Değişiklikleri

LOFAR hatlarının Lofargram üzerinde band genişliği, stabilite ve spektrumu SONAR operatörü için önemli bilgiler elde edilebilir ve bu alt başlıkta açıklanmaktadır.

### 3.1.3.1. Band Geniřlięi


LOFARGRAM üzerindeki hatlar geniřlik olarak oldukęa deęiřkendir. Bir hattın geniřlięi yayılan ses enerjisi boyunca frekans bandını gsterir. Bu nedenle hat geniřlięi band geniřlięi olarak adlandırılabilir. Hattın band geniřlięi saę ve sol kenarların frekansları arasındaki farktır. Őekil 3.3'te band geniřlięi farkını kırmızı oklar ile hatların kalınlıkları ile grlmektedir.



Őekil 3.3: Band geniřlięi.

### 3.1.3.2. Stabilite

Srat deęiřimleri esnasında LOFAR iinde deęiřen makine grltleri tespit edilebilir. Frekansın zamana karřı deęiřme derecesi stabilite olarak adlandırılabilir. Őekil 3.4'te kırmızı ok ile gsterilen frekans hattı stabilitesi yksek, mavi ok ile gsterilen zayıf olarak deęerlendirilmektedir.



Őekil 3.4: Stabilite.

### 3.1.3.3. Spektrum

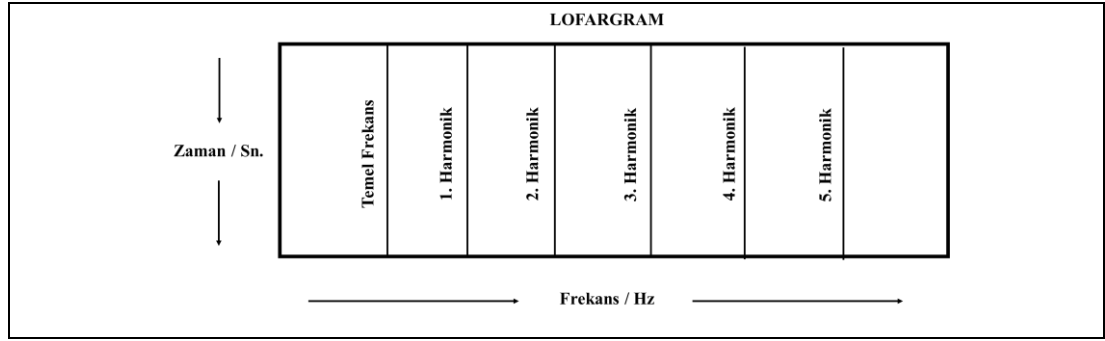
En dřk frekanstan en yksek frekansa uzanan sinyaldir.

### 3.1.4. LOFARGRAM Sinyal Hatları ile İlgili Terimler

Bu bölümde LOFARGRAM üzerinde LOFAR hatlarının sonar operatörü tarafından incelenerek elde edilen bilgiler ile ilgili önemli terimler açıklanmaktadır.

#### 3.1.4.1. Temel (Ana) ve Harmonik Frekanslar

Genel olarak bir kaynak belli bir frekansta gürültü neşrettiği zaman, bu frekanstaki gürültü katlarında da gürültüye ait hatlar tespit edilebilmektedir. Gürültüyü üreten frekansa Temel (ana) Frekans, bu frekansın katlarını takip eden hatlara da Harmonik Frekans denir. Şekil 3.5'te Temel ve Harmonik Frekanslar görülmektedir.



Şekil 3.5: Temel (Ana) ve harmonik frekanslar.

Örnek olarak 5 Hz gürültü üreten bir gürültü kaynağının frekans ve harmonik hatları; 5 Hz temel frekans, 10 Hz 1'inci Harmonik, 15 Hz 2'nci Harmonik, 20 Hz 3'üncü Harmonik ve katları olarak takip eden diğer harmonik hatları olarak tespit edilir. LOFARGRAM üzerinde temel ve harmonik frekans hatları tespit edilirken en küçük temel frekans değerinin tespit edilmesi gerekmektedir. Tespit edilen frekans hatlarını aşağıda yer alan terimler ile ifade edilmektedir.

- Harmonik Ailesi

Aynı temel frekansa sahip harmonik ilişkili olan hat gruplarına denir.

- Harmonik Sayısı

Temel frekansın katlarını gösteren sayıdır.

- Harmonik Üstünlük

En büyük genlik şiddetine sahip harmonik ilişkili olan hatlardır.

- Belirgin Frekans

LOFARGRAM'da ortam gürültüsü üzerinde sergilenebilecek şiddete genliğe sahip kaynak frekansıdır.

- Çözünürlük

LOFAR görüntüsünde iki ya da daha fazla birbirine yakın aralıklı frekans hatlarının ayırt edilmesi kabiliyetidir.

### **3.1.5. LOFAR ile Tespit Edilen Dizel Makine Terimleri**

Dizel makineler ana tahrik sistemi olan askeri, sivil uçak ve gemilerde kullanılmaktadır. Dizel makineler üzerinde buldukları hareketli parçacıklardan dolayı gürültülü çalışmaktadır. Aşağıda dizel makinelere ait terimler, anlamları ve hesaplamalar açıklanmaktadır.

#### **3.1.5.1. Dizel Makineler ile İlgili Terim Kısaltma ve Anlamları**

Dizel gürültüsünü üreten en önemli etken silindirlerdeki piston vuruşlarıdır ve bu vuruşlar darbe tipi bir titreşim üretir ve tekne üzerinden su altına yayılır [11]. LOFAR'ın temel amacı bu titreşim ve gürültüleri kestirmektir.

- Silindir Ateşleme Oranı

Bir silindirin bir saniyedeki ateşleme sayısıdır. CFR (CFR ing. Cylinder Firing Rate) makinenin bir silindiri içinde tekrarlanan ateşlerden kaynaklanır. Ses frekansı gaz yanması gücü ve vuruş gücünden oluşur.

- Krank Şaft Dönüş Oranı

Krank şaftın bir saniyedeki dönüş sayısıdır. CSR (CSR ing. Crank Shaft Rate) kaynaklı gürültü, dönen krank şaftın ve krank şafta bağlı pistonun dönüşüne bağlı olarak titreşiminden kaynaklanır. Bu titreşim ses frekansı olarak sualtında iletilir.

- Makine Devri

ERPM (ERPM ing. Engine RPM) krank şaftın bir dakikada dönüş sayısıdır.

- Makine Ateşleme Oranı

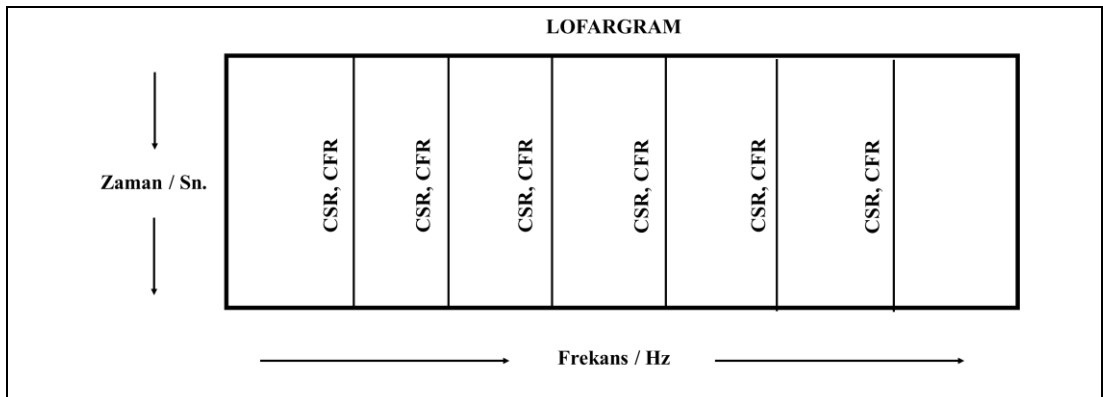
Bir saniyede bütün silindirlerdeki toplam ateşleme sayısıdır. Ses frekansları, makine silindirleri içinde birbirini takip eden ateşlemelerden dolayı EFR (EFR ing. Engine Firing Rate)'de üretilir. Ses, gaz yanma gücü ve silindir duvarlarına çarpan pistonun çarpma gücünden oluşur. Her bir ateşleme meydana geldiğinde titreşim meydana gelmektedir.

- Silindir Sayısı

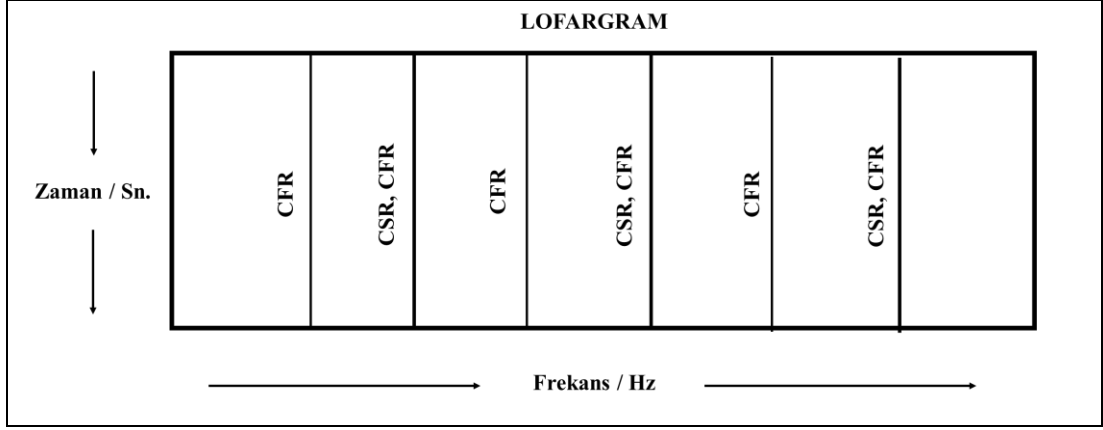
NOC (NOC ing. Number of Cylinders) makinede yer alan toplam silindir sayısıdır.

### 3.1.5.2. Dizel Makine Sinyallerinin LOFARGRAM ile Tespiti

LOFARGRAM üzerinde yeterli sinyal bilgisi mevcut olduğunda makine konfigürasyonu hakkında makine tipi, silindir sayısı tespit edilebilmektedir. LOFARGRAM'da hatları inceleyerek tesirlerine band genişliklerine göre belirlenen temel frekans ve harmonik ailesine bakarak CSR VE CFR hatlarının arasındaki boşlukları sayarak sırasıyla iki zamanlı, dört zamanlı makinelerin silindir sayıları hesaplanmaktadır. Şekil 3.6 ve 3.7'de iki ve dört zamanlı dizel makine CSR ve CFR etkileri olması beklenen hatların görselleştirilmiş halleri yer almaktadır.



Şekil 3.6: İki zamanlı dizel makine CSR ve CFR etkisi.



Şekil 3.7: Dört zamanlı dizel makine CSR ve CFR etkisi.

### 3.1.5.3. LOFARGRAM Sinyallerinin Hesaplanması

LOFARGRAM üzerinde tespit edilebilen üç ana frekans CSR, CFR ve EFR'dir.

$$CSR = \frac{ERPM}{60} \quad (3.1)$$

Denklem 3.1 kullanılarak 600 ERPM'e sahip geminin 60 Sn. 'ye bölünmesi ile CSR değerini 10 Hz olarak hesaplanmaktadır.

CFR hesabı yapılırken iki zamanlı dizel makine için Denklem 3.2 geçerli iken dört zamanlı makineler için Denklem 3.3 geçerlidir.

$$CSR = CFR \quad (3.2)$$

$$CSR = 2 \times CFR \quad (3.3)$$

EFR frekansı hesaplaması için dört zamanlı makinelerde Denklem 3.4 ile gerçekleştirilir. İki zamanlı makineler için Denklem 3.5 ile yapılmaktadır.

$$EFR = \frac{1}{2} \times CSR \times NOC = CFR \times NOC \quad (3.4)$$

$$EFR = CSR \times NOC \quad (3.5)$$

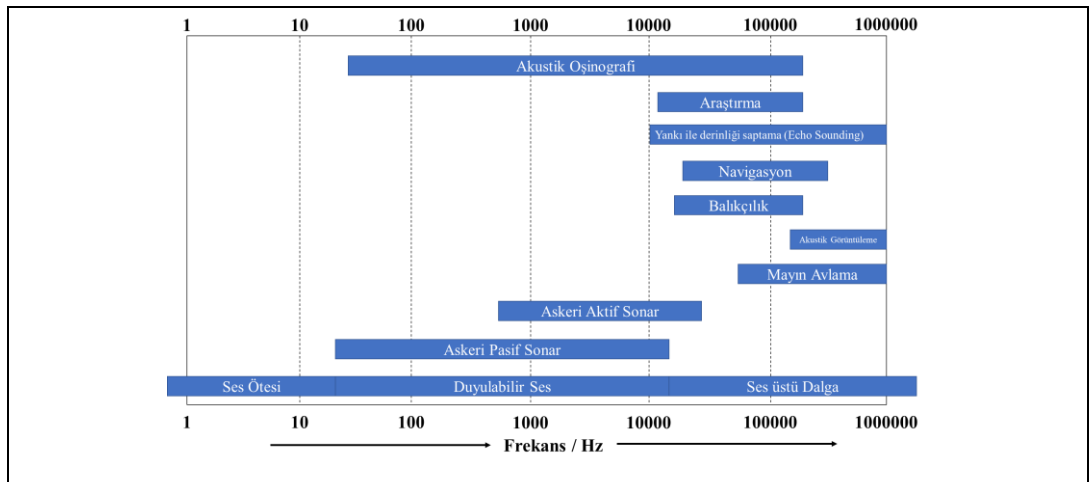
## 3.2. LOFAR Algoritması

Bu çalışmada, pasif sonar görüntüleme tekniği olan LOFAR (Low Frequency Analysis and Recording) algoritması geliştirilmiştir. Sonar operatörü hedeften gelen akustik seslere ait işaretin şiddeti, salınımlarını duysal olarak analiz edebilme yeteneğine sahip olmasının yanında akustik işaretin karakterini görsel olarak analiz etmesi son derece önemlidir.

Yoğun olarak kullanılan görüntü elemanları olarak geniş bantlı analizler için kerteriz (bearing) ve dar bantlı analizler için LOFAR görüntüleri kullanılır. LOFAR geniş bantlı hedef gürültü spektrumunda baskın olan düşük frekanslı ve ayırık tonalların daha detaylı tespiti ve analizi için kullanılır [10].

### 3.2.1. Frekans Aralıkları

Frekans, sonar sistemlerinin önemli bir parametresidir. Aktif sonar sistemlerde frekans seçimi uzamsal ve aralık çözünürlüğünü belirler. Pasif sonar sistemleri tespit edilecek kaynağın frekans aralığında çalışmak zorundadır. Şekil 3.8’de görüldüğü üzere farklı sonar uygulamaları için frekans aralıkları görülmektedir [28]. Askeri pasif sonar uygulamaları 20-20000 Hz arasında hedeflerin çalışma frekanslarını göstermektedir. Bu çalışmada pasif sonar görüntüleme birimi LOFAR için gerekli frekans aralığı belirlenmesinde dikkate alınmıştır.



Şekil 3.8: Farklı sonar uygulamaları için frekans aralıkları.

Bu çalışmada askeri pasif sonar uygulaması olarak operatöre destek olması amacıyla otomatik sınıflandırma çalışması yapılmıştır. Sualtı akustik ses verisine sırasıyla aşağıda görülen sinyal işleme ve görüntü işleme adımları uygulanarak LOFAR görüntüsü ve sinyali elde edilmiştir. Adımlar aşağıda sırasıyla anlatılmaktadır.

### **3.2.2. Alçak Geçiren Filtre**

Sualtı akustik ses verisine alçak geçiren filtre (LPF ing. Low Pass Filter) uygulanarak seçilen bir kesme frekansından daha düşük bir frekansa sahip sinyalleri ileten ve kesme frekansından daha yüksek frekanslı sinyaller zayıflatılmıştır.

### **3.2.3. Yeniden Örnekleme**

Bu çalışmada rasyonel oran ile yeniden örnekleme kullanılarak istenilen örnekleme frekansına sahip veriler elde edilmiştir. İstenen yeniden örnekleme oranının,  $P/Q$  örnekleme oranındaki bir artış için yukarı  $P$  ve aşağı  $Q$  gibi tamsayıların bir oranı ile yeniden örnekleme gerçekleştirilmektedir [34]. Yeniden örnekleme işlemi gerçekleştirilirken öncesinde alçak geçiren filtre ile uygulanmaktadır. Filtre katsayıları  $P$  ve  $Q$  tamsayılarının oranına göre yeni elde edilecek sahip veriler için oran sonucu istenilen örnekleme frekansına göre belirlenmektedir. ShipEar veri kümesinde yer alan sualtı akustik ses verilerinin örnekleme frekansı 52734 Hz'tir. DeepShip veri kümesinde yer alan sualtı akustik ses verilerinin örnekleme frekansı 32000 Hz'tir. Ses verilerinin spektrumları incelendiğinde anlamlı verilerin 4 kHz'e kadar olduğu anlaşılmıştır. Ayrıntılı analiz Bölüm 4'te anlatılmaktadır. Sualtı akustik sinyale önce örtüşme önleyici alçak geçiren filtre uygulanmış ve yeniden örneklenecek 8 kHz örnekleme frekansına sahip sinyaller elde edilmiştir.

### **3.2.4. DC Ofset Kaldırma**

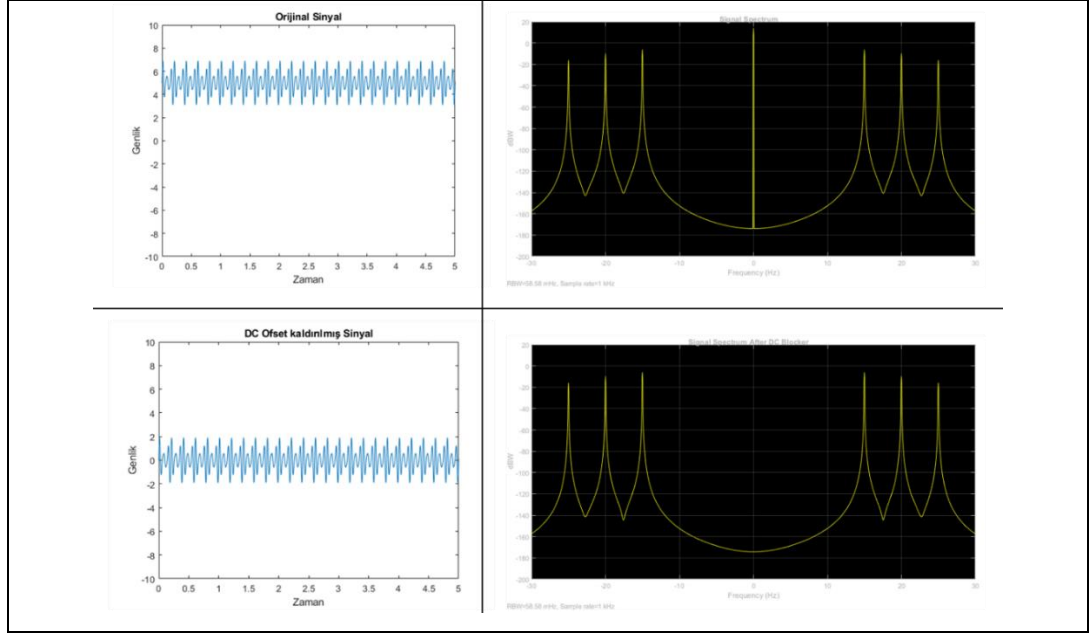
DC ofseti, sıfırdan ortalama bir genlik yer değiştirmesidir. Hidrofon ile kaydedilen akustik ses verisinin kaydedilen dalga formunun merkez sıfır noktasından uzakta bir kayması olarak görülebilir. Ses kaydında, bir DC ofseti istenmeyen bir

özelliğidir. Sesin kaydediciye ulaşmadan önce yakalanmasında meydana gelir ve normalde arızalı veya düşük kaliteli ekipmanlardan kaynaklanır. Bu, iki ana soruna neden olabilecek kayıt dalga formunun merkezinin yer değiştirmesine neden olur.

Sinyalin en gürültülü kısımları, dalga formunun tabanı yukarı taşındığından beri erken kırılacak veya duyulmayan düşük frekanslı bozulma meydana gelecektir. İlk kayıta düşük frekanslı bozulma duyulmayabilir, ancak dalga formu WAV (Waveform Audio File Format) gibi sıkıştırılmış veya kayıplı bir dijital formata yeniden örneklenirse, bu bozulmalar duyulabilir hale gelebilir. DC ofseti, olası bir tıklama, bozulma ve ses hacmi kaybı kaynağıdır. Bunun nedeni, analog sinyal dijital değerlere dönüştürülmeden önce neredeyse her zaman ses zincirinde bir yerde sabit bir voltaj kaymasıdır. Örneğin, voltaj doğrudan hatalı bir ses arabiriminden kaynaklanabilir veya ses kartına bağlı başka bir aygıttan gelebilir.

Şekil 3.9'da görülen örnekte büyük bir DC ofseti olan bir sinyale FFT (Fast Fourier Transform) uygulanmış genellikle 0 Hz frekansında büyük bir darbeye neden olduğu görülmektedir. FFT gerçekleştirilmeden önce DC ofsetini orijinal sinyalden çıkarmak için iki yöntem uygulanarak 0 Hz civarında büyük darbeye sebep olabilecek etkileri kaldırmak için; DC uzaklıklarını kaldırmanın bir yolu, yüksek geçiş filtreleri (HPF ing. High Pass Filter) kullanmaktır [35]. İşlem yükü açısından daha az karmaşık olan sinyalin ortalamasının sinyalden çıkarılarak elde edilen yeni sinyal DC kaldırma işlemi uygulanmış sinyal elde edilmiştir. Şekil 3.9'da DC ofseti kaldırılan sinyalin spektrum analizi incelendiğinde 0 Hz civarında büyük bir darbe görülmemektedir.

Herhangi bir ofset normalde fark edilmeyecek kadar küçüktür, ancak arızalı veya düşük kaliteli donanım ile sorun olacak kadar büyük olabileceği için bu çalışmada DC ofset kaldırma işlemi uygulanmıştır.



Şekil 3.9: DC ofset etkisi.

### 3.2.5. Pencere Fonksiyonu

Pencereleme işlemi, sonsuz uzunluktaki veri dizisi ile çalışmanın imkânsız olmasından dolayı sinyalin zaman alanındaki Fourier dönüşümü sırasında frekans bileşenlerinin durağanlığını sağlamaktır. Zaman alanındaki pencereleme, çerçevenin ve pencere fonksiyonunun çarpımıdır ve aşağıdaki denklemde gösterilmiştir.

$$x(n) = x(n)w(n), \quad 0 \leq n \leq N - 1 \quad (3.6)$$

İyi bir pencere fonksiyonu, yer değiştirmeyi azaltmak için dar ana lob ve düşük yan lob seviyelerine sahiptir, transfer fonksiyonlarında maalesef ana lob seviyeleri daraldığında, yan lob seviyeleri de artar [36].

### 3.2.6. Fourier Dönüşümü

Fourier dönüşümü, genellikle zaman içindeki bir sinyali frekans alanına aktarmak için kullanılan matematiksel işlem olarak tanımlanmaktadır. Zaman

alanındaki bir  $x(t)$  sinyali için Fourier dönüşümünün matematiksel tanımı aşağıdaki Denklem 3.7’de olduğu gibi ifade edilir.

$$x(f) = \int_{-\infty}^{\infty} x(t)e^{-i2\pi ft} dt \quad (3.7)$$

Bu çalışmada ise 1024 noktalı Fourier dönüşümü alınarak 1024 nokta sınıflandırmada, 512 noktası LOFAR görüntüleme kullanılmıştır. LOFAR algoritması geliştirilmesiyle 1024 nokta görüntüleme gerçekleştirilmektedir. Hali hazırda literatürde yer alan diğer çalışmalarda 1024 nokta sınırlandırılarak görüntülenmesi gerçekleştirilmiştir.

### 3.2.7. Enerji Hesaplanması

Parserval teoremi periyodik bir sinyaldeki ortalama gücün, sinyalin DC bileşenindeki ortalama güç ve harmoniklerinin ortalama güçlerin toplamına eşit olduğunu ifade eder ve aşağıdaki denklemde metod gösterilmiştir.

$$E = \frac{1}{2\pi} \sum_{-\infty}^{\infty} (|X(e^{j\omega})|^2 d\omega) \quad (3.8)$$

$|X(e^{j\omega})|^2$  enerjinin frekans alanında nasıl dağıldığını belirlediği için enerji yoğunluğu spektrumu denir. Zorunlu olarak, enerji yoğunluğu spektrumu sadece sonlu enerji sinyalleri için tanımlanır [37].

### 3.2.8. İki Geçişli Bölünmüş Pencere algoritması

Tahmini arka plan gürültüsü (TPSW- İki Geçişli Bölünmüş Pencere algoritması ile hesaplanır) ve azaltma spektrumlar TPSW algoritması kullanılarak normalleştirilir. Normalleştirme, her spektrumda bulunan arka plan gürültüsünü tahmin ederek ve bu tahmini normalleştirme faktörü olarak kullanarak normalleştirilmiş bir frekans bölmesini hesaplayarak uygulanabilir. Bu tahmin, spektrum yanlılığını ortadan kaldırır ve spektrum genliğini eşitler [13]. Orijinal spektrumun her bir örneğini karşılık gelen

yerel ortalamasına bölerek spektrumunu düzeltmek için kullanılır. TPSW ile yapılan düzeltme yerel ortalamayı kaldırır, bu arka plan gürültüsüne karşılık gelmektedir ve aynı anda spektrumları eşitleyerek farklı frekans aralıklarına farklı kazançlar sağlar [20]. Yerel bir ilk geçiş ortalaması olan  $Z$  hesabı Denklem 3.9'da gösterilmektedir.  $m$  her aralıktaki hücreyi,  $n$  huzmeleri ve  $t$  anındaki parametrelerle  $Z$  ilk geçiş ortalaması ifade edilmektedir.  $n \times t$  ilk geçiş aralıklarını göstermektedir.  $W_s$ , normalleştirilecek hücrenin bir tarafındaki aralık hücrelerinin sayısıdır.  $W_g$ , toplam pencerelerinin ortasındaki tek sayıda atlanan aralık hücreleridir.  $k = 2W_s$  ile ifade edilir.

$$Z_{n,t}(m) = \frac{1}{k} \sum_{i=m+(W_s+\frac{W_g-1}{2})}^{m+(W_s+\frac{W_g-1}{2})} \varphi(i) x(i, n, t) \quad (3.9)$$

$\varphi$  cinsinden boşluk penceresi  $W_g$ , hedefin beklenen aralık kapsamından daha fazla aralık hücrelerine sahip olacak şekilde seçilir ve Denklem 3.10'da gösterilmektedir.

$$\varphi(i) = \begin{cases} 0, & \text{eğer } |i - m| \leq \left(\frac{W_g - 1}{2}\right) \\ 1, & \text{diğer} \end{cases} \quad (3.10)$$

Toplam penceresi, yeterli ortalamayı sağlamak için yeterli aralık hücrelerine sahip olmalı, ancak gürültü gücünün  $\varphi$  üzerinde yaklaşık olarak sabit olması için yeterince küçük olmalıdır. Her ilk geçiş ortalaması daha sonra her bir  $t$  'deki tüm huzmeler için ilgili aralık hücreleriyle karşılaştırılır ve Denklem 3.11'de görülmektedir.  $r$  eşliği, sinyal tahmininin aşağı doğru önyargısı ile yüksek seviyenin sinyalin bir parçası olma olasılığı arasında bir uzlaşma olarak seçilmektedir [38].

$$y_{n,t}(m) = \begin{cases} x(m, n, t), & \text{eğer } x(m, n, t) < r Z_{n,t}(m) \\ Z_{n,t}(m), & \text{eğer } x(m, n, t) \geq r Z_{n,t}(m) \end{cases} \quad (3.11)$$

### 3.2.9. Medyan Normalizasyonu

TSPW normalize edilmiş veri medyan normalizasyonu ile %25 altında kalan değerler gürültü olarak değerlendirilerek LOFAR hatları ön plana çıkartılmakta ve arka plan gürültüsü bastırılmaktadır. LOFAR sinyalinin medyan değerleri alınarak elde edilen sinyalin belli bir seviyesi gürültü olarak değerlendirilmektedir. Medyan normalizasyonu aşırı sapmalardan etkilenmemesi [39] LOFAR hatlarının ön plana çıkarılmasında güçlü bir adım olduğunu göstermektedir ve Denklem 3.12 kullanılarak %25 altında kalan değerler gürültü olarak değerlendirilmesi gösterilmektedir.

$$\begin{aligned} \text{median}\{s(x)\} &= s(x)' \\ \text{uzunluk}(s(x)') \times 0.25 &= \text{gürültü seviyesi} \end{aligned} \quad (3.12)$$

Tüm adımlar sonucunda LOFAR veri dizisi sinyali elde edilmiştir. Elde edilen LOFAR veri dizisi sınıflandırma işleminde kullanılarak hedefin sınıf tespiti gerçekleştirilmiştir. Vektör LOFAR sinyali matrise dönüştürülmüş olup normalizasyon ve görüntü yoğunluğu değerleri ayarlanarak LOFAR görüntüsü elde edilmiştir.

### 3.2.10. Normalizasyon

LOFAR veri dizisi sinyali vektör matris dönüşümü yapıldıktan sonra elde edilen matris LOFAR görüntüsü elde edilmiştir. Elde edilen LOFAR görüntüsü Şekil 3.10'da (solda) görülmektedir. Sonar operatörü için hatların belirlenmesi ve hedef hakkında yorum yapabilmesi için yeterli olmamasından dolayı görüntüye normalizasyon ardından görüntü yoğunluğu ayarlanarak sağda yer alan görüntü elde edilmiştir.

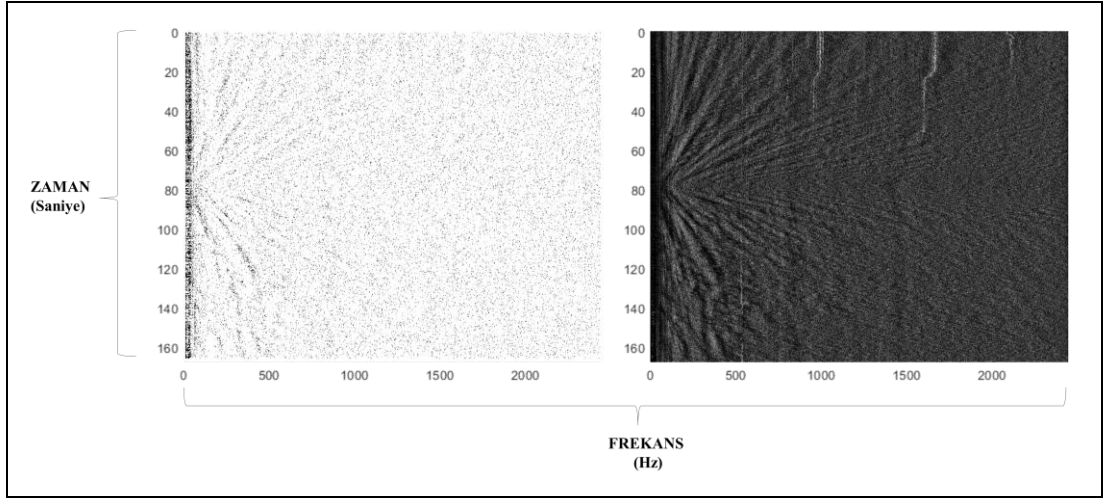
Görüntüler arasında yapılan aritmetik işlemler sonunda elde edilen tüm görüntü değerler aralığının sabit bir bit sayısına atanması garanti eden yaklaşım bir  $f$  görüntüsü için aşağıdaki denklem uygulanır ve bu işlem en küçük değeri 0 olan bir  $f_m$  görüntüsü oluşturur.

$$f_m = f - \min(f) \quad (3.13)$$

Sonra da aşağıdaki Denklem 3.14 uygulanır.

$$f_s = K \left[ \frac{f_m}{\max(f_m)} \right] \quad (3.14)$$

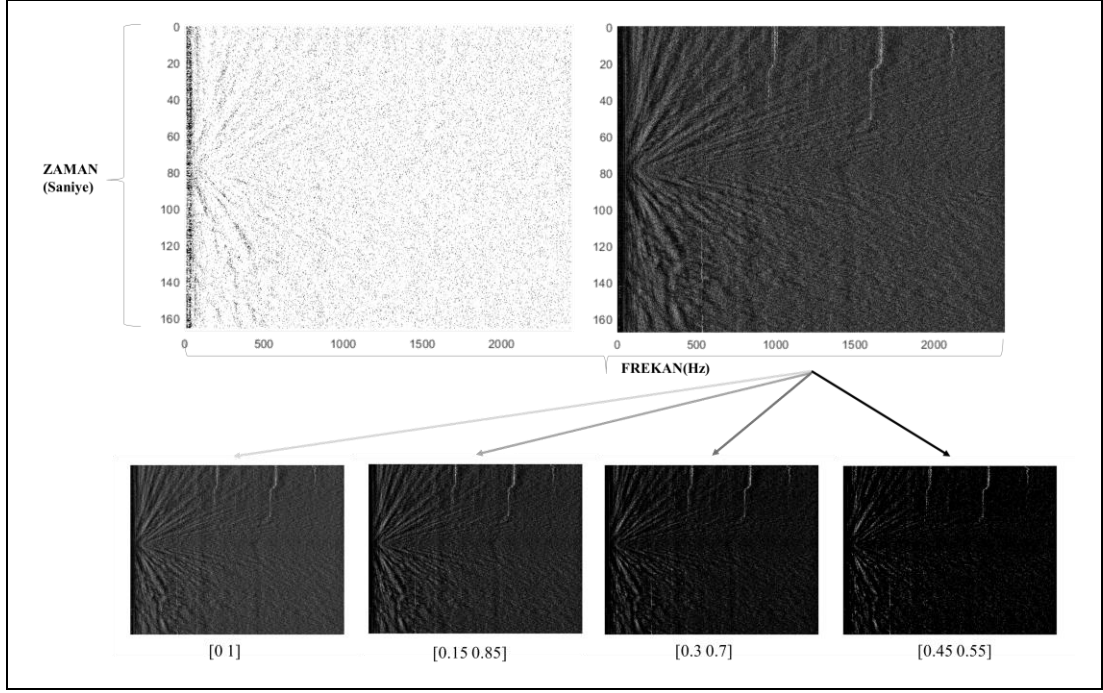
İşlem sonucunda  $[0, K]$  aralığında olan ölçeklenmiş bir  $f_s$  görüntüsü elde edilir. 8 bitlik görüntülerle çalışırken  $K = 255$  yapılır. Böylece yeğinlikleri 0'dan 255'e kadar olan 8 bitlik ölçeği kapsayan ölçeklenmiş bir görüntü elde edilir [40].



Şekil 3.10: Normalizasyon yapılmamış (solda) ve yapılmış (sağda) LOFAR görüntüsü.

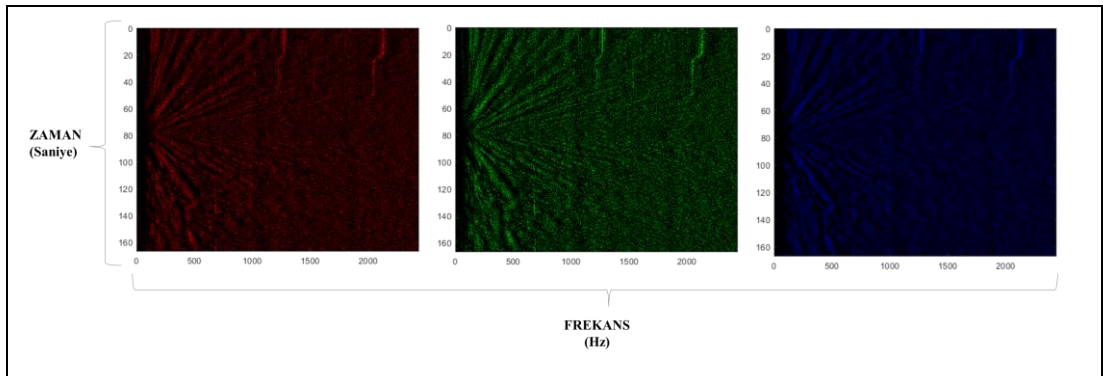
### 3.2.11. Görüntü Yoğunluğu

Görüntü yoğunluğu değerlerini ve renk haritası kullanılarak, normalize edilen görüntü çıktı görüntüsündeki değerlerle eşlemek istenilen giriş gri tonlamalı görüntüdeki kontrast sınırları belirlenerek değerler  $[0 \ 1.0]$  aralığında seçilmiştir. Şekil 3.11'de görülen normalize edilen görüntüden farklı kontrast sınırları kullanılarak görüntüler için sonar operatörüne en ideal  $[0.15 \ 0.85]$  kontrast sınırları seçilerek görüntü yoğunluğu değerleri ayarlanmıştır.



Şekil 3.11: ShipEar veri kümesi 49 numaralı görüntü yoğunluğu değerleri.

Normalize edilmiş görüntü analizi yapılırken Şekil 3.12’de görülen kırmızı, mavi ve yeşil logaritmik görüntüleme paleti kullanılarak ayrı ayrı yapılmış ve yeşil kanaldaki görünürlük sonar operatörü için diğer iki kanala göre daha belirgin olduğu gözlenmiştir.

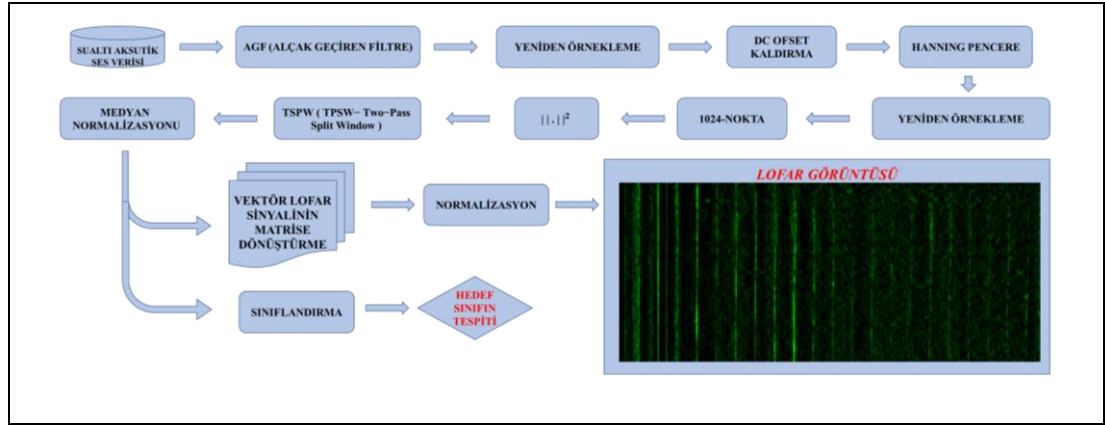


Şekil 3.12: ShipEar veri kümesi 49 numaralı geminin kırmızı, mavi ve yeşil kanalları LOFAR görüntüsü.

### 3.2.12. LOFAR-D Algoritması Akış Şeması

Şekil 3.13’te görülen akış diyagramında yer alan sinyal işleme ve görüntü işleme uygulamaları kullanılarak LOFAR algoritması geliştirilmiştir. Geliştirilen LOFAR

algoritması LOFAR-D olarak isimlendirilmiştir. LOFAR-D algoritmasında sinyal işleme adımlarından biri olan ikinci yeniden örnekleme ve Normalizasyon adımlarından biri olan medyan normalizasyonu literatürde yer alan LOFAR algoritmalarına kıyasla en önemli farkları oluşturmaktadır. Medyan normalizasyonu ile LOFAR hatları daha belirgin hale gelmektedir.



Şekil 3.13: LOFAR-D algoritması akış şeması.

### 3.2.13. LOFAR-DDC Algoritması Geliştirilmesi

LOFAR-D algoritması iyileştirilmiş bir versiyonu olan LOFAR-DDC algoritması bu bölümde sunulmaktadır. LOFAR-D ve LOFAR-DDC algoritmalarının performans karşılaştırması Bölüm 4'te verilmektedir. LOFAR-D algoritmasında hız, işlem yükü ve LOFAR görüntü performansı açısından iyileşme sağlamak üzere Sayısal Aşağı Dönüşüm (DDC ing. Digital Down Conversion) işlemi kullanan LOFAR-DDC algoritmasına ilişkin detaylar aşağıda verilmektedir.

#### 3.2.13.1. Sayısal Aşağı Dönüşüm

Sayısal aşağı dönüşüm, iletişim ve sinyal işlemede temel işlemdir. Sayısal aşağı dönüşüm işlemi, simülasyonu basitleştiren, hesaplama belleği gereksinimlerini ve çalışma süresini azaltan modellerdir. Suallı akustik sinyaller yüksek örnekleme frekansı ile kaydedilmesi sinyal işleme uygulamalarında büyük ve karmaşık filtreleme ihtiyacı duymaktadır.

İletişim sistemlerinde kullanılan temel parçalar arasında sayısal aşağı dönüştürme (DDC) elemanlarıdır. DDC, ilgilenilen frekans bandını spektrumdan ayırarak örnekleme hızının azaltılmasını sağlar. Böylelikle filtre gereksinimleri ve ilgili sinyal işleme işlemleri daha kolay gerçekleştirilebilir hâle gelmektedir [41].

Aşağı dönüştürücüler, bant genişliğini daraltmak ve sinyal çıkış verisi miktarını azaltarak sinyalin sıfır frekansta ortalanmış bir temel bant sinyaline dönüşümünü gerçekleştirir. İlgilenilen daha küçük sinyal bant genişliği için ek işlem kazancı elde etmek için kullanılır. Sinyali karmaşık temel bant sinyaline dönüştürür.

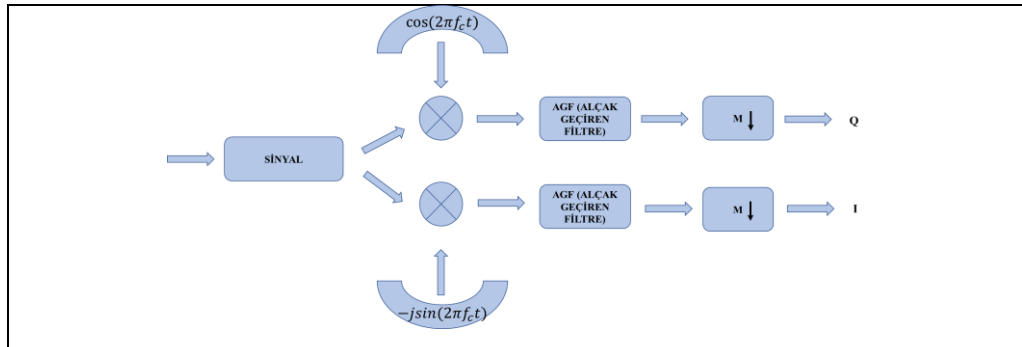
DDC'ler ayrıca karmaşık giriş sinyalleriyle yaygın olarak kullanılır. DDC'nin temelini frekans kaydırma özelliği oluşturmaktadır. Sinyalin karmaşık üstel ile çarpılması ile gerçekleşir ve Denklem 3.15'te görülmektedir.

$$e^{-i2\pi f_c t} = \cos(2\pi f_c t) - i \sin(2\pi f_c t) \quad (3.15)$$

Frekans spektrumu  $f_c$  kadar kaydırılmış olmaktadır. Matematiksel olarak sinyalin frekansta kaydırma zamanda üstel fonksiyonla çarpılması anlamına gelmektedir [37]. Denklem 3.16'da görülmektedir.

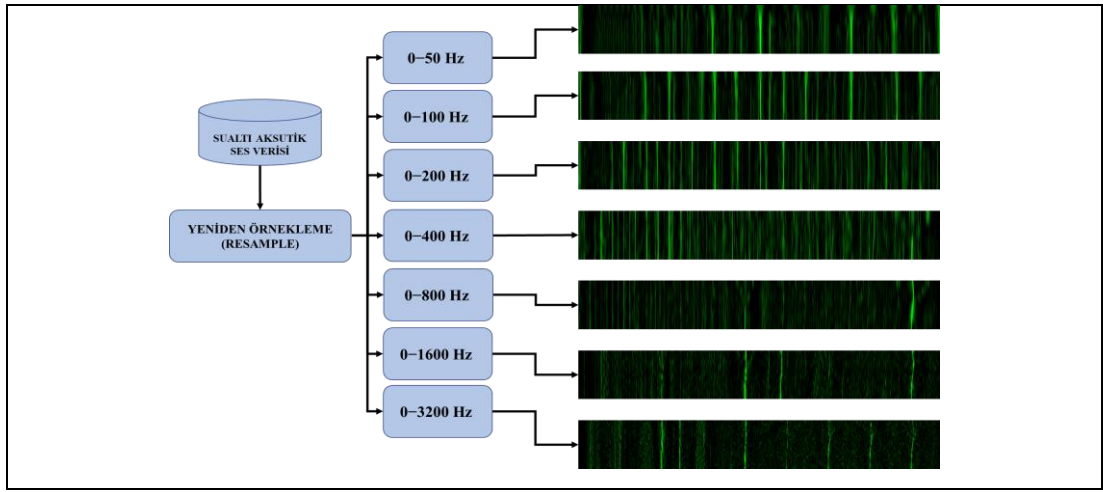
$$F(f) = \mathcal{F}\{x(t)\}, F(f - f_c) = \mathcal{F}\{x(t) e^{-i2\pi f_c t}\} \quad (3.16)$$

Standart sayısal aşağı dönüşüm blok diyagramı Şekil 3.14'te gösterilmiştir ve sinyal, sinüs ve kosinüs sinyallerinde sinyal çarpımı, alçak geçiren filtreler ve M faktörü seyreltme işlemlerinden oluşur. Bu işlemden sonra, kosinüs ve sinüs terimlerine karşılık gelen faz (I) ve karesel (Q) sinyal örnekleri alırız. Bu I / Q çiftleri, orijinal sinyalin tüm bilgilerini korur ve sinyal demodülasyonu için kullanılabilir.




Şekil 3.14: Sayısal aşağı dönüşüm blok diyagramı.

Sinyal işleme ve görüntü işleme adımları ile SONAR operatörüne iki kez yeniden örnekleme ile 7 farklı frekans aralığında LOFAR görüntüsü sunmaktadır. 7 farklı frekans aralığından 6'sı sınıflandırma için kullanılarak hedefler sınıflandırılmıştır. Şekil 3.15'te farklı örnekleme frekansına ait LOFAR görüntüleri gösterilmektedir. Sonar operatörü hedefe ait bilgileri farklı frekanslara denk gelen LOFAR hatlarından edinirken aynı zamanda veriler sınıflandırmada kullanılarak otomatik hedef tespiti ile farklı frekans aralıkları kullanılması ile yeni bir yaklaşım sağlanmaktadır.



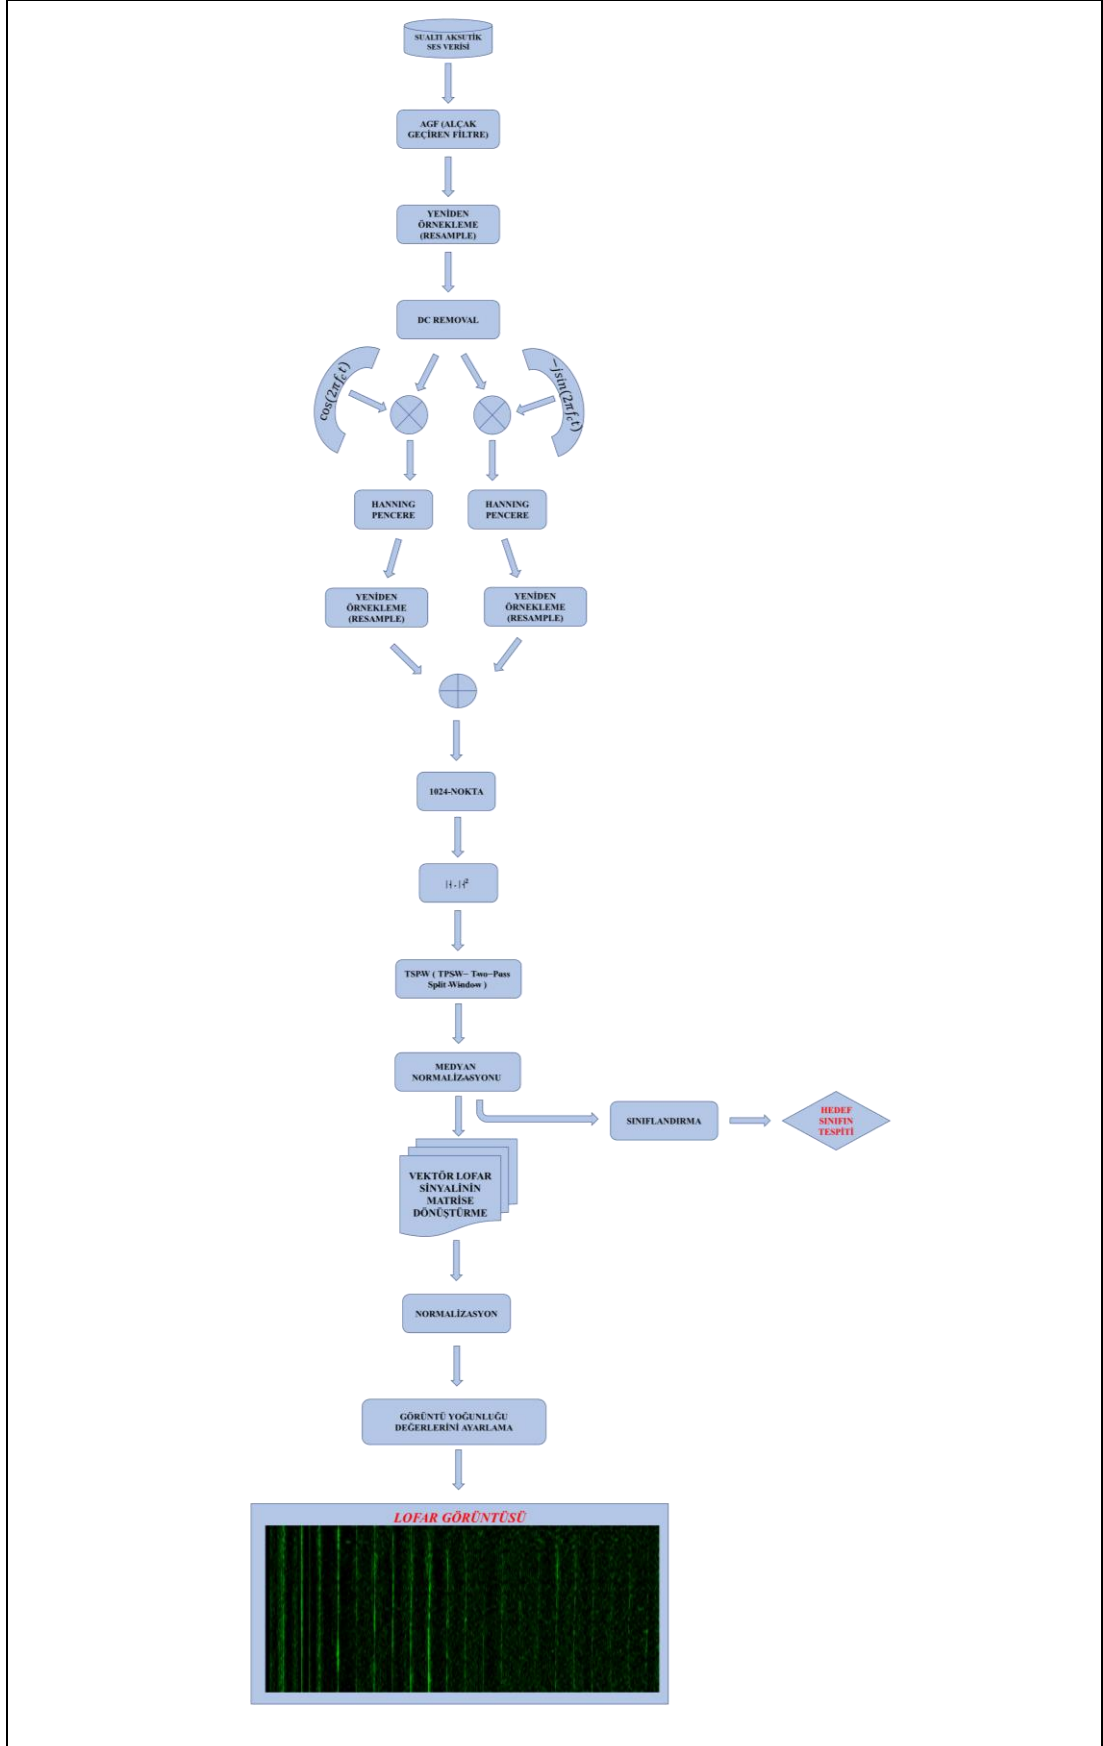
Şekil 3.15: ShipEar veri kümesi 23 numaralı geminin farklı frekanslarda LOFAR görüntüsü.

Şekil 3.16'da ShipEar 23 numaralı gemiye ait 10 saniyelik ses verisinin farklı örnekleme frekanslarında LOFAR görüntüsü görülmektedir. Sonar operatörünün farklı örnekleme frekanslarında LOFAR görüntülerine bakarak hedef hakkında bilgi edinmesini sağlamaktadır. LOFAR görüntülerinde farklı frekanslarda çıkan hatlar gemi hakkında bilgi vermektedir. Bu hatlar geminin makine, cihaz ve sistemlerden kaynaklı titreşimler sonucu oluşmaktadır ve her geminin kendisine ait LOFAR görüntüsü olmaktadır. Gemiler hakkında bir iz olarak değerlendirilirken geminin karakteristiğini göstermektedir ve sınıflandırma işleminde kullanılabilir olduğu yani bir öznitelik olarak değerlendirilmelidir. LOFAR görüntüsünün anlamlandırılabilmesi için en az 10 saniyelik bir görüntünün olması gereğinden bütün veriler 10 Sn ye bölünerek LOFAR sinyali elde edilmiştir.



Şekil 3.16: 10 Sn ses verisinin farklı örnekleme oranları kullanılarak elde edilen LOFAR görüntüleri.


LOFAR-D algoritması geliştirilerek LOFAR-DDC OLARAK isimlendirilmiştir ve algoritmasının akış şeması Şekil 3.17’de görülmektedir.



Şekil 3.17: Geliştirilen LOFAR-DDC algoritması.

### 3.2.13.2. Sayısal Aşağı Dönüşüm'ün LOFAR Görüntüsüne Etkisi

Şekil 3.15'te DDC kullanımı etkisi gösterilmektedir. DDC kullanılarak 1024 noktalı Fourier Dönüşümü sonrasında noktaların tamamı anlamlı frekanslara denk gelmektedir. Kullanılmadığı durumda DDC frekansta kaydırma olmaması simetrik 512 noktası anlamlı LOFAR görüntüleri elde edilmektedir. DDC kullanılarak 1024 nokta kullanılırken uygulanmadığı durumda 512 nokta LOFAR görüntüsü sağlanması ve sınıflandırma adımında da performansı etkilemektedir. DDC ile sınıflandırma performansı artmaktadır.



Şekil 3.18: DDC uygulanmış ve uygulanmamış LOFAR görüntüleri.

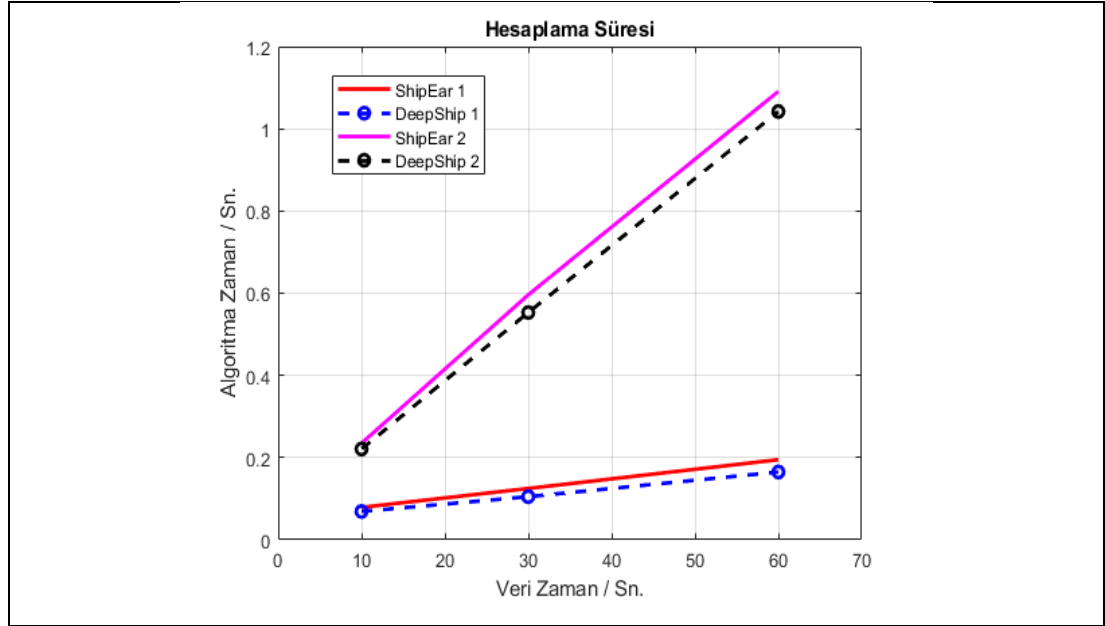
### 3.2.14. LOFAR Hesaplama Süreleri

Bu çalışmada algoritmaların çalışma süreleri hesaplanarak farklı veri kümeleri ile karşılaştırmalar yapılmıştır. Tablo 3.1'de yer alan iki farklı veri kümesinde 2 farklı algoritmanın, farklı örnekleme frekanslarına sahip verilerin 10, 30 ve 60 Sn. uzunluğunda yer alan akustik ses verisinin 0-3200 Hz sabit frekans aralığında LOFAR görüntüsü elde edilmesi için geçen süreler görülmektedir.

Tablo 3.1: ShipEar ve DeepShip LOFAR hesaplama süreleri karşılaştırması.

Algoritma	Veri Kümesi	Fs (Hz)	Süre (Sn.)			Frekans Aralığı / Hz
			10	30	60	
			Gerçek Zaman / Sn.			
LOFAR-D	ShipEar [6]	52734	0.079	0.125	0.195	0 - 3200
	DeepShip [7]	32000	0.069	0.105	0.165	
LOFAR-DDC	ShipEar [6]	52734	0.235	0.596	1.091	
	DeepShip [7]	32000	0.221	0.553	1.042	

Şekil 3.19’da Tablo 3.1’de yer alan iki farklı algoritmanın çalışma sürelerinin grafiği görülmektedir. Şekil 3.13’te yer alan algoritma kullanılarak kırmızı ve mavi ile görülen hesaplama süresi elde edilerek Şekil 3.17’de kullanılan algoritmaya göre daha hızlı olduğu gözlenmektedir. Şekil 3.17’de geliştirilen LOFAR algoritmasında kullanılan DDC yeniden örnekleme işlemini yavaşlatarak sinyal işleme adımlarını kolaylaştırarak 60 Sn. uzunluğundaki veri için hesaplama süresinin 1.091 Sn. hesaplama süresi ile gerçekleştirmektedir. Algoritma geliştirilerek hesaplama süresi artmasına sebep olurken başarı doğruluğunun arttığı sonuçlar bölümünde gösterilmektedir.



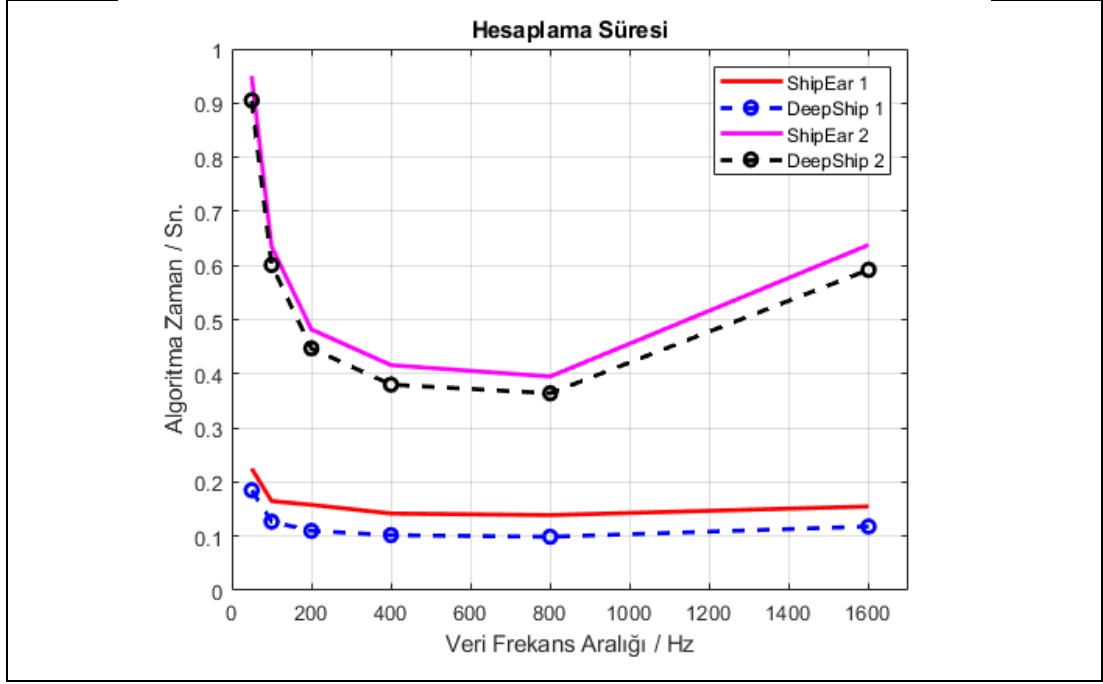
Şekil 3.19: ShipEar ve DeepShip LOFAR hesaplama süreleri grafiği farklı uzunlukta akustik ses verisi için.

Bu çalışmada algoritmaların çalışma süreleri hesaplanarak farklı veri kümeleri ile karşılaştırmalar yapılmıştır. Tablo 3.2’de yer alan iki farklı veri kümesinde farklı algoritmanın, farklı frekans aralıklarında yer alan 60 Sn. uzunluğundaki akustik ses verisinin LOFAR görüntüsü elde edilmesi için geçen süreler görülmektedir.

Tablo 3.2: ShipEar ve DeepShip LOFAR hesaplama süreleri karşılaştırması.

Algoritma	Veri Kümesi	Fs (Hz)	Frekans Aralığı / Hz						Süre (Sn.)
			0-50	0-100	0-200	0-400	0-800	0-1600	
LOFAR-D	ShipEar [6]	52734	0.225	0.165	0.158	0.142	0.139	0.155	60
	DeepShip [7]	32000	0.185	0.127	0.110	0.102	0.099	0.118	
LOFAR-DDC	ShipEar [6]	52734	0.950	0.635	0.482	0.416	0.395	0.638	
	DeepShip [7]	32000	0.905	0.601	0.447	0.380	0.364	0.592	

Şekil 3.19’da Tablo 3.2’de yer alan iki farklı algoritmanın çalışma sürelerinin grafiği görülmektedir. 60 Sn. uzunluğundaki akustik ses verisi kullanılarak farklı frekans aralıklarında LOFAR görüntüsü elde edilmesi için geçen süreler görülmektedir. Mavi ve Siyah ile gösterilen LOFAR-D algoritmasının farklı veri kümelerinden alınan örnek için hesaplama sürelerini göstermektedir. Pembe ve Siyah ile gösterilen LOFAR-DDC algoritması için iki farklı veri kümesinden alınan örnek için hesaplama sürelerini göstermektedir. 0-800 Hz frekans aralığında LOFAR görüntüsü hesaplama süresi en hızlı gerçekleşmiş olup LOFAR-D algoritmasına göre yavaş kaldığı görülmektedir. LOFAR-DDC algoritması daha yavaş hesaplama süresine sahipken doğruluğun artması sonuç bölümünde gözlemlenmektedir.



Şekil 3.20: ShipEar ve DeepShip LOFAR hesaplama süreleri grafiği farklı frekans aralığı sabit uzunluktaki akustik ses verisi için.

Sonuç olarak hesaplama sürelerinde düşük örnekleme frekansına sahip örneklerin yüksek örnekleme frekansına sahip verilerden daha hızlı hesaplama süresi olduğu gözlemlenmiştir. İdeal LOFAR görüntüsü elde edilmesinde 10 Sn. verilerin kullanılması hesaplama süresi açısından daha yararlı olduğu görülmektedir.

## **4. SINIFLANDIRMA, ANALİZ VE SONUÇLAR**

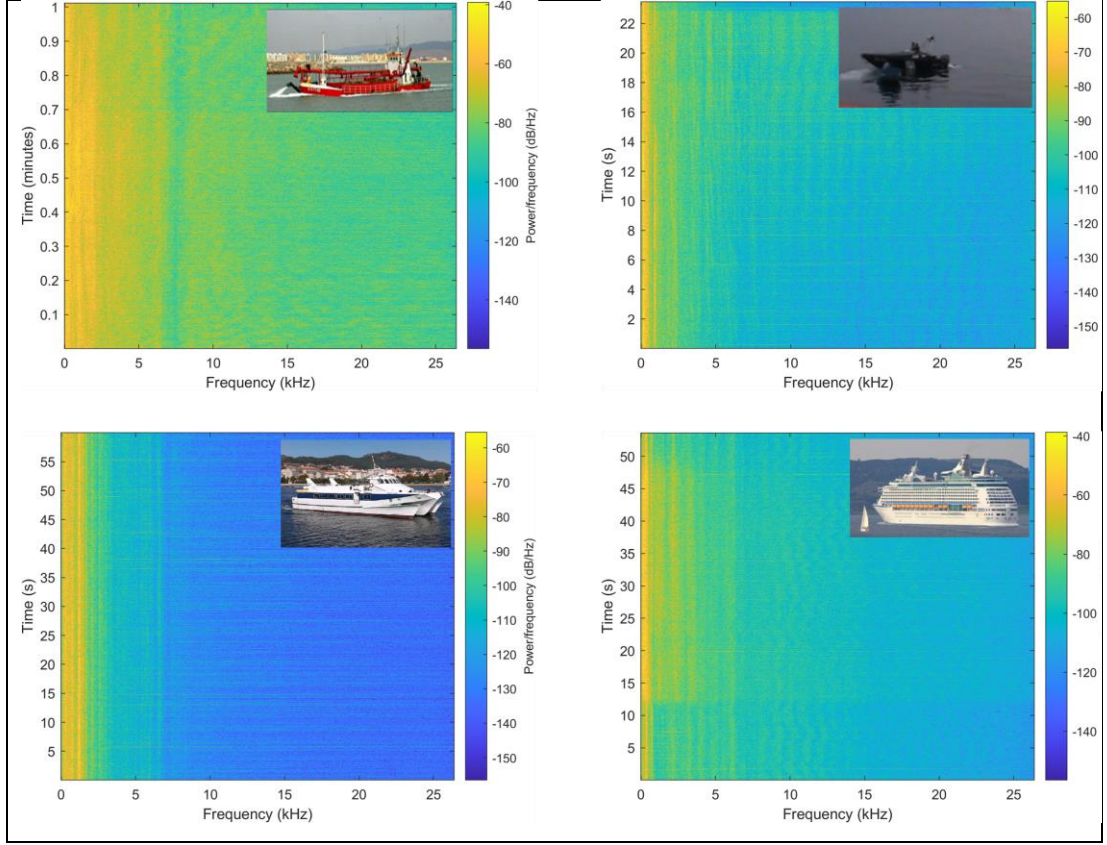
Bu bölümde ShipEar, veri kümesi kullanılarak detaylı analizler ve sonrasında sınıflandırma sonuçları gösterilmektedir. Devamında DeepShip veri kümesi kullanılarak analiz ve sınıflandırma sonuçları gösterilmektedir. Son olarak operatör tarafından üretilen sentetik veri amacı ve analizi ile sonlandırılmaktadır.

### **4.1. ShipEar Veri Kümesi Analiz ve Sonuçları**

Bu alt bölümde ShipEar veri kümesi analiz sonuçları verilmektedir. Öncelikle zaman frekans spektrum analizi, güç spektrum yoğunluğu kestirimi, enerji analizi devamında verilerin görselleştirilmesi ve son olarak sınıflandırma sonuçları gösterilmektedir.

#### **4.1.1. Zaman Frekans Spektrum Analizi**

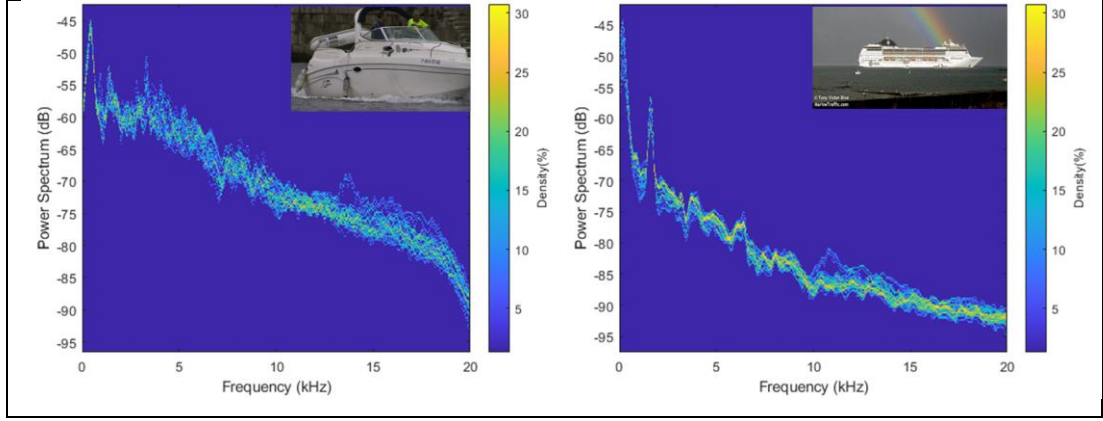
Zaman frekans analizi ile akustik sinyallerin yoğun olduğu frekans aralıkları incelenmektedir. ShipEar veri kümesinde yer alan sualtı akustik ses verilerinin örnekleme frekansı 52734 Hz'tir. Ses verilerinin spektrumları incelendiğinde anlamlı verilerin 4 kHz'e kadar olduğu anlaşılmıştır. Sualtı akustik sinyale önce örtüşme önleyici alçak geçiren filtre uygulanmış ve yeniden örneklenerek 8 kHz örnekleme frekansına sahip sinyaller elde edilmiştir. Şekil 4.1'de farklı gemiler için spektrumlar gösterilmektedir.



Şekil 4.1: Sualtı akustik sinyal spektrum analizi.


#### 4.1.2. Güç Spektrum Yoğunluğu Kestirimi ve Enerji Analizi

Geminin yaydığı gürültü kısa sürede yaklaşık olarak kararlıdır, bu nedenle güç spektrumu ile tanımlanabilir [42]. Güç spektrum analizi ile frekans alanındaki gemilerden yayılan gürültülü sinyallerin enerji dağılımlarını analiz etmek için kullanılabilir. Gemilerden yayılan gürültüler ile güç spektrum yoğunluğu analizi ile geminin karakteristik özellikleri ile seyir durumu hakkında önemli bilgiler elde edilebilir. Şekil 4.2’de görüldüğü üzere farklı gemi sınıflarına ait gemilerin güç spektrumlarının farkı görülmektedir. Hedef tanıma için kullanılan özelliklerin çoğu, LOFAR, MFCC, GFCC, vb. dahil olmak üzere güç spektrumuna göre oluşturulmuştur [42].



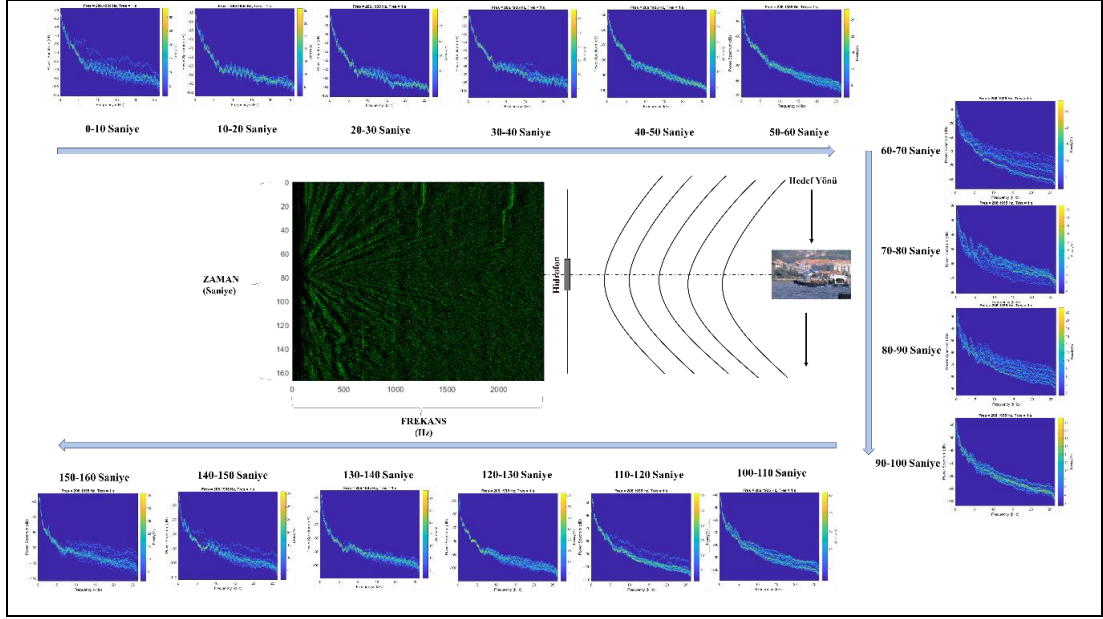
Şekil 4.2: ShipEar veri kümesi motor yat (solda) ve okyanus gemisi (sağda) güç spektrum grafikleri.

Şekil 4.3'te görüldüğü üzere farklı gemi sınıflarına ait gemilerin güç spektrumlarının benzer olduğu görülmektedir. Hedef tanıma için kullanılan LOFAR, MFCC, GFCC, vb. öznitelik olarak kullanılarak Tablo 2.1'de yer alan karakteristik olarak farklı gemilerin sınıflandırılmasında kullanılabileceğini gözler önüne sermektedir.



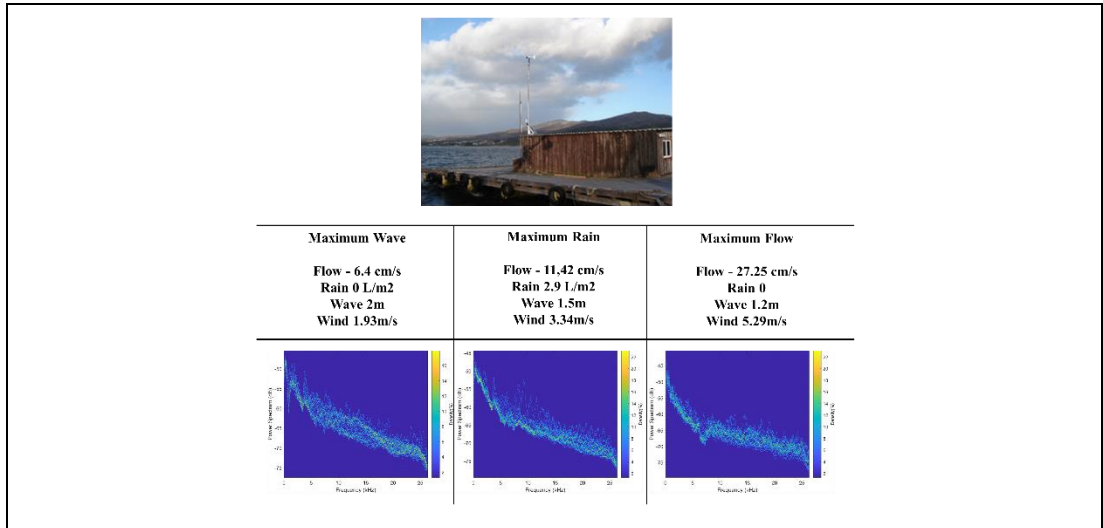
Şekil 4.3: ShipEar veri kümesi benzer karakteristik özelliklerine sahip 3 farklı geminin güç spektrum grafikleri.

Sınıflandırma işlemi gerçekleştirilmeden önce verilerin analizleri gerçekleştirilip operatör tarafından karar verilmesi aşamasında destekleyici bilgiler verilmesi büyük önem taşımaktadır. Ortam şartları; rüzgar durumu, yağmur, dalga durumu ve en önemlisi mesafe durumu sınıflandırmayı etkileyebilmektedir. Şekil 4.4'te 49 numaralı geminin mesafeye bağlı olarak LOFAR görüntüsü ve güç spektrum değişimi görülmektedir.



Şekil 4.4: ShipEar veri kümesi 49 numaralı geminin mesafeye bağlı olarak güç spektrum yoğunluğu değişimi ve LOFAR görüntüsü.

Şekil 4.5'te farklı ortam koşullarında güç spektrum değişimleri gösterilmektedir. Maksimum dalga, yağmur ve akış durumlarındaki farklılıklar gözlemlenmiştir.



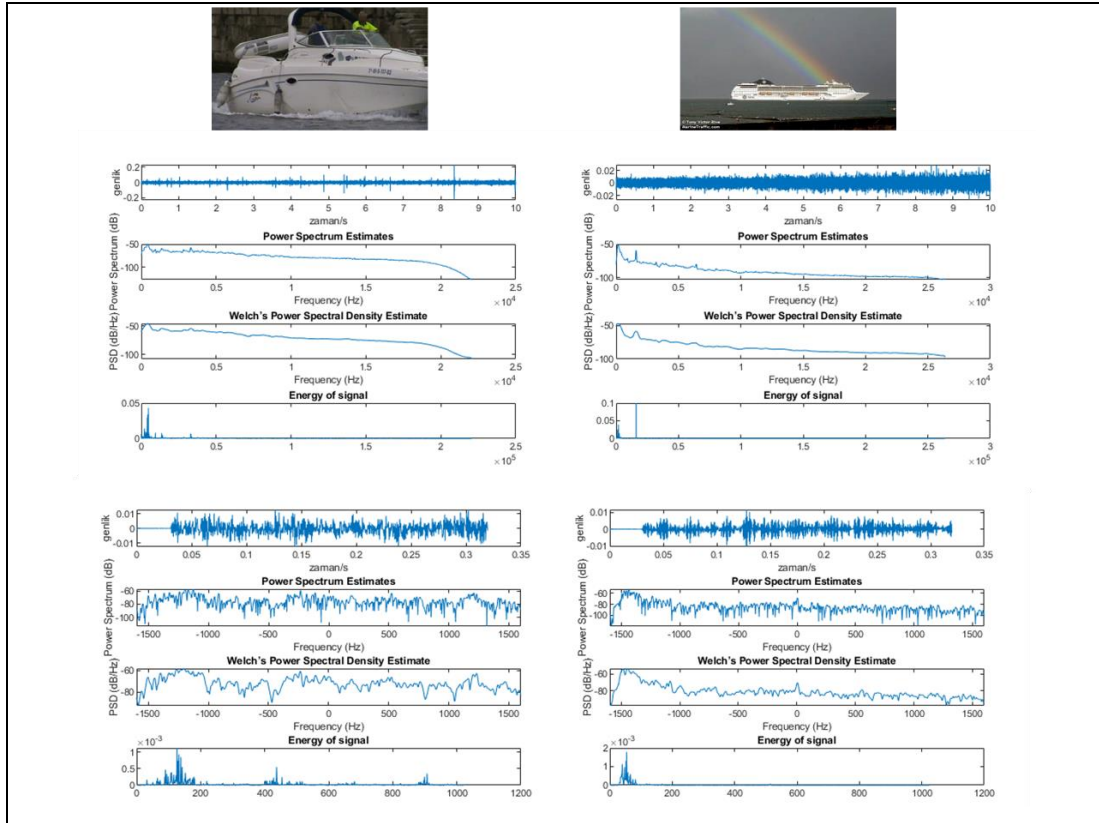
Şekil 4.5: ShipEar veri kümesi ortam gürültüsünün farklı ortam şartları durumunda güç spektrum grafikleri.

Şekil 4.6'te görülen iki farklı geminin güç spektrum kestirimleri ve enerjileri sinyal işleme adımları uygulanmadan ve uygulanarak karşılaştırılması yapılmış ve sinyallerin enerjileri analiz edilerek karşılaştırılmaları yapılmıştır. ShipEar veri kümesi

kullanılarak yapılan çalışmalarda gemileri boyutlarına göre Tablo 4.1’de kullanılan sınıflar oluşturulmuştur.

Tablo 4.1: ShipEar boyuta göre sınıflar.

Sınıf	Gemi Tipi	Gemi Sayısı	Süre başına Kayıt (Sn.)
A	Balıkçı tekneleri, troller, midye tekneleri, römorkörler ve taraklar	17	1729
B	Motorlu tekneler, pilot tekneler ve yelkenli tekneler	19	1435
C	Yolcu feribotları	30	4054
D	Okyanus gemileri ve ro-ro gemileri	12	2041
E	Arka plan gürültü kayıtları	12	923



Şekil 4.6: Farklı iki gemi tipi güç spektrum ve enerjilerinin sinyal işleme adımlarının uygulanmadan ve uygulandıktan sonra karşılaştırılması.

Oluşturulan sınıflardaki gemilerden yayılan gürültü sinyalleri kullanılarak enerji hesaplaması yapılarak ortalama enerji, toplam enerji ve maksimum enerji değeri kullanılarak sınıflandırma gerçekleştirilmiştir. Eğitim verileri kullanılarak 10-

katlamalı çapraz doğrulama (10-fold cross validation) kullanılarak farklı frekans aralıkları validasyon doğrulukları Tablo 4.2’de gösterilmektedir.

Tablo 4.2: Enerji hesaplaması yapılarak ortalama enerji, toplam enerji ve maksimum enerji değeri ile sınıflandırma sonuçları.

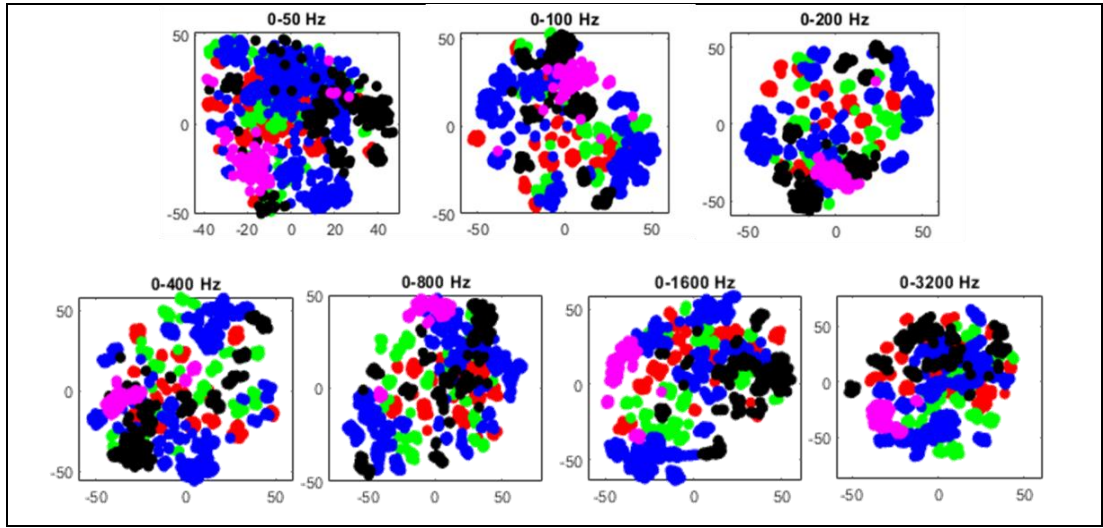
Model Tipi	Doğruluk	Frekans Aralıkları / Hz					
		0-50	0-100	0-200	0-400	0-800	0-1600
Badges Trees	Validasyon (%)	76.7	78.6	77.4	74.8	71.1	66.4
	Test (%)	69.1	73.51	66.48	62.23	55.67	55.67

Gerçek	A	90	7	22	22	1	Gerçek	A	23		2	14	
	B	10	54	53	3	2		B	1	12	12		
	C	12	10	328	12			C	2		44	4	1
	D	9		23	164			D				40	
	E	2		3		66		E	2	3	8		17
		A	B	C	D	E			A	B	C	D	E
		Tahmin							Tahmin				

Şekil 4.7: Başarı matrisleri (solda validasyon, sağda test).


#### 4.1.3. t-SNE ile Yüksek Boyutlu Verileri Görselleştirilmesi Analizi

Yüksek boyutlu verilerin görselleştirilmesi birçok farklı alanda önemli bir sorundur ve geniş ölçüde değişen boyutsallıktaki verilerle ilgilidir [18]. ShipEar veri kümesi kullanılarak yapılan çalışmalarda gemileri boyutlarına göre ayırarak Tablo 4.1’de kullanılan sınıflar oluşturulmuştur. Gemilere ait LOFAR sinyali elde edilmiş olup gemide bulunan makineler, cihaz ve sistemler tarafından üretilen gürültüler gemiye ait karakteristik özelliğini taşıdığından sınıflandırma için önemli bir ipucudur ve hedefe ait parmak izi olarak tanımlanır. Kısaca LOFAR bir öznitelik olarak değerlendirilmektedir. Elde edilen LOFAR özniteliği yüksek boyutlu olması sebebiyle t-SNE kullanılarak veriler üzerinde görsel analiz yapılmıştır. Tablo 4.1’de yer alan boyutlarına göre 5 sınıfa ayrılan eğitim verilerinin farklı frekans aralığında t-SNE algoritması kullanılarak elde edilen grafikler Şekil 4.8’de görülmektedir.




Şekil 4.8: ShipEar veri kümesi tablo 4.1’de yer alan 5 sınıfa ait verilerin farklı frekans aralıklarında t-SNE algoritması kullanılarak elde edilen grafikler.

Şekil 4.9’da görüldüğü üzere en başarılı sınıflandırma performansına sahip 0-100 Hz frekans aralığı için tüm verilere ait gemi boyutlarına göre ayrılan 5 sınıflı problemde gemilerin aynı boyutlu olan A sınıfı için farklı sınıflara daha yakın olduğu gözlemlenmektedir. Problemin çözümü için boyutsal sınıflara ayrılmasından ziyade gemilerin makine, cihaz sistem ve kullanım amaçlarına göre sınıflar oluşturulması halinde hedefe ait sınıfın belirlenmesinin yanında gemi tip ve özellikleri hakkında kesin bilgiler edilebilir.




Şekil 4.9: ShipEar veri kümesi tablo 4.1’de yer alan 5 sınıfa ait t-SNE algoritması kullanılarak elde edilen grafik.

Şekil 4.10’da görüldüğü üzere aynı boyutlu olarak değerlendirilen A sınıfı için gemilerin farklı karakteristik özelliklerinden dolayı birbirlerinden daha uzak farklı sınıflara yakın olarak görülmektedir. 4 farklı balıkçı teknesi aynı boyutta olmasına rağmen farklı karakteristik özelliğe sahip cihaz, sistem ve makine konfigürasyonu sebebiyle kırmızı çarpı olarak gösterilen farklı sınıflarda olduğu görülmüştür.




Şekil 4.10: ShipEar veri kümesi Tablo 4.1’de yer alan A sınıfa ait t-SNE algoritması kullanılarak elde edilen grafik.

Şekil 4.11’de görülen B sınıfı için boyut olarak aynı sınıfta yer alan 3 tip geminin karakteristik olarak birbirinden farklı olduğu farklı sınıflara yakınlığı görülmektedir. Birbirinden farklı motor botların farklı karakteristik özelliğe sahip olduğu kırmızı çarpı olarak işaretlerden görülmektedir.




Şekil 4.11: ShipEar veri kümesi tablo 4.1’de yer alan B sınıfa ait t-SNE algoritması kullanılarak elde edilen grafik.

Şekil 4.12’de C sınıfına ait birbirinden farklı yolcu gemilerinin karakteristik özellikleri birbirine benzer olması sebebiyle birbirlerine kümelenmiş olarak çıkmaları görülmektedir.




Şekil 4.12: ShipEar veri kümesi tablo 4.1’de yer alan C sınıfa ait t-SNE algoritması kullanılarak elde edilen grafik.

Şekil 4.13'te D sınıfına ait boyut olarak aynı olarak değerlendirilirken farklı sınıflara yakın çıkması ve farklı Ro-Ro gemilerinin karakteristik özellikleri farklı olması sınıflarının farklı çıkmasına sebep olmuştur.

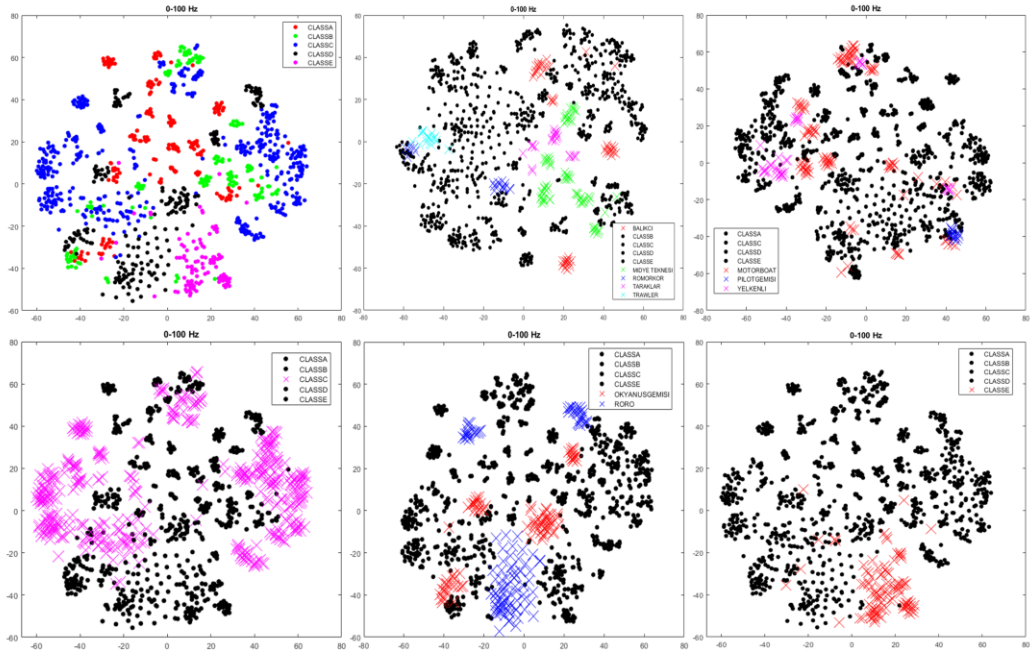


Şekil 4.13: ShipEar veri kümesi tablo 4.1'de yer alan D sınıfa ait t-SNE algoritması kullanılarak elde edilen grafikler.



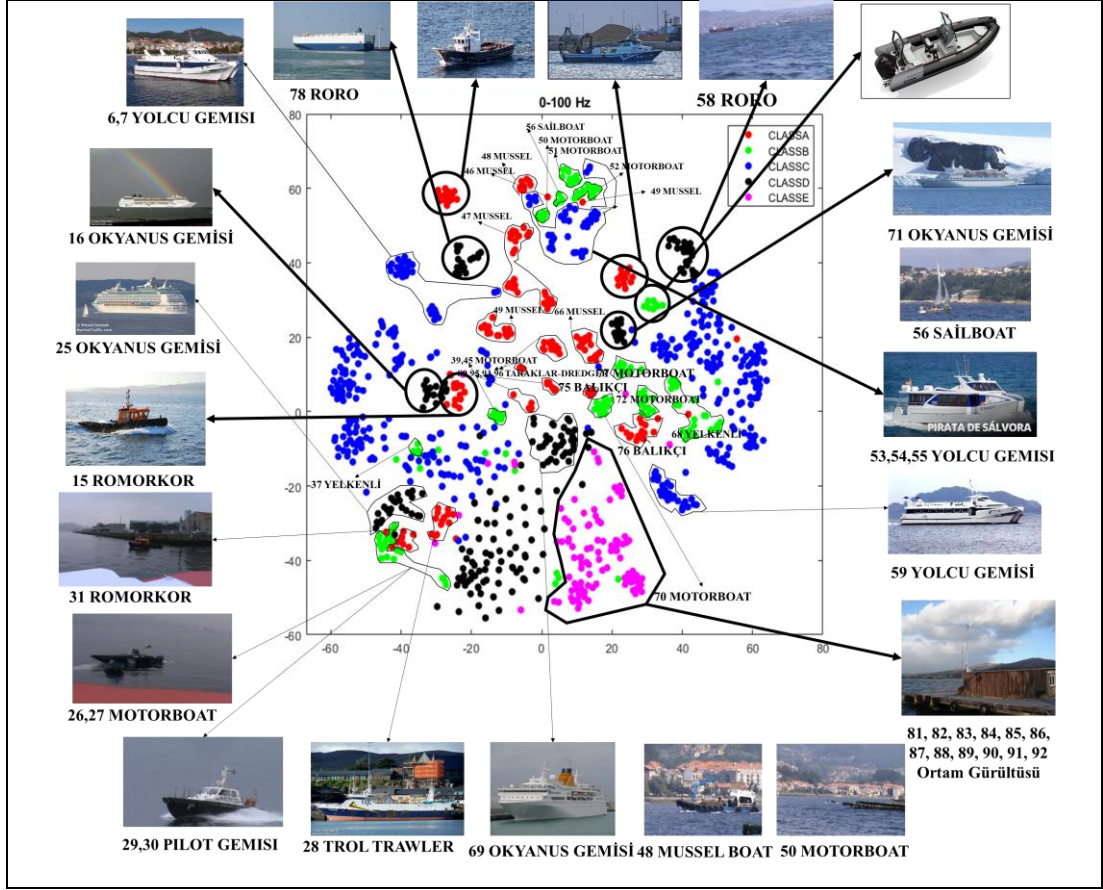
Şekil 4.14: ShipEar veri kümesi Tablo 4.1'de yer alan E sınıfa ait t-SNE algoritması kullanılarak elde edilen grafikler.

Şekil 4.14'te E sınıfına ait farklı zamanlarda kaydedilmiş ortam gürültüsü karakteristik olarak aynı sınıflarda çıktığı görülmektedir. Şekil 4.15'te inceleme gerçekleştirmek amacıyla Şekil 4.10-14 bir arada yer verilmektedir.



Şekil 4.15: ShipEar veri kümesi şekil 4.10-14 bir arada incelenmesi.

Tablo 4.1'de görülen sınıflar Şekil 4.16'da görüldüğü üzere detaylı incelenmiştir. Aykırı olan tek gemi ses kaydı olması, aynı boyutta olan gemilerin farklı makine konfigürasyonuna sahip olması vb. sebeplerden dolayı benzer karakteristiğe sahip gemilerin bir arada olduğu Tablo 4.3'te yer alan 5 sınıf oluşturulmuştur.




Şekil 4.16: ShipEar veri kümesi 0-100 Hz frekans arası detaylı incelenmesi.

Tablo 4.3: ShipEar gürültü karakteri benzer sınıflar.

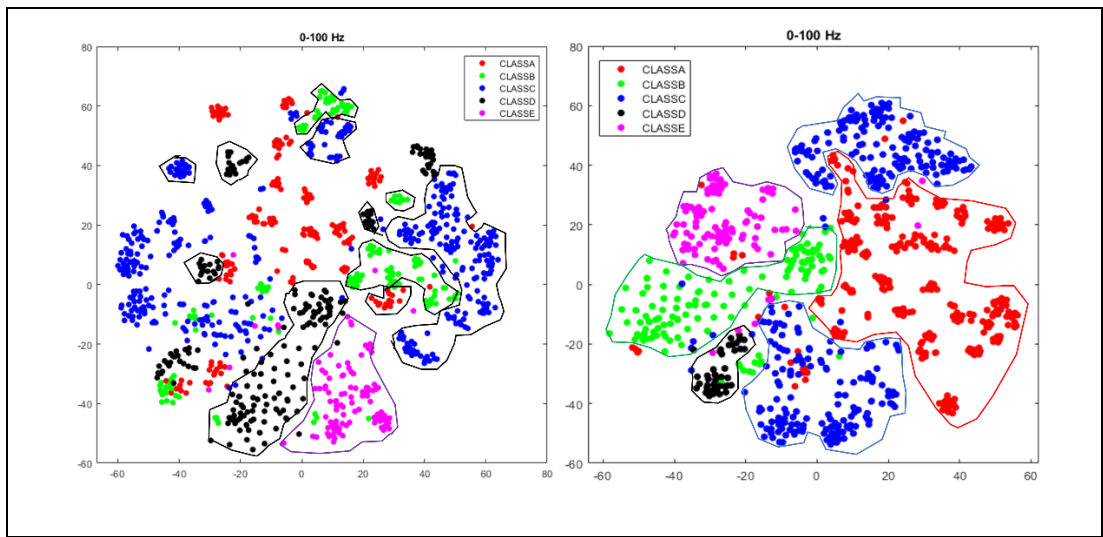
Sınıf	Gemi Tipi	Gemi Sayısı
A	Balıkçı tekneleri, Midye tekneleri, Motorlu tekneler ve taraklar, Yelkenli tekneler	28
B	Okyanus Gemileri, Ro-Ro gemileri	7
C	Yolcu feribotları	25
D	Pilot tekneler, Römorkörler	6
E	Arka plan gürültü kayıtları	12

Oluşturulan benzer karakteristiklere sahip gemiler ve boyuta göre gemiler t-SNE kullanılarak görselleştirilerek Tablo 4.1 ve Tablo 4.3'te yer alan sınıflara göre karşılaştırma yapılmıştır. 0-100 ve 0-200 Hz frekans aralığında LOFAR-D algoritması ve LOFAR-DDC algoritması ile elde edilen LOFAR verilerinin sırasıyla Şekil 4.17 ve Şekil 4.18'de yapılan görselleştirme ile benzer karakteristiklere sahip verilerin görsel dağılımını daha iyi olduğu gözlenmektedir. Farklı frekans aralıkları kullanılarak

gösterilmesi en iyi sınıflandırma sonuçlarından seçilen aralıklar seçilerek görselleştirme gerçekleştirilmiştir.

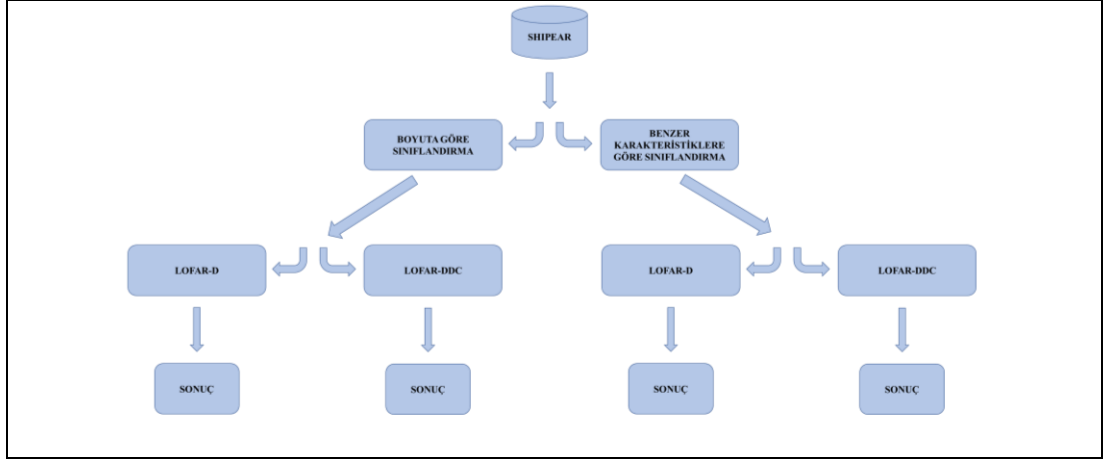


Şekil 4.17: ShipEar veri kümesi 0-200 Hz frekans arası tablo 4.1’de gemi boyutlarına göre (Solda) ve tablo 4.3’te gemi karakteristik olarak benzer t-SNE kullanılarak yüksek boyutlu LOFAR sinyali özneliğinin görselleştirilmesi.



Şekil 4.18: ShipEar veri kümesi 0-100 Hz frekans arası tablo 4.1’de gemi boyutlarına göre (Solda) ve tablo 4.3’te gemi karakteristik olarak benzer t-SNE kullanılarak yüksek boyutlu LOFAR sinyali özneliğinin görselleştirilmesi.

Analizler sonrası elde edilen bilgiler ile LOFAR algoritmaları kullanılarak sonuçlar için akış şeması Şekil 4.19’da gösterilmektedir. Sonraki bölümde sonuçlar gösterilmektedir.



Şekil 4.19: Analiz sonrası akış şeması.

#### 4.1.4. Sınıflandırma Sonuçları

Farklı sınıflandırıcılar ile analizler sonucu farklı sınıflar test edilmektedir. Tablo 4.4'te LOFAR-D algoritması ve boyuta göre sınıflandırma sonuçları yer almaktadır. KNN sınıflandırıcı ile 0-200 Hz arası en yüksek başarı elde edilmiştir.

Tablo 4.4: LOFAR-D algoritması ve tablo 4.1'e göre sınıflandırma sonuçları.

Model Tipi	Frekans Aralıkları / Hz					
	0-50	0-100	0-200	0-400	0-800	0-1600
KNN	48.18	75.67	83.78	75.67	73.51	69.73
ENSEMBLE	*	64.32	72.43	68.10	70.81	69.18
SVM	*	63.78	76.21	63.78	65.40	65.40
LINEAR DISCRIMINANT	*	61.08	75.13	70.27	64.40	69.19

\*%48 altında çıkan değerlerdir.

Tablo 4.5'te LOFAR-D Algoritması ve boyuta ve benzer karakteristiklere göre sınıflandırma sonuçları yer almaktadır. KNN sınıflandırıcı ile 0-200 Hz arası en yüksek başarı elde edilmiştir.

Tablo 4.5: LOFAR-D algoritması ve tablo 4.3'ye göre sınıflandırma sonuçları.

Model Tipi	Frekans Aralıkları / Hz					
	0-50	0-100	0-200	0-400	0-800	0-1600
KNN	Benzer boyut ile sınıflandırma					
	48.18	75.67	83.78	75.67	73.51	69.73
KNN	Benzer gürültü karakteristiği ile sınıflandırma					
	49.74	77.38	86.93	86.92	83.41	74.37

Tablo 4.6'da LOFAR-DDC Algoritması ve boyuta göre sınıflandırma sonuçları yer almaktadır. KNN sınıflandırıcı ile 0-100 Hz arası en yüksek başarı elde edilmiştir. Tablo 4.7'de LOFAR-DDC Algoritması ve benzer karakteristiklere göre sınıflandırma sonuçları yer almaktadır. KNN sınıflandırıcı ile 0-100 Hz arası en yüksek başarı elde edilmiştir.

Tablo 4.6: LOFAR-DDC algoritması ve tablo 4.1'e göre sınıflandırma sonuçları.

Model Tipi	Doğruluk	Frekans Aralıkları / Hz					
		0-50	0-100	0-200	0-400	0-800	0-1600
KNN	Validasyon (%)	74.5	89.7	91.7	89.7	90.8	90.1
	Test (%)	62.16	83.7	74.05	75.6	72.97	71.35

Tablo 4.7: LOFAR-DDC algoritması ve tablo 4.3'e göre sınıflandırma sonuçları.

Model Tipi	Doğruluk	Frekans Aralıkları / Hz					
		0-50	0-100	0-200	0-400	0-800	0-1600
KNN	Validasyon (%)	79	92.2	93.4	91.6	89.6	91.2
	Test (%)	71.35	91.45	87.43	81.91	78.39	75.37

Tablo 4.8'de LOFAR-DDC Algoritması ile elde edilen başarı matrisi sonuçları görülmektedir.

Tablo 4.8: Tablo 4.6 ve 4.7 başarı matrisleri.

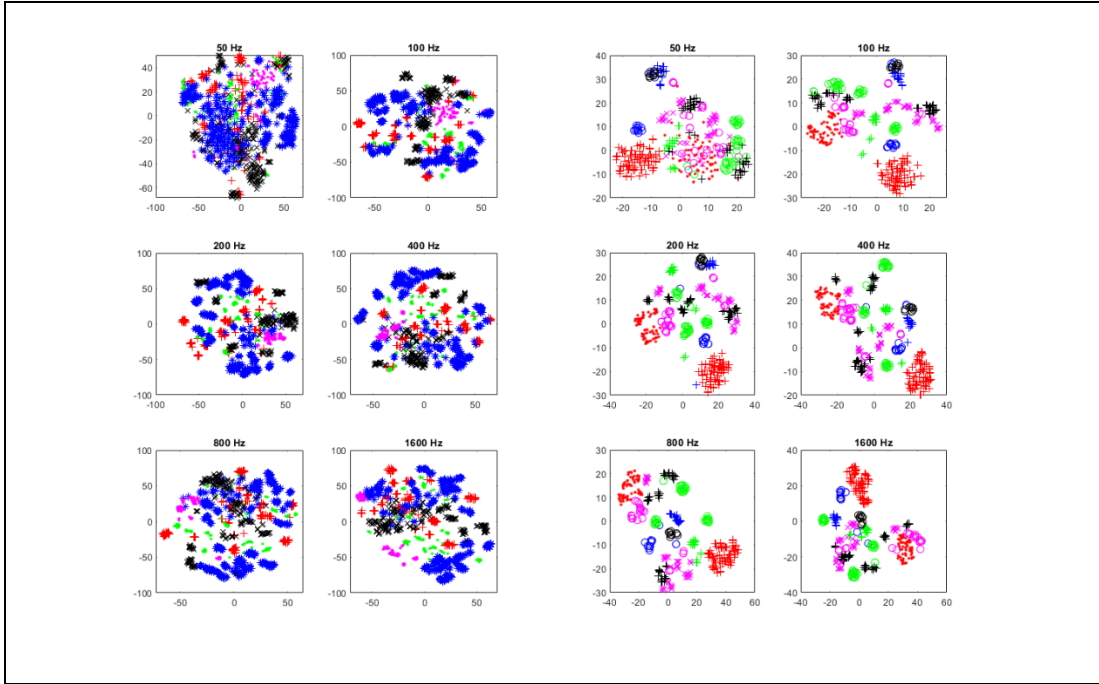
SONUÇLAR													
Tablo 4.6 Sonuçları						Tablo 4.7 Sonuçları							
Validasyon Başarı Matrisi													
Gerçek	A	119	13	7	3		Gerçek	A	200		17		3
	B	3	94	16	5	4		B	2	108	2	4	
	C	7	7	342	6			C	11	3	230		
	D	3	2	1	189	1		D				31	
	E	3	1	5	5	57		E	3	4	3	1	60
		A	B	C	D	E			A	B	C	D	E
	Tahmin						Tahmin						
Test Başarı Matrisi													
Gerçek	A	26	8	2	3		Gerçek	A	47	5	2		
	B		21	4				B		36			
	C	3	6	41		1		C	9		61		
	D	2		1	37			D				9	
	E					30		E		1			29
		A	B	C	D	E			A	B	C	D	E
	Tahmin						Tahmin						

5 sınıflı sınıflandırmanın yanında 10 sınıfa göre sınıf oluşturularak Yuan ve arkadaşlarının [19] ShipEar veri kümesi ile sınıflandırmalar gerçekleştirilmiştir. Şekil 4.20'de Yuan vd. [19] ShipEar veri kümesi için 10 sınıf görülmektedir.

ID	
Class 1: Passenger ferries	60, 61, 62
Class 2: Tugboats	15, 31
Class 3: RO-RO vessels	18, 19, 20
Class 4: Ocean liners	22, 24, 25
Class 5: Pilot boats	29, 30
Class 6: Motorboats	50, 51, 52, 70, 72, 77, 79
Class 7: Mussel boats	46, 47, 48, 49, 66
Class 8: Sailboats	37, 56, 57, 68
Class 9: Fishing boats	73, 74, 75, 76
Class 10: Dredgers	80, 93, 94, 95, 96

Şekil 4.20: Yuan vd. ShipEar 10 sınıf.

Şekil 4.21’de Tablo 4.1’de yer alan 5 sınıf (Solda) ve Şekil 4.20’de yer alan 10 sınıfa (Sağda) göre t-SNE görselleştirilmesi görülmektedir. 10 sınıf oluşturulması ve benzer karakteristiklerin bir arada bulunmasıyla dağılımın daha fazla ayırt edici olduğu gözlemlenmektedir.



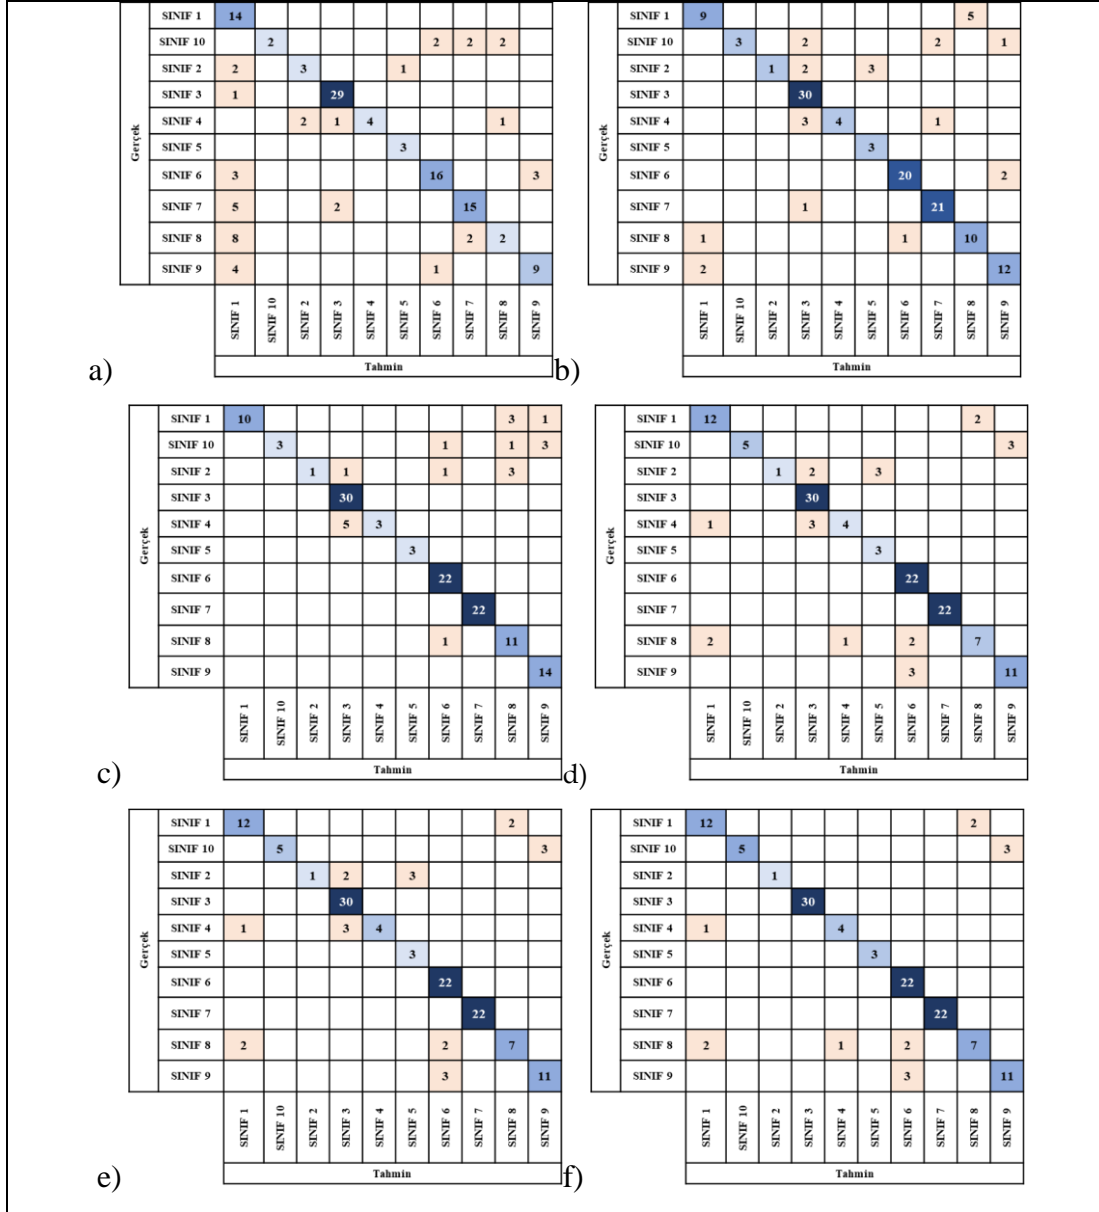
Şekil 4.21: Farklı örnekleme frekanslarından oluşan verilerin t-SNE algoritması kullanarak elde edilen grafikleri.

Tablo 4.9: LOFAR-DDC algoritması ve şekil 4.20’ye göre sınıflandırma sonuçları.

Model Tipi	Frekans Aralıkları / Hz					
	0-50	0-100	0-200	0-400	0-800	0-1600
KNN	69.06	79.14	81.29	84.17	86.33	83.45
ENSEMBLE	61.15	81.29	76.98	71.94	68.35	69.78
SVM	61.87	76.98	79.14	77.70	69.78	62.59
LINEAR DISCRIMINANT	66.91	84.89	84.17	84.17	79.86	69.78
NAİVE BAYES	69.78	82.73	85.61	82.7	77.70	68.35

Şekil 4.22’de Tablo 4.9’da yer alan 10 sınıfa göre farklı sınıflandırıcı sonuçlarının en yüksek doğruluğa sahip olan ve yeşil işaretli başarı matrisleri yer

almaktadır. a) 0-50, b) 0-100, c) 0-200, d) 0-400, e) 0-800 ve f) 0-1600 Hz arasında yer alan yeşil işaretli sonuçların karşılığı sınıflandırıcıların başarı matrisleri gösterilmektedir.



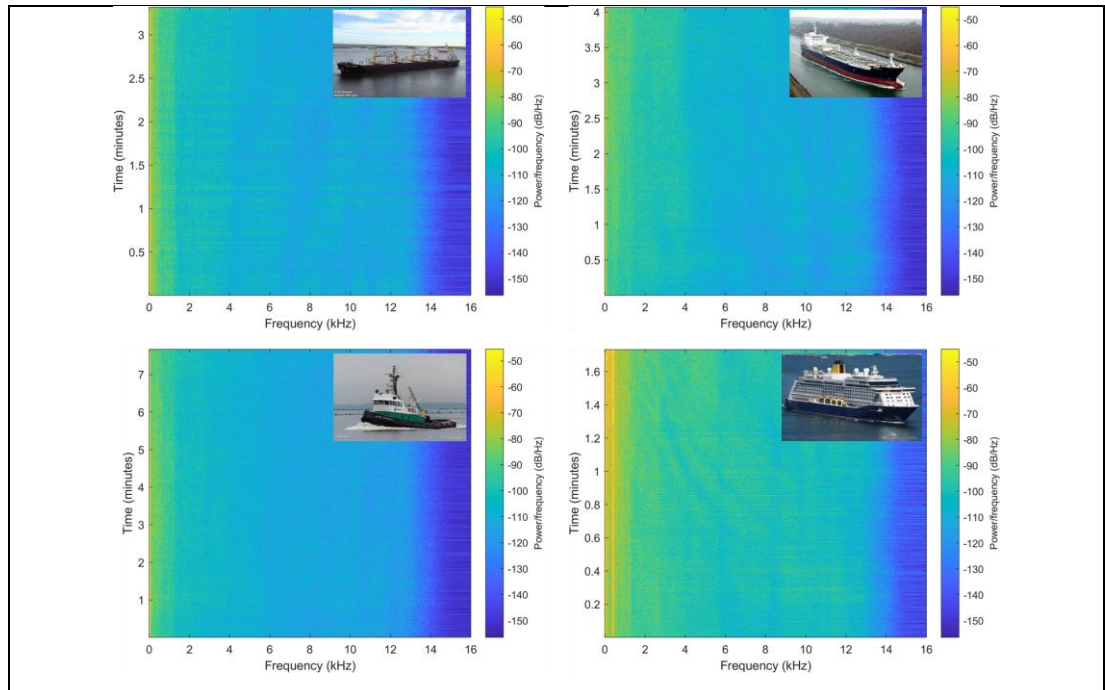
Şekil 4.22: Tablo 4.9’da yüksek başarı sonuçları kalın işaretli sonuçların başarı matrisleri.

## 4.2. DeepShip Veri Kümesi Analiz ve Sonuçlar

Bu alt bölümde DeepShip veri kümesi analiz sonuçları verilmektedir. Öncelikle zaman frekans spektrum analizi, güç spektrum yoğunluğu kestirimi devamında verilerin görselleştirilmesi ve son olarak sınıflandırma sonuçları gösterilmektedir.

### 4.2.1. Zaman Frekans Spektrum Analizi

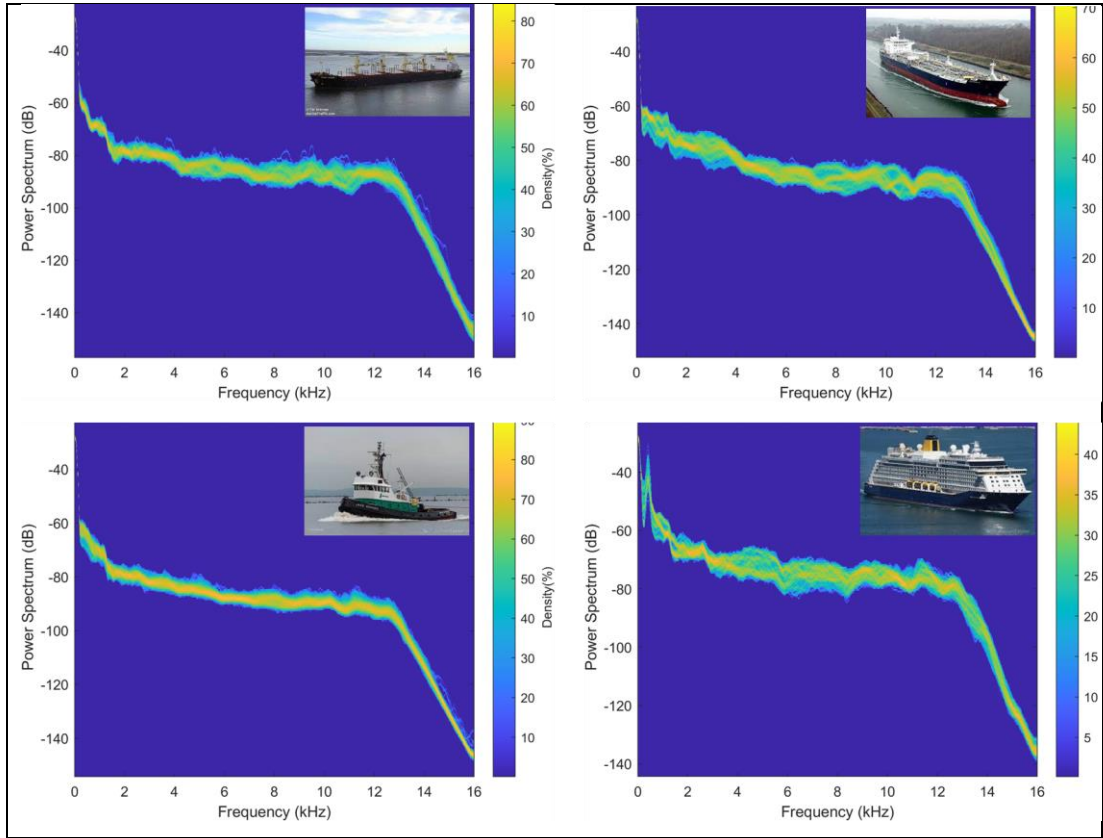
Zaman frekans analizi ile akustik sinyallerin yoğun olduğu frekans aralıkları incelenmektedir. DeepShip veri kümesinde yer alan sualtı akustik ses verilerinin örnekleme frekansı 32000 Hz'tir. Ses verilerinin spektrumları incelendiğinde anlamlı verilerin 4 kHz'e kadar olduğu anlaşılmıştır. Sualtı akustik sinyale önce örtüşme önleyici alçak geçiren filtre uygulanmış ve yeniden örneklenerek 8 kHz örnekleme frekansına sahip sinyaller elde edilmiştir. Şekil 4.23'te farklı gemiler için spektrumlar gösterilmektedir.



Şekil 4.23: Sualtı akustik sinyal spektrum analizi.

## 4.2.2. Güç Spektrum Yoğunluğu Kestirimi

Gemilerden yayılan gürültüler ile güç spektrum yoğunluğu analizi ile geminin karakteristik özellikleri ile seyir durumu hakkında önemli bilgiler elde edilebilir. Şekil 4.24'te görüldüğü üzere DeepShip veri kümesinde 4 sınıfa ait farklı gemilerin güç spektrumlarının farkı görülmektedir. Gemi sınıflarına ait gemilerin güç spektrumlarının benzer olduğu görülmektedir. Hedef tanıma için kullanılan LOFAR öznelik olarak kullanılarak Tablo 2.3'te yer alan karakteristik olarak benzer gemilerin sınıflandırılmasında kullanılabileceğini gözler önüne sermektedir. Benzer gemilerin sınıflandırma problemi olarak zor olduğu Şekil 4.24 göstermektedir.

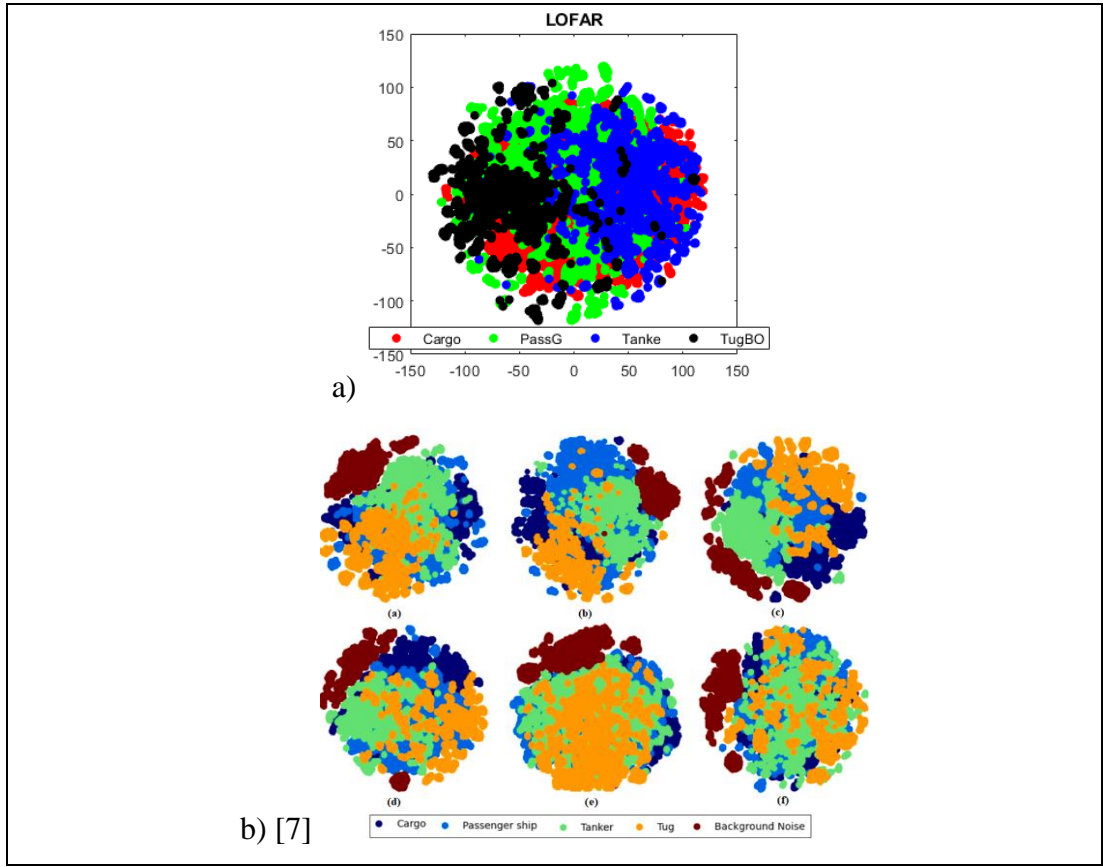


Şekil 4.24: DeepShip veri kümesi güç spektrum grafikleri.

## 4.2.3. t-SNE ile Yüksek Boyutlu Verileri Görselleştirilmesi Analizi

t-SNE kullanılarak LOFAR sinyali öznelik vektörü görselleştirilerek DeepShip'te yer alan t-SNE grafiği ile karşılaştırılması Şekil 4.25'te gösterilmektedir. Şekil 4.25 a) LOFAR sinyali öznelik vektörü görselleştirmesinin b) Irfan ve

arkadaşlarının farklı öznelilikler kullanarak görselleştirmeleri ile benzer ayrışım gösterdiği görülmektedir.



Şekil 4.25: t-SNE algoritması kullanılarak elde edilen a) grafiği b) İrfan ve arkadaşlarının elde ettiği grafikler.

#### 4.2.4. Sınıflandırma Sonuçları

Farklı sınıflandırıcılar ile analizler sonucu farklı sınıflar test edilmektedir. Tablo 2.3'te yer alan 4 sınıf farklı sınıflandırıcılar ile test edilmektedir. Tablo 4.10'da LOFAR-DDC Algoritması ve Tablo 4.11'de LOFAR-D Algoritması ile sınıflandırma sonuçları yer almaktadır.

Tablo 4.10: LOFAR-DDC algoritması ve tablo 2.3'e göre sınıflandırma sonuçları.

Model Tipi	Doğruluk	Frekans Aralıkları / Hz				
		0-50	0-100	0-200	0-400	0-800
KNN	Validasyon (%)	72.70	78.86	93.37	92.13	95.01
	Test (%)	50.57	49.85	56.54	61.96	65.58
SVM	Validasyon (%)	72.16	74.05	81.16	79.48	78.57
	Test (%)	56.81	55.04	57.04	61.33	62.22
Naïve Bayes	Validasyon (%)	51.31	52.84	57.51	62.61	64.32
	Test (%)	48.10	48.89	49.52	55.36	62.12

Şekil 4.25'te Tablo 4.10'da yer alan KNN'e ait a), b), c), d), e) sırasıyla 0-50, 0-100, 0-200, 0-400, ve 0-800 Hz aralıklarında başarı matrisleri gösterilmektedir. KNN ile 0-400 Hz aralığında en yüksek başarı 63.74 elde edilmiştir.

Gerçek	KARGO	106	43	174	365	Tahmin
	YOLCU	43	270	30	309	
	TANKER	189	96	543	175	
	TUG	8	28	18	614	
		KARGO	YOLCU	TANKER	TUG	
a)						
Gerçek	KARGO	119	59	173	357	Tahmin
	YOLCU	48	326	38	240	
	TANKER	243	108	474	178	
	TUG	12	42	22	592	
		KARGO	YOLCU	TANKER	TUG	
b)						
Gerçek	KARGO	229	55	197	227	Tahmin
	YOLCU	41	406	57	146	
	TANKER	241	102	535	125	
	TUG	21	69	36	542	
		KARGO	YOLCU	TANKER	TUG	
c)						
Gerçek	KARGO	303	104	174	127	Tahmin
	YOLCU	57	451	21	123	
	TANKER	173	113	645	72	
	TUG	46	111	32	479	
		KARGO	YOLCU	TANKER	TUG	
d)						
Gerçek	KARGO	372	115	107	114	Tahmin
	YOLCU	40	506	11	95	
	TANKER	157	114	650	82	
	TUG	38	130	40	460	
		KARGO	YOLCU	TANKER	TUG	
e)						

Şekil 4.26: Tablo 4.10 KNN sınıflandırma başarı matrisleri.

Şekil 4.26'da Tablo 4.10'da yer alan SVM'e ait a), b), c), d), e) sırasıyla 0-50, 0-100, 0-200, 0-400, ve 0-800 Hz aralıklarında başarı matrisleri gösterilmektedir. SVM ile 0-400 Hz aralığında en yüksek başarı 60.54 elde edilmiştir.

Gerçek	KARGO	168	156	135	249	Tahmin	KARGO	YOLCU	TANKER	TUG
	YOLCU	48	440	32	132					
	TANKER	165	174	617	47					
	TUG	14	132	25	497					
a)										
Gerçek	KARGO	178	125	164	241	Tahmin	KARGO	YOLCU	TANKER	TUG
	YOLCU	48	450	41	113					
	TANKER	221	166	564	52					
	TUG	23	146	22	447					
b)										
Gerçek	KARGO	272	109	163	164	Tahmin	KARGO	YOLCU	TANKER	TUG
	YOLCU	62	462	76	52					
	TANKER	256	127	569	51					
	TUG	44	182	16	426					
c)										
Gerçek	KARGO	296	124	158	128	Tahmin	KARGO	YOLCU	TANKER	TUG
	YOLCU	62	494	46	50					
	TANKER	254	90	628	31					
	TUG	40	164	25	439					
d)										
Gerçek	KARGO	308	115	114	171	Tahmin	KARGO	YOLCU	TANKER	TUG
	YOLCU	60	461	66	65					
	TANKER	250	77	645	31					
	TUG	52	121	23	472					
e)										

Şekil 4.27: Tablo 4.10 SVM sınıflandırma başarı matrisleri.

Şekil 4.27'da Tablo 4.10'da yer alan Naive Bayes'e ait a), b), c), d), e) sırasıyla 0-50, 0-100, 0-200, 0-400, ve 0-800 Hz aralıklarında başarı matrisleri gösterilmektedir. Naive Bayes ile 0-800 Hz aralığında en yüksek başarı 62.59 elde edilmiştir.

Gerçek	KARGO	122	123	153	310
	YOLCU	42	264	62	284
	TANKER	245	210	477	71
	TUG	31	38	4	595
		KARGO	YOLCU	TANKER	TUG
a)		Tahmin			
Gerçek	KARGO	97	148	176	287
	YOLCU	32	299	93	228
	TANKER	215	193	510	85
	TUG	20	59	13	576
		KARGO	YOLCU	TANKER	TUG
b)		Tahmin			
Gerçek	KARGO	108	121	191	288
	YOLCU	31	299	99	223
	TANKER	173	173	568	89
	TUG	17	108	17	526
		KARGO	YOLCU	TANKER	TUG
c)		Tahmin			
Gerçek	KARGO	191	80	182	255
	YOLCU	66	370	51	165
	TANKER	206	98	632	67
	TUG	41	119	23	485
		KARGO	YOLCU	TANKER	TUG
d)		Tahmin			
Gerçek	KARGO	215	61	183	249
	YOLCU	45	398	58	151
	TANKER	164	49	726	64
	TUG	43	43	38	544
		KARGO	YOLCU	TANKER	TUG
e)		Tahmin			

Şekil 4.28: Tablo 4.10 Naive Bayes sınıflandırma başarı matrisleri.

Tablo 4.11: LOFAR-D algoritması ve tablo 2.3'e göre sınıflandırma sonuçları.

Model Tipi	Doğruluk	Frekans Aralıkları / Hz				
		0-50	0-100	0-200	0-400	0-800
KNN	Validasyon (%)	66.40	74.5	92.71	92.93	91.51
	Test (%)	45.7	49.5	57.9	63.74	62.8
SVM	Validasyon (%)	70.74	73.80	82.14	79.52	73.32
	Test (%)	55.16	56.35	59.08	60.54	57.14
Naive Bayes	Validasyon (%)	51.94	53.80	55.50	64.01	64.65
	Test (%)	46.18	48.19	50.14	54.17	62.59

Şekil 4.27'te Tablo 4.11'de yer alan KNN'e ait a), b), c), d), e) sırasıyla 0-50, 0-100, 0-200, 0-400, ve 0-800 Hz aralıklarında başarı matrisleri gösterilmektedir. KNN ile 0-400 Hz aralığında en yüksek başarı 63.74 elde edilmiştir.

Gerçek	KARGO	77	76	139	416
	YOLCU	21	216	9	406
	TANKER	171	126	506	200
	TUG	5	57	19	587
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

a)

Gerçek	KARGO	105	76	152	375
	YOLCU	38	333	25	256
	TANKER	239	118	459	187
	TUG	9	35	20	604
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

b)

Gerçek	KARGO	250	58	186	214
	YOLCU	43	406	57	146
	TANKER	274	101	530	98
	TUG	33	39	27	569
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

c)

Gerçek	KARGO	294	77	176	161
	YOLCU	46	435	47	124
	TANKER	184	97	670	52
	TUG	47	59	29	533
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

d)

Gerçek	KARGO	385	128	106	87
	YOLCU	80	438	21	113
	TANKER	171	170	598	64
	TUG	56	87	41	484
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

e)

Şekil 4.29: Tablo 4.11 KNN sınıflandırma başarı matrisleri.

Gerçek	KARGO	148	142	141	277
	YOLCU	40	379	29	204
	TANKER	170	206	598	29
	TUG	17	83	21	547
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

a)

Gerçek	KARGO	176	134	147	251
	YOLCU	60	440	36	116
	TANKER	181	149	620	53
	TUG	13	156	27	472
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

b)

Gerçek	KARGO	279	106	154	169
	YOLCU	64	479	39	70
	TANKER	234	105	629	35
	TUG	55	192	17	404
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

c)

Gerçek	KARGO	293	111	148	156
	YOLCU	62	489	48	53
	TANKER	247	120	608	28
	TUG	43	160	20	445
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

d)

Gerçek	KARGO	275	145	120	168
	YOLCU	76	423	95	58
	TANKER	257	139	570	37
	TUG	39	134	31	464
		KARGO	YOLCU	TANKER	TUG
		Tahmin			

e)

Şekil 4.30: Tablo 4.11 SVM sınıflandırma başarı matrisleri.

Gerçek	KARGO	115	76	293	330	Tahmin
	YOLCU	87	426	133	443	
	TANKER	259	170	516	61	
	TUG	29	36	8	595	
a)						
Gerçek	KARGO	112	110	299	293	Tahmin
	YOLCU	56	467	187	379	
	TANKER	201	167	569	69	
	TUG	21	55	16	576	
b)						
Gerçek	KARGO	124	103	312	275	Tahmin
	YOLCU	67	513	178	331	
	TANKER	149	164	628	65	
	TUG	19	104	16	529	
c)						
Gerçek	KARGO	280	83	271	180	Tahmin
	YOLCU	116	533	161	279	
	TANKER	211	104	636	55	
	TUG	28	127	24	489	
d)						
Gerçek	KARGO	371	77	223	143	Tahmin
	YOLCU	119	595	134	241	
	TANKER	172	48	739	47	
	TUG	41	54	39	534	
e)						

Şekil 4.31: Tablo 4.11 Naive Bayes sınıflandırma başarı matrisleri.

Tablo 4.12’de Irfan ve arkadaşlarının farklı öznelik kullanarak elde ettiği başarı değerleri ile bu tez çalışması kapsamında LOFAR-D ve LOFAR-DDC algoritmaları kullanılarak elde edilen en yüksek başarı değerleri ile karşılaştırılması gösterilmektedir.

Tablo 4.13’te Literatürde kullanılan LOFAR algoritması ile ShipEar ve DeepShip veri kümesi kullanılarak elde edilen başarı değerleri gösterilmektedir.

Tablo 4.12: Irfan vd. ile karşılaştırmalı deney sonuçları.

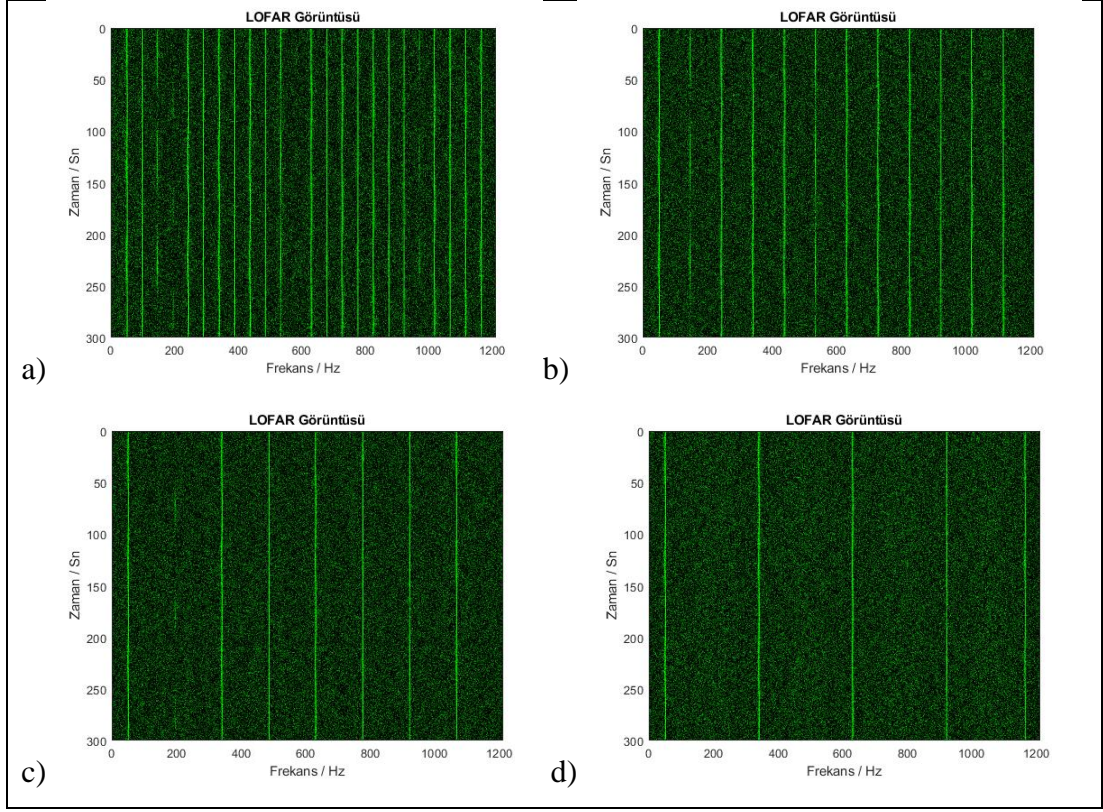
Model Tipi	Doğruluk (%)	Bu Çalışma	Irfan vd. [7]					
		LOFAR-D, LOFAR-DDC	Mel-spectrogram	MFCC	CQT	Wavelets	Kepstrum	Gammatone
KNN		65.58	58.11	54.96	62.71	50.04	49.75	61.93
SVM		62.22	64.83	58.33	72.24	55.47	71.74	68.86
Naïve Bayes		62.59	48.00	46.12	53.97	45.09	53.50	55.09

Tablo 4.13: Literatür çalışmalarında kullanılan LOFAR algoritması sonuçları.

Veri Kümesi	Model Tipi	Komponent	PCA				
			-	5	10	15	20
ShipEar [6]	KNN	Benzer boyut ile sınıflandırma	48.1	40.54	31.89	38.91	40.54
		Benzer gürültü karakteristiği ile sınıflandırma	58.29	42.21	43.71	45.7	46.7
DeepShip [7]		-	39.25	35.92	37.21	38.63	37.49

### 4.3. Sentetik Veri Analiz

Literatüre katkı amacıyla kullanıcı tarafından belirlenen parametrelerle sinüs dalgaları kullanılarak gerçek verilere benzer sentetik veriler elde edilmektedir. Operatör tarafından belirlenen frekanslara sinüs dalgaları belirli genlik ve periyotlarda seçildikten sonra gürültü eklenerek sentetik veriler elde edilmiştir. Ayrıca veri uzunluğu ve örnekleme frekansı operatör tarafından belirlenerek elektronik harp amacıyla sinyal karıştırma, düşman hedeflerini aldatma amacıyla kullanılması amaçlanmaktadır. Şekil 4.32’de operatör tarafından farklı frekanslarda belirlenmiş, 32 kHz örnekleme frekansına sahip 300 Sn. uzunluğunda gürültü eklenerek elde edilmiş sentetik veriler LOFAR algoritması kullanılarak görüntülenmektedir.



Şekil 4.32: Sentetik veri.

## 5. SONUÇ

Bu çalışmada LOFAR algoritması ile üretilen görüntüler öznitelik olarak kullanılarak sınıflandırma gerçekleştirilmiştir. Tek bir frekans aralığı yerine 6 farklı frekans aralığında ayrı ayrı olmak üzere LOFAR algoritması ile elde edilen görüntüler öznitelik olarak kullanılıp sınıflandırma performansları incelenmiştir. t-SNE algoritması kullanılarak veriler görselleştirildiğinde gemileri boyutlarına göre sınıflandırmaktan ziyade benzer gürültü karakteristiklerine sahip olanlar aynı sınıfta olduğunda öznitelik uzayında daha kompakt öbekler oluşturduğu gözlemlenmiştir. Bu gözleme göre gruplandırıldığında, gemileri boyutu yerine gürültü karakteristiğine göre gruplandırmanın daha yüksek doğrulukta sınıflandırmaya sebep olduğu görülmüştür. Sınıflandırma performansı farklı frekans aralıkları için incelenmiş, tüm aralıklarda performansın iyileştiği görülmüştür.

## KAYNAKLAR

- [1] Ece N. J., (2020), “Covid-19 Salgınının Konteyner Taşımacılığı ve Limanlarına Etkisi”, Mersin Üniversitesi Denizcilik ve Lojistik Araştırmaları Dergisi, 2 (2), 47-66.
- [2] Yılmaz E. A., (2020), “Doğu Akdeniz’deki Gelişmeler Doğrultusunda Türk Dış Politikası’nın Dünü ve Bugünü”, Karadeniz Uluslararası Bilimsel Dergi, 1 (48), 27-48.
- [3] Garrido J. M. A., (2019), “Maestro En Ingeniería Aplicada”, Doktora Tezi, Universidad Veracruzana.
- [4] Agrawal H., Das A., (2021), “Passive sonar simulator and interactive applications”, Resaerch Note, Maritime Research Center, India.
- [5] Ulug U., Akgul T., Gezer C., (2008), “Ambient noise measurements in the strait of istanbul”, Proceedings of the Institute of Acoustics, Conference on Underwater Noise Measurement, 30, 35-42, Ekim 2008.
- [6] Santos-Domínguez D., Torres-Guijarro S., Cardenal-López A., Pena-Gimenez A., (2016), “ShipsEar: An Underwater Vessel Noise Database”, Applied Acoustics, 113, 64-69, Aralık 2016.
- [7] Irfan M., Jiangbin Z., Ali S., Iqbal M., Masood Z., Hamid U., (2021), “DeepShip: An Underwater Acoustic Benchmark Dataset and a Separable Convolution Based Autoencoder for Classification”, Expert Systems with Applications, 183, 115270, Kasım 2021.
- [8] Zhu S., Yang Y., Wang Y., Yang Q., Yan X., (2017), “Performance of a Cylindrical Hydrophone Array for Practical Use”, içinde 2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC), 1-5, Xiamen, Ekim 2017.
- [9] Ozen S., Oner M., Cavuslu M. A., Ilguy A. C., Tatar O., Basaran Y. H., (2013), “Simulation and Estimation of Underwater Acoustical Tonals Emanating from Naval Platforms”, içinde 2013 21st Signal Processing and Communications Applications Conference (SIU), 1-4, Haspolat, Türkiye, Nisan 2013.
- [10] Waite A. D., (2002), Sonar for Practising Engineers, 3rd Edition Wiley.
- [11] Fırat U., Akgül T., (2017), “Gemi Akustik İz Analizi”, EMO Bilimsel Dergi, 7 (13), 25-31.

- [12] Neupane D., Seok J., (2020), "A Review on Deep Learning-Based Approaches for Automatic Sonar Target Recognition", *Electronics*, 9 (11), 1972.
- [13] de Moura N. N., de Seixas J. M., Ramos R., (2011), "Passive Sonar Signal Detection and Classification Based on Independent Component Analysis", *Sonar Systems*, N. Kolev, Ed. InTech.
- [14] Pollara A., Sutin A., Salloum H., (2017), "Passive Acoustic Methods of Small Boat Detection, Tracking and Classification", *IEEE International Symposium on Technologies for Homeland Security (HST)*, 1-6, Waltham, MA, USA.
- [15] Chung K. W., Sutin A., Sedunov A., Bruno M., (2011), "DEMON Acoustic Ship Signature Measurements in an Urban Harbor", *Advances in Acoustics and Vibration*, 2011, 1-13.
- [16] de Simas Filho E. F., de Moura N. N., de Seixas J. M., (2016), "Neural Passive Sonar Signal Classification Using Independent Component Analysis", *Anais do 10. Congresso Brasileiro de Inteligência Computacional*, 1-7, Fortaleza, Ceará.
- [17] Yağcı T., (2005), "Target Classification and Recognition Using Underwater Acoustic Signals", *Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi*.
- [18] van der Maaten L., Hinton G., (2008), "Visualizing Data using t-SNE", *Journal of Machine Learning Research*, 9 (86), 2579-2605.
- [19] Yuan F., Ke X., Cheng E., (2019), "Joint Representation and Recognition for Ship-Radiated Noise Based on Multimodal Deep Learning", *Journal of Marine Science and Engineering*, 7 (11), 380.
- [20] Soares-Filho W., Manoel de Seixas J., Pereira Caloba L., (2001), "Principal Component Analysis for Classifying Passive Sonar Signals", *The 2001 IEEE International Symposium on Circuits and Systems (Cat. No.01CH37196)*, 2, 592-595, Sydney, NSW, Australia.
- [21] Soares-Filho W., Seixas J. M., Caloba L. P., (2002), "Enlarging Neural Class Detection Capacity in Passive Sonar Systems", *IEEE International Symposium on Circuits and Systems. Proceedings (Cat. No.02CH37353)*, 3, 105-108, Phoenix-Scottsdale, AZ, USA.
- [22] de Moura N. N., de Seixas J. M., (2015), "Novelty Detection in Passive SONAR Systems Using Support Vector Machines", *Latin America Congress on Computational Intelligence (LA-CCI)*, 1-6, Curitiba, Ekim 2015.
- [23] Mello V. dos S., de Moura N. N., de Seixas J. M., (2018), "Novelty Detection in Passive Sonar Systems using Stacked AutoEncoders", *International Joint Conference on Neural Networks (IJCNN)*, 1-7, Rio de Janeiro, Temmuz 2018.

- [24] Yue H., Zhang L., Wang D., Wang Y., Lu Z., (2017), “The Classification of Underwater Acoustic Targets Based on Deep Learning Methods”, program adı: 2017 2nd International Conference on Control, Automation and Artificial Intelligence (CAAI 2017), Sanya, China.
- [25] Chen J., Liu J., Liu C., Zhang J., Han B., (2021), “Underwater Target Recognition based on Multi-Decision LOFAR Spectrum Enhancement: A Deep Learning Approach”, ArXiv210412362 Eess, Erişim: 11 Şubat 2022. [Çevrimiçi]. Erişim adresi: <http://arxiv.org/abs/2104.12362>
- [26] Luo X., Zhang M., Liu T., Huang M., Xu X., (2021), “An Underwater Acoustic Target Recognition Method Based on Spectrograms with Different Resolutions”, *Journal of Marine Science and Engineering*, 9 (11), 1246.
- [27] Wang P., Peng Y., (2020), “Research on Underwater Acoustic Target Recognition Based on LOFAR Spectrum and Deep Learning Method”, içinde 2020 5th International Conference on Automation, Control and Robotics Engineering (CACRE), 666-670, Dalian, China, Eylül 2020.
- [28] Urban H. G., (2002), “Handbook of Underwater Acoustic Engineering”, STN-Atlas-Elektronik GmbH.
- [29] Liu F., Ding H., Li D., Wang T., Luo Z., Chen L., (2021), “Few-shot Learning with Data Enhancement and Transfer Learning for Underwater Target Recognition”, OES China Ocean Acoustics (COA), 992-994, Harbin, China, Tem. 2021.
- [30] Bıcakcı S., Aksüren I. G., Hocaoglu A. K., (2018), “Prohibited zone intrusion detection”, içinde 2018 26th Signal Processing and Communications Applications Conference (SIU), 1-4, İzmir, Türkiye, Mayıs 2018.
- [31] Hastie T., Tibshirani R., Friedman J. H., (2009), “The elements of statistical learning: data mining, inference, and prediction”, 2nd Edition, Springer.
- [32] Fisher R. A., (1936), “The Use of Multiple Measurements in Taxonomic Problems”, *Annals of Eugenics*, 7 (2), 179-188.
- [33] Bishop M.L.A., (2006), “Pattern Recognition and Machine Learning”, Springer.
- [34] Harris F. J., (2004), *Multirate Signal Processing for Communication Systems*, Second Edition, River Publishers.
- [35] Nezami M. K., (2002), “Performance Assessment of Baseband Algorithms for Direct Conversion Tactical Software Defined Receivers: I/Q Imbalance Correction, Image Rejection, DC Removal, and Channelization”, içinde *MILCOM 2002 Proceedings*, 369-376, Anaheim, CA, USA.

- [36] Rocchesso D., (2003), Introduction to Sound Processing. Firenze: Mondo estremo.
- [37] Oppenheim A. V., Schaffer R. W., (2014), Discrete-time Signal Processing, 3rd Edition, Pearson new international edition. Harlow: Pearson.
- [38] Carbone C. P., Kay S. M., (2012), “A Novel Normalization Algorithm Based on the Three-Dimensional Minimum Variance Spectral Estimator”, IEEE Transaction on Aerospace and Electronic Systems, 48 (1), 430-448.
- [39] Jayalakshmi T., Santhakumaran A., (2011), “Statistical Normalization and Back Propagation for Classification”, International Journal of Computer Theory and Engineering, 3 (1), 89-93.
- [40] Gonzalez R. C., Woods R. E., (2008), “Digital Image Processing”, 3rd Edition, Pearson.
- [41] Koşar O., (2017), “DDC Tabanlı Kanallaştırıcı Tasarımı”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.
- [42] Luo X., Feng Y., (2020), “An Underwater Acoustic Target Recognition Method Based on Restricted Boltzmann Machine”, Sensors, 20 ,18, 5399.

## ÖZGEÇMİŞ

İbrahim Gökhan Aksüren, 2012 yılında Polatlı Anadolu Lisesi'ni tamamladı ve ardından başladığı Gebze Yüksek Teknoloji Enstitüsü Mühendislik Fakültesi Elektronik Mühendisliği Bölümünü 2017 yılında başarıyla tamamladı. 2020 yılında yüksek lisans eğitimine Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalında başladı. Araştırma ilgi alanları arasında Sayısal İşaret İşleme, Görüntü İşleme, Örüntü Tanıma ve Akustik Sinyal İşleme yer almaktadır.

## **EKLER**

### **Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar**

Aksüren İ. G., Hoccođlu A. K., (2022), " Automatic Target Classification Using Underwater Acoustic Signals", 30th Signal Processing and Communications Applications Conference (SIU), 1-4.