

T.C.  
BAHÇEŞEHİR ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

İLERİ BAKIŞ GÖRÜNTÜLEME SONARI İLE SUALTINDA YAPAY  
NESNELERDEN REFERANSLA KONUMLANDIRMA

YÜKSEK LİSANS TEZİ

EMRE ESENCAN

İSTANBUL 2023

T.C.  
BAHÇEŞEHİR ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

İLERİ BAKIŞ GÖRÜNTÜLEME SONARI İLE SUALTINDA YAPAY  
NESNELERDEN REFERANSLA KONUMLANDIRMA

YÜKSEK LİSANS TEZİ

EMRE ESENCAN

TEZ DANIŞMANI  
DOÇ.DR. MEHMET BERKE GÜR

İSTANBUL 2023

T.C  
BAHÇEŞEHİR ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

.../.../...

YÜKSEK LİSANS TEZ ONAY FORMU

<b>Program Adı:</b>	BİLGİ TEKNOLOJİLERİ
<b>Öğrencinin Adı Soyadı:</b>	EMRE ESENCAN
<b>Tezin Adı:</b>	İLERİ BAKIŞ GÖRÜNTÜLEME SONARI İLE SUALTINDA YAPAY NESNELERDEN REFERANSLA KONUMLANDIRMA
<b>Tez Savunma Tarihi:</b>	EYLÜL 2023

Bu tezin Yüksek Lisans tezi olarak gerekli şartları yerine getirmiş olduğu Lisansüstü Eğitim Enstitüsü tarafından onaylanmıştır.

**Enstitü Müdürü**

Bu Tez tarafımızca okunmuş, nitelik ve içerik açısından bir Yüksek Lisans tezi olarak yeterli görülmüş ve kabul edilmiştir.

	Ünvanı Adı Soyadı	Kurumu	İmza
<b>Tez Danışmanı:</b>	Doç.Dr. Mehmet Berke GÜR	Bahçeşehir Üniversitesi	
<b>2. Üye (Kurum İçi):</b>	Dr.Öğr. Üyesi Görkem KAR	Bahçeşehir Üniversitesi	
<b>3. Üye (Kurum Dışı):</b>	Dr.Öğr. Üyesi Ahmet GÜNEŞ	Gebze Teknik Üniversitesi	



**Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.**

Ad, Soyad : Emre ESENCAN

İmza :

## ÖZET

### İLERİ BAKIŞ GÖRÜNTÜLEME SONARI İLE SUALTINDA YAPAY NESNELERDEN REFERANSLA KONUMLANDIRMA

ESENCAN Emre

Bilgi Teknolojileri Yüksek Lisans Programı

Tez Danışmanı: Doç. Dr. Mehmet Berke GÜR

Haziran 2023, 52 sayfa

Bu araştırma uzaktan kumandalı veya otonom sualtı araçlarının sualtındaki konumunun hesaplanması amacıyla, konumu bilinen yapay nesnelere ileri bakış sonarı simülasyonu ile eş zamanlı tespit edilerek sınıflandırılmasının yapılması ve buna bağlı olarak robotun konumunun simülasyon ortamında belirleme yaklaşımını içermektedir. Araştırmada ulaşılması zor, yüksek maliyetli sualtı akustik konumlandırma sistemlerine alternatif olarak düşük maliyetle, sonarda tespit edilen yansımaların makine öğrenmesi ile sınıflandırılması, konumu bilinen bu nesnelere mesafe tabanlı olarak multilaterasyon, kerteriz ve mesafe tabanlı olarak nirengi-üçgenleme yaklaşımları kullanılarak robotun konumunun hesaplanmasına cebirsel bir yaklaşım sunulmaktadır. Bununla birlikte sonarda temas elde edilememesi durumlarda robot üzerinde bulunan ataletsel sensörlerin birleşimi ile parakete seyri ile mevki konumlamasının yapılması gerçekleştirilmektedir. Tüm hesaplamalarda optimum doğruluğun sağlanması için doğrusal Kalman Süzgeci kullanılarak en iyi sonuç elde edilmektedir. Elde edilen değerler sonucunda; gerçek konumlar ile karşılaştırılarak alınan sonuçlar ile maliyeti düşük bir konumlandırma yaklaşımının kullanılabilirliği için olumlu sonuçlar elde edilmiştir.

**Anahtar kelimeler:** İleri Bakış Sonarı, Mesafe Tabanlı Laterasyon, Makine Öğrenimi, Sualtı Konumlandırma, Sonarda Nesne Sınıflandırma

## ABSTRACT

### UNDERWATER LOCALIZATION WITH FORWARD LOOKING IMAGING SONAR USING ARTIFICIAL OBJECTS AS REFERENCES

ESENCAN Emre

Master's Program in Information Technologies

Supervisor: Associate Professor Mehmet Berke GÜR

June 2023, 52 pages

This research focuses on the determination of the underwater position of remotely operated or autonomous underwater vehicles by simultaneously detecting and classifying artificial objects with forward-looking sonar simulation whose positions are known. As an alternative to costly and hard-to-reach underwater acoustic positioning systems, it presents an algebraic approach to determining the robot's position in a simulation environment by classifying the reflections detected in sonar using machine learning, employing distance-based multilateration, triangulation, and distance-based triangulation approaches with respect to these known objects. Additionally, in cases where sonar contact cannot be established, it accomplishes dead reckoning (DR) position estimation by combining inertial sensors on the robot. For achieving optimal accuracy in all calculations, a linear Kalman Filter is utilized to obtain the best results. The obtained values are compared with actual positions, yielding positive results in terms of the usability of a cost-effective localization approach.

**Keywords:** Forward Looking Sonar, Distance Based Lateration, Machine Learning, Underwater Localization, Object Detection on Sonar

Sualtı ve denizcilik arařtırmalarına gönül veren sualtı sevdalılarına, bu arařtırmalara ömrünü adayan ve bilimin gelişmesine katkı sunan tüm bilim insanlarına, sevgili kızım Destin Su'ya, aileme ve kendisini tez hazırlık sürecinde kaybettiğim babama ithaf ediyorum.

## TEŞEKKÜR

Yüksek Lisans eğitimim ve tez çalışmam boyunca hep yanımda bana destek olan, bu alanda gelişmeme çok önemli değerler katan, akademik ve bireysel gelişimim için sunduğu bilimsel katkı, emek ve öğretileri ile tezime büyük katkı sunan çok değerli hocam ve tez danışmanım Doç. Dr. Mehmet Berke GÜR'e, yüksek lisans eğitim süreci boyunca ilgi ve destekleri ile yanımda olan değerli hocalarım başta Doç. Dr. Yücel Batu SALMAN olmak üzere, Prof. Dr. Mehmet Alper TUNGA'ya, Doç. Dr. Yalçın ÇEKİÇ'e, Dr. Öğr. Üyesi Tamer UÇAR'a, Dr. Öğr. Üyesi Orhan GÖKÇÖL'e, ve tüm çalışma arkadaşlarıma teşekkürlerimi sunarım.

Ayrıca yaşamım boyunca beni destekleyen, sevgi ve ilgilerini hep yanımda hissettiğim, maddi ve manevi destekleri ile hep bir adım kadar yakınımda olan rahmetli babam, annem ve sevgili kardeşime, hayatımda ve kalbimde olduğu andan itibaren her konuda yanımda olan, destekleyen ve ruhuma eş olan hayat arkadaşım Dr. Öğr. Üyesi Tuğba YILMAZ ESENCAN'a ve ruhumun diğer parçası olan kızım Destin Su ESENCAN'a sonsuz teşekkür ederim.

## İÇİNDEKİLER

ETİK BEYAN.....	iii
ÖZET.....	iv
ABSTRACT.....	v
İTHAF.....	vi
TEŞEKKÜR.....	vii
İÇİNDEKİLER.....	viii
TABLolar LİSTESİ.....	x
ŞEKİL/RESİM/ŞEMA LİSTESİ.....	xi
SEMBOLLER/KISALTMALAR LİSTESİ.....	xii
Bölüm 1 Giriş.....	1
Bölüm 2 Literatür Taraması.....	5
2.1 Sualtı Navigasyon Sensörleri.....	5
2.1.1 Ataletsel Navigasyon Sistemi ve Sensörler.....	6
2.1.2 Akustik Aktarıcılar.....	8
2.1.3 Jeofizik Tabanlı Sensörler.....	9
2.2 Sualtında Nesne Tanıma ve Sınıflandırma.....	13
2.3 Sualtında Konumlandırma.....	15
Bölüm 3 Yöntem.....	17
3.1 Kullanılacak Platform ve Materyaller.....	18
3.1.1 Çok Hüzmeli İleri Bakış Sonarı.....	18
3.1.2 Sualtı Objelerinin Hazırlanması.....	19
3.2 Nesne Tanıma.....	20
3.2.1 Makine Öğrenimi.....	21
3.2.2 Nesne Tespiti.....	23
3.3 Konum Tahmin ve Tespiti.....	28
3.3.1 Tek Temas ile Konum Tahmini.....	29
3.3.2 Trilaterasyon.....	31
3.3.3 DR Konum Tespiti.....	33
3.3.4 Kalman Süzgeci.....	33
Bölüm 4 Bulgular.....	40
Bölüm 5 Tartışma ve Sonuçlar.....	48
KAYNAKLAR.....	53

EKLER.....	58
A. Sonar İşleme Python Kodları. ....	59
B Trilaterasyon Kodları.....	69
C. Sonar Hareket Paternleri Kodları .....	70



## TABLÖLAR LİSTESİ

### TABLÖLAR

Tablo 1 BlueView P900 İleri Bakış Sonarı Özellikleri (Choi ve diğeri, 2021).....	19
Tablo 2 Makine Öğrenmesi İçin Hazırlanan Veri Setine İlişkin Öğrenim ve Test Sayıları .....	21
Tablo 3 Güvenirlilik Derecesi Tespiti İçin Sınıflandırma Metrik Değeri.....	26
Tablo 4 Kullanılan Yönteme Göre Kayıtlarılandırılan Veri Miktarı.....	43



## ŞEKİL/RESİM/ŞEMA LİSTESİ

### ŞEKİLLER

Şekil 1 Sualtı Navigasyon Sınıflandırması Ana Hatları. (Paull ve diğerleri, 2014) ....	6
Şekil 2 Akustik Konumlandırma Sistemleri a) SBL, b) USBL, c) LBL (Paull ve diğerleri, 2014).....	9
Şekil 3 Sonar Çeşitleri.....	11
Şekil 4 Genel Hatlarıyla Konumlandırma Yöntem Akışı .....	18
Şekil 5 Öğrenmede Kullanılacak Sualtı Obje Modelleri.....	19
Şekil 6 Teker, Kafes ve Dikdörtgen Prizması Objelerinin Sonar Görüntüsü. ....	20
Şekil 7 Makine Öğrenmesinde Kullanılan Örnek Sonar Görüntüleri .....	21
Şekil 8 YOLOv4 Eğitim ve Test Çizelgesi.....	23
Şekil 9 Güvenirlilik Derecesi Tespiti Karşılaştırmalı Matrisleri .....	25
Şekil 10 Sınıflandırma Metrikleri. ....	27
Şekil 11 Tespit Edilen Nesnelere Kimlik ve Güvenirlilik Değeri ile Gösterilmesi..	28
Şekil 12 Çalışma Düzlemleri .....	29
Şekil 13 Mesafe Ölçümlerine Dayalı Trilaterasyon.....	31
Şekil 14 Tek Temas ile Konumlandırma Çalışma Ortamı.....	40
Şekil 15 Tek Temas Yöntemi ile Veri Toplamadaki Sonar/Robot Hareket Grafiği..	41
Şekil 16 Trilaterasyon-Multilaterasyon Çalışma Ortamı. ....	41
Şekil 17 Trilaterasyon-Multilaterasyon Yöntemi ile Veri Toplamadaki Sonar/Robot Hareket Grafiği.....	42
Şekil 18 Hata Miktarlarının Karşılaştırılması. ....	44
Şekil 19 Hatalı Sınıflandırma Örneği.....	45
Şekil 20 Hatalı Konum Hesap Örneği.....	46
Şekil 21 Kalman Süzgeci Karşılaştırmalı Kullanımı .....	47

## SEMBOLLER/KISALTMALAR LİSTESİ

FLS	İleri Bakış Sonarı (Forward Looking Sonar)
GPS	Küresel Konumlandırma Sistemi (Global Positioning System)
ROV	Uzaktan Kumandalı Araç (Remote Operating Vehicle)
AUV	Otonom Sualtı Aracı (Autonomous Underwater Vehicle)
USBL	Ultra Kısa Baz Çizgisi Konumlama Sistemi (Ultra Short Baseline Localization)
SBL	Kısa Baz Çizgisi Konumlama Sistemi (Short Baseline Acoustic Localization)
LBL	Uzun Baz Çizgisi Konumlama Sistemi (Long Baseline Acoustic Localization)
IMU	Ataletsel Ölçü Birimi (Inertial Measurement Unit)
DVL	Doppler Hız Günlüğü/Kaydedici (Doppler Velocity Log)
FOG	Fiber Optik Cayro (Fiber Optic Gyroscope)
VIO	Görsel Ataletsel Odometri (Visual Inertial Odometry)
ROS	Robot İşletim Sistemi (Robot Operating System)
DR	Parekete Seyri (Dead Reckoning)
MSS	Mekanik Taramalı Sonar (Mechanical Scanning Sonars)
SSS	Yandan Taramalı Sonar (Side Scan Sonar)
YOLO	Konvolüsyonel Nesne Tanıma Algoritması (You Only Look Once)
mPA	Ortalama Hassasiyet (mean Average Precision)
loss	Makine Öğrenimi Hata Miktarı
SLAM	Eş Zamanlı Konumlandırma ve Haritalama (Simultaneous Localization and Mapping)

INS	Ataletsel Seyir Sistemi (Inertial Navigation System)
MEMS	Mikro Elektronik Mekanik Sistemler (Microelectromechanical Systems)
VO	Görsel Odometri (Visual Odometry)
CNN	Konvolüsyonel Sinir Ağları (Convolutional Neural Network)
ToA	Sinyal Varış Zamanı (Time of Arrival)
TDoA	Sinyal Varış Zaman Farkı (Time Difference of Arrival)
AoA	Sinyal Varış/Geliş açısı (Angle of Arrival)
RSSI	Alınan Sinyali Gücü (Received Signal Strength Indicator)
UWSN	Sualtı Kablosuz Sensör Ağları (Underwater Wireless Sensor Networks)
ROS	Robot İşlerim Sistemi (Robot Operating System)
OpenCv	Açık Kaynak Görüntü İşleme Kütüphanesi (Open Source Computer Vision)
$ver_{px}$	Dikeydeki Piksel Sayısı (Vertical Pixel Count)
$hor_{px}$	Yataydaki Piksel Sayısı (Horizontal Pixel Count)
$res_{px}$	Piksel Çözünürlüğü (Pixel Resolution)
range	Sonar Menzili (Sonar Range)
alt	Altimetre Ölçüm Değeri (Altimeter Measured Value)
<b>S</b>	Sonar Görüntü Düzlemi Çerçevesi (Sonar Screen)
<b>B</b>	Sonar/Robot Düzlemi (Body)
<b>E</b>	Dünya düzlemi (Earth Plane)
<b>T</b>	Sonar Görüntü Düzlemindeki Temas (Target)

<b>P</b>	Konum (Position/Localization) (Ör: Temasin sonar görüntüsüne göre konumu ${}^S_T\mathbf{P}$ )
<b>R</b>	Rotasyon (Rotation) (Ör: Sonar Görüntüsünün Robota (Body) Göre Rotasyonu ${}^B_S\mathbf{R}$ )
$\Delta t$	Zaman Değişimi
$v$	Hız
$a$	İvme
LKF	Lineer Kalman Süzgeci (Linear Kalman Filter)
EKF	Genişletilmiş Kalman Süzgeci (Extended Kalman Filter)
UKF	Kokusuz Kalman Süzgeci (Unscented Kalman Filter)
$\hat{\mathbf{x}}$	Sistem Durum Vektörü Tahmini
<b>F</b>	Doğrusal Dinamik Sistem Modeli Durum Geçiş Matrisi
<b>Q</b>	Süreç Gürültü Matrisidir.
$z$	Ölçüm Matrisi
<b>H</b>	Gözlem Geçiş Matrisi
<b>R</b>	Ölçüm Belirsizliği Matrisi
$\rho$	Mevcut Durum Tahmininin Belirsizlik (kovaryans) Matrisi,
<b>I</b>	Birim Matris

## Bölüm 1

### Giriş

Kara parçalarına oranla daha büyük bir kısmının sularla kaplı olan Dünya’ımızda, karasal kaynakların kullanımındaki talebin her geçen gün artması ile bu durum, insanları sualtında kaynak arayışı ve sualtının araştırılmasına yönlendirmektedir. Deniz, kara, hava ve astronomi alanları ile bağlantılı olarak bilimsel alanda gelişimin koordineli ve paralel olması gerekliliği nedeniyle sualtı araştırmaları, geçmişte olduğu gibi bugün ve gelecekte de önemli bir konu olmaya devam edecektir.

Gelişen teknolojilerle birlikte elektronik bileşenlerin ve sensörlerin günümüzde küçük boyutlara indirgenmesi, metalürji alanındaki gelişmeler, düşük güç tüketen teknolojilerdeki ilerleme ve buna bağlı olarak insanlı/insansız, uzaktan kumandalı veya otonom sualtı cihazlarının teknolojik gelişimi sualtında yapılan çalışmaların artmasını sağlamıştır.

Halen günümüzde sanayi dalgıçlığı insan kaynağına ihtiyaç duyan bir meslek grubu olmasına rağmen, insanı dalış konusunda kısıtlayan anatomik etkenler göz önüne alındığında, dalış limitlerinin de ötesinde daha derin dalış gerektiren sanayi alanlarında (petrol sondaj faaliyetleri, deniz üstü rüzgar tarlaları vb.), arama ve kurtarma çalışmalarının (denizaltı kazalarına müdahale, arama süreçleri vb.) yanında bilimsel araştırmalar (oşinografi araştırmaları vb.) için de insanlı/insansız veya otonom sualtı robotlarına ve çeşitliliğine ihtiyaç her geçen gün artmaktadır.

Karmaşık ve çeşitliliği fazla olan sualtı ortamında iş yapabilme kabiliyeti öncelikle sualtında bulunan cihaz/robot konumunun tespiti konusunda büyük zorluklar içermektedir. Küresel konumlandırma sistemi (GPS-Global Positioning System) elektromanyetik sinyalleri sualtında uzak mesafelere yayılamazlar. Sualtında akustik sinyaller, elektromanyetik sinyallere göre çok daha uzak mesafelere yayılması sebebiyle tercih edilen iletişim tipidir. Genel olarak konum tespiti kullanılan akustik sensörler ile yüzeydeki GPS konum bilgilerinin denkleştirilmesine dayalıdır.

Denizaltı gemileri sualtında uzun süre GPS sinyallerine ihtiyaç duymadan seyir gerçekleştirebilmektedir. Bu tarz bir parakete seyri basit olarak rota, sürat, zaman değerleri kullanılarak icra edilir. Hareket dinamiği iyi derecede modellenmiş ve yüksek maliyetli jiroskop, doppler hız günlüğü/kaydedicisi (DVL- Doppler Velocity Log), aktif ve pasif sonarlar gibi sensörlere sahip denizaltı gemileri dahi zamana bağlı olarak sualtı şartlarında oluşan ve tespit edilemeyen birçok faktöre bağlı olarak konumlarında hata üretirler. Bunun sonucunda bir denizaltı gemisinin dahi konumuna düzeltme uygulamak için ya su yüzeyine (anten derinliği veya periskop umku) çıkma, yada stratejik açıdan tespit edilme pahasına aktif sonarlarını kullanarak zengin veri veren batimetrik haritalar ile nerede olduğunu tespit etmeye ihtiyacı vardır. (Andrews, 1970)

Teknolojik gelişmelerin paralelinde hassas, hata payı düşük olan sensörler imal edilmesine rağmen hem karada hem sualtında sensörlerin minimumda hatalı sonuçlar üretmesi olasıdır. Zamana ve harekete bağlı olarak hata değerleri de artış gösterecektir. Bu sebeple genel olarak bir cihaz için bir sensör bilgisinden öte çoklu sensörlerin kullanılması, her bir sensör hatasını, diğer sensör verileri ile doğrulama veya iyileştirme imkanını ortaya koyar. Sualtında temel olarak parakete seyri (DR- Dead Reckoning) ile giden bir robot için pusuladan alınan yön değeri, sürati ve aynı rotada belirli bir süre hareketine bağlı olarak başlangıç konumundan hangi noktaya geldiği hesaplanabilir. Son konumu doğal olarak ivmelenme, olası akıntı kuvvetleri ile rotasından belli bir miktar sapma, akıntının geldiği yöne göre sürat düşüklüğü gibi birçok hesaplanamayan sebeplerle hata miktarları ortaya çıkacaktır. Hareket süresinin artması ile de hata miktarlarında kümülatif artış meydana gelecektir. Robot üzerinde kullanılacak bir ataletsel ölçü birimi (IMU- Inertial Measurement Unit) ile ataletsel davranışlardaki sapmalar ve hata miktarları düşürülebilecektir. Eklenecek bir DVL sensörü ile de sürat üzerindeki hata miktarları da minimize edilecektir ki her zaman minimumda hata miktarı var olacaktır. Bu noktada önemli olan sualtında çalışması planlanan cihaz/robot konumun hesaplanmasında ne kadar hatanın kabul edilebileceği riskidir.

Buzullar altında uzun süreler GPS konumlandırmasından yoksun seyir yapan milyonlarca dolarlık maliyetteki denizaltı gemisinin sualtı konumunda hata yapması riski minimumda olmasına karşın sualtı araştırma ve çalışma grupları için bu riskler

daha yüksek olabilir. Genel olarak hedeflenen düşük maliyet ve kabul edilebilen hata seviyeleridir.

Robot üzerinde sualtı konumlandırma ve navigasyonu için veri sağlayan çeşitli sensörler bulunmaktadır. IMU, DVL, optik kameralar, lazer mesafe ölçüm, ısı, basınç, akustik sensörler bunlardan bazılarıdır. Sensörlerin hassasiyetlerine ve hata miktarları ile yapım tekniklerine bağlı olarak maliyetleri de değişkenlik göstermektedir.

Uzaktan kumandalı sualtı aracı (ROV-Remote Operating Vehicle), otonom sualtı aracı (AUV-Autonomous Underwater Vehicle) ve benzeri sualtı cihaz/robotları için konumlandırma askeri, ticari alanlarda genel olarak akustik aktarıcılar (USBL-Ultra Short Baseline Localization, SBL-Short Baseline Localization, LBL-Long Baseline Localization) ile yapılmaktadır (Paull, Saeedi, Seto ve Li, 2014).

Bu yöntemler kısa mesafelerden uzak mesafelere, sığ sulardan derin sulara, birçok farklı su şartlarında kullanılmaktadır. Kullanılan yöntemler farklılık gösterse de yöntemlerin genelinde akustik aktarıcılar yüksek maliyetler ortaya çıkarmaktadır.

Akustik aktarıcılar ile konumlandırmanın yanında son zamanlarda yapılan araştırma çalışmalarında, anlık fazla veri sağlayan optik sensör, mekanik taramalı (MSS-Mechanical Scanning Sonar) ve ileri bakış sonar (FLS-Forward Looking Sonar) sistem yaklaşımlarının tercih edilmesi artmaktadır.

Optik sensörler (kamera) ile karasal ortamlarda obje tanıma, sınıflandırma ve kapalı ortamlarda konumlandırma konusunda yapılan çalışmalar her geçen gün artmakta, ümit verici yeni yaklaşımlar ortaya çıkmaktadır. Optik sensörler ile genel olarak karada, sabit ışık kaynağında yüksek veri içeren bilgiler ile yaklaşımlarda etkin çözümler üretilebilmektedir. Ancak sabit ışık kaynağı olmayan, görüntüde su yoğunluğuna bağlı olarak ancak birkaç metre ötesi görülebilen, dipten kalkan tortu ile görüşün kısıtlanması, yapay ışık kaynağından çıkan ışınların sualtı planktonlarında parlama yapması ve buna benzer olumsuzluklar sebebiyle optik sensörlerin sualtında kullanılması kısıtlı düzeyde gerçekleşmektedir. (Ferreira, Djapic, Micheli ve Caccia, 2015)

Sualtı robotları özelinde yapılmış, yapılmaya devam eden ve yapılacak çalışmalarda konumlandırmada minimum hata ve düşük maliyet vazgeçilmez bir kriter olmasından dolayı ileri bakış sonarı gerçek zamanlı veri almak için kullanılabilen alternatif sensörlerdendir.

Bu çalışmada; sualtında bulunan bir aracın konumunun, ulaşılması zor ve maliyetleri yüksek akustik konumlandırma (USBL, LBL, SBL) sistemlerine ihtiyaç duymadan tespit edilebilmesi amacıyla, ileri bakış sonarı tabanlı konumlandırma yaklaşımı sunulmaktadır.

Çalışılan sualtı ortamı simülasyonunda; ileri bakış sonarında temas olarak yansıma veren, konumu önceden belirlenerek çalışma ortamına yerleştirmiş yapay nesnelerin, nesne tanıma algoritmaları (YOLO-YouOnlyLookOnce) ile tespit, sınıflandırılma, gerçek zamanlı takibi amaçlanmıştır. Gerçekleşen sınıflandırmaya bağlı olarak; karasal ortamda kullanılan GPS veya GSM şebekelerinin baz istasyonlarına olan mesafesine dayalı nirengi/üçgenleme (triangulation) ve trilaterasyon (trilateration) yöntemlerine benzer şekilde, sualtı aracının konum tespiti yapılmaya çalışılmıştır. Hesaplanan konumun yanında, ataletsel sensörlerin füzyonu ile de tünelde GPS sinyallerini kaybeden bir kara aracına benzer şekilde, sonarda temas tespit edilememesi veya sınıflandırılmaması durumunda dahi, süratine ve yönelimine bağlı olarak sualtı cihazının DR ilerlemesiyle konum tahminini yaparak akustik konumlandırma sistemlerine bağımlılığın azaltılması ve düşük maliyetle etkin konumlandırma amaçlanmıştır.

## Bölüm 2

### Literatür Taraması

Sualtında kullanılan insanlı/insansız robotlar, bilimsel araştırmalar, kurtarma operasyonları, arama, tespit, teşhis, derinliğe bağlı olarak dalgıç marifetiyle yapılamayacak sualtı işlerinin yapılması, sualtı yapılarının inşası ve askeri alanlar başta olmak üzere birçok alanda kullanılmaktadır. (Aulinas ve diğerleri, 2011; Carrasco, Bonin-Font ve Codina, 2016).

Karmaşıklığı ve çeşitliliği fazla olan sualtı ortamında; yüksek frekanslı sinyallerin hızlı zayıflaması ve denizaltı ortamının yapılandırılmamış doğası nedeniyle karasal robotlarda kullanılan teknik ve yöntemlerin doğrudan kullanılması ile iyi sonuçlar elde edilmesi oldukça zordur. Suyun üzerinde otonom sistemlerin konumlandırılması ve navigasyonu genel olarak radyo iletişimine ve küresel konumlandırmaya dayanır. Bununla birlikte, su altında, bu tür sinyaller yalnızca kısa mesafelerde yayılır ve akustik tabanlı sensörler iletişimde daha iyi performans gösterir (Chatpadol ve Itthisek, 2017). Sualtındaki uygulamalarda insanlı/insansız sualtı araçlarının performansları büyük ölçüde hareket tahmin yeteneğine bağlıdır. Bu bağlamda kullanılan sensör ve cihazlar ile sağlanan hareket tahmin yeteneğinin, konumlandırma ve navigasyon sistemlerine etkisi oldukça önemlidir. Son yıllarda çeşitli sensörlerden yararlanılarak sualtı otonom araç ve cihazları için çeşitli navigasyon ve konum belirleme teknikleri geliştirilmiştir. Paull ve diğerleri (2014), otonom cihazların navigasyonu ile ilgili derinlemesine yaptığı çalışmada otonom sualtı cihazla üzerinde kullanılan sensör, çalışma prensipleri ile eş zamanlı konumlandırma ve haritalama (SLAM-Simultaneous Localization and Mapping) yöntemlerini genel hatlarıyla açıklamakta, ayrıca otonom sualtı cihazları için navigasyon ve konumlandırma tekniklerini Şekil 1'e göre kategorize edebileceğini belirtmişlerdir.

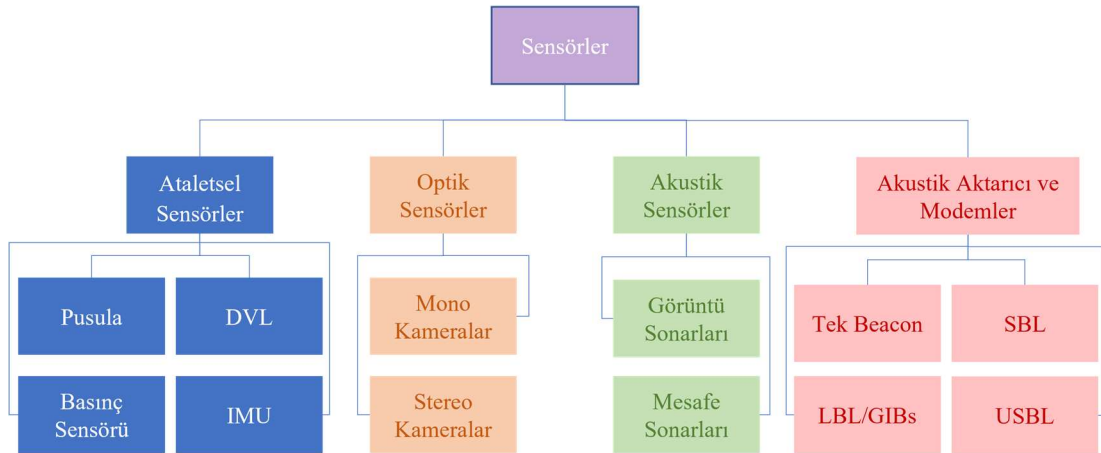
#### 2.1 Sualtı Navigasyon Sensörleri

Otonom sualtı araçları, sensör teknolojileri geliştikçe ve maliyetleri azaldıkça araştırma, askeri ve ticari endüstri başta olmak üzere birçok alanda kullanılmaktadır. Otonom navigasyon, AUV'lerin temel bir işlevi olarak kabul edilmekle birlikte,

sudaki elektromanyetik dalgaların yayılma problemi ve yapılandırılmamış sualtı ortamları nedeniyle zorlu bir konudur. AUV'lerde navigasyon, atalet sensörleri, akustik aktarıcılar ve jeofizik (optik, akustik, manyetik) sensör verilerinin belirli algoritmalar dahilinde ferdi veya birlikte kullanılması ile gerçekleştirilir (L. Zhang, Liu ve Zhang, 2020).

Sualtı robotlarına yönelik artan taleple birlikte, sualtı robotları üzerine yapılan çalışmalarda, konumlandırma ve navigasyon işlevlerini tamamlamak için tek bir sensör bilgisinin görev gereksinimlerini yeteri kadar karşılamadığı, bu performans boşluğunun farklı çeşitteki sensör bilgilerinin birleşimi ile yapılabileceği öngörülmüştür. Çoklu sensör bilgisinin kullanımı ile cihazların konum ve hız tahminlerinin doğruluğu iyileştirebilir ve optimum navigasyon sağlanabilmektedir. (P. M. Lee ve diğerleri, 2007).

Otonom Sualtı Aracı Navigasyonu



Şekil 1. Sualtı navigasyon sınıflandırması ana hatları. (Paull ve diğerleri, 2014)

**2.1.1 Ataletsel navigasyon sistemi ve sensörler.** Önceden belirlenmiş bir konum veya sabit kullanılarak nesnenin mevcut konumunun hesaplanması sonrasında konumun bir atalet veya hızına bağlı olarak belirli bir süre içinde gittiği istikamete göre konumunun tahmin edilmesine ölü hesaplama, ölü iz (Dead Reckoning) veya denizcilikte parakete seyri denir. Ataletsel navigasyon sistemi, (INS-Inertial Navigation System) nesne konumunun ve oryantasyonunun DR olarak

sürekli ivme ölçerden, pusula/jiroskoptan, hız ölçerden, basınç, yükseklik vb. cihaz ve sensörlerden desteklenmesidir (Sahoo, Dwivedy ve Robi, 2019).

Konumlandırma doğruluğu sensörlerin ölçüm hassasiyeti ile doğrudan ilgilidir. Sensörlerdeki yapısal ve ölçüm hata miktarları, DR ilerlemede zamana bağlı olarak birikerek artacak, sualtı şartlarına bağlı olarak ölçümü yapılamayan akıntı, yoğunluk vb. koşullar da ayrıca hata artışına sebep olacaktır. Tahmini konumdaki hatayı en aza indirmek için birçok sensör verisi birlikte kullanılmalıdır (Sahoo ve diğerleri, 2019).

AUV navigasyonu ile ilgili Paull ve diğerleri (2014), yaptığı incelemede ataletsel, akustik aktarıcılar/modemler ve jeofizik verilerine dayalı navigasyon olarak incelediği üç kategoride kullanılan yöntemlerin kesintili tahmine dayalı zayıf sonuçlar verdiğini, konumlandırma ve navigasyon doğruluğunun iyileştirilmesi için diğer sensörlerle (DVL, IMU vb.) birlikte yerleşik olarak kullanılmasını gerektiğini savunmuştur.

*DVL (Doppler Velocity Logger)*: Hareket ederken sualtı tabanına gönderilen sabit frekanslı ultrasonik sinyal dalgaları ile sualtı tabanından yansıtılarak alınan sinyal dalgaları arasındaki oluşan sinyal frekansı farkı doppler kayması olarak adlandırılır. (Bergert, 1957). DVL cihazı ile doppler frekans kayması ölçülerek robotun yere göre bağıl radyal hızı elde edilir. DVL sualtı robotlarının gelişim sürecinde, yüksek konum hassasiyeti gereksinimi gereken robot sistemlerinde kullanılmış olmasına rağmen maliyet sorununa bağlı olarak çoğunlukla eylemsiz navigasyon sensörlerine bağlı teknolojiler kullanılmıştır. DVL, ataletsel navigasyon sisteminde hata birikimini bastırmak ve en aza indirmek için yüksek hassasiyette hızlı bilgi sağlar. Ticari DVL'ler oldukça pahalı cihazlardır. Küçük araştırma ve proje ekipleri tarafından erişilebilir değildir (Dylan ve Timothy, 2012). INS ve DVL kombinasyonu günümüzde teknolojilerin gelişmesi ile performans gereksinimlerine ve maliyet etkinliğine bağlı olarak sualtı konumlandırma, navigasyon teknolojilerinde kullanılmakta olmalarına rağmen günümüzde dahi ulaşılmaları zordur (Wu ve diğerleri, 2019).

*IMU (Inersial Measurement Unit)*: Atalet ölçüm birimleri genel olarak içinde birkaç ölçüm ünitelerinden oluşmaktadır. İvme ölçer, jiroskop, manyetometre vb. ölçüm birilerini tasarımına bağlı olarak bünyesinde bulundurlar. Genel olarak

IMU, monte edildiği herhangi bir platformun 3 boyutlu hareketini yakalamak için üç karşılıklı ortogonal eksen boyunca monte edilmiş 3 eksenli bir ivmeölçer ve yine 3 eksenli bir jiroskoptan oluşur. İvme ölçerler yerçekimi ivmesini statik, hızlanma, yavaşlama ve durma sonucunda oluşan ivmeleri dinamik olarak ölçerler. Genelde ivme ölçerler  $m/s^2$  veya yerçekimi kuvveti (g) türünden ifade edilirler (El-Sheimy ve Youssef, 2020).

Jiroskoplar; sürtünmesi azaltılmış ve belirli bir süratle dönmesi sağlanan rotorun, dönme yönüne dik eksenler üzerine yalpa çemberleri ile donatılmış, açısız momentumun korunumu yasası üzerine kurgulanmış yapılardır. Bu yasaya göre dönen bir cisim, dönme yönünü ve eksenini koruma eğilimindedir. Bu nedenle eksenindeki oluşturulmaya çalışılan herhangi bir değişiklik, açısız momentumda bir değişiklik ile sonuçlanacaktır.


Kullanım alanlarına göre birçok jiroskop çeşidi bulunmasına karşın genel olarak araştırma gruplarında mikro elektro mekanik jiroskoplar (MEMS-Mikro Elektronik Mekanik Sistemler) tercih edilmektedir. Uçak, gemi, denizaltılar, uzay araçları, dron, helikopter vb. araç ve sistemlerde maliyetleri yüksek ve hassas mekanik, fiber optik jiroskoplar kullanılmaktadır. Jiroskopta yunuslama, yalpalama ve yönelim değerleri genel olarak radyan/s cinsinden ölçümlerler (L. Wang ve diğerleri, 2019).

**2.1.2 Akustik aktarıcılar.** Akustik sinyaller ile sualtında konumlandırma, genel kullanımlı önemli bir tekniktir. Elektromanyetik sinyal dalgalarının aksine sualtında akustik sinyaller daha uzağa yayılabilirler. Klasik karasal robotlarda kullanılan küresel konumlandırma sistemlerine alternatif olarak sualtında LBL, SBL veya USBL akustik konumlandırma sistemleri kullanılabilir. Bu sistemlerin donanım konfigürasyonları pahalı olmakla birlikte elde edilmesi, kullanımda bir platforma ihtiyaç duyması, LBL sistemlerinin sualtına konuşlandırılması ve batarya değişimi gibi işlemler sebebiyle ekstra zorluklar içermektedir. (Y. Wang, Ma, Wang ve Wang, 2020)

USBL ve SBL sistemler bir su üstü platformuna (tekne, bot vb.) monte edilmiş bir dizi akustik alıcı verici (transdüser) ile sualtı robotuna yerleştirilmiş bir akustik cevaplayıcı (transponder) ilişkilendirir. Akustik alıcı verici dizisi ile gövde

arasındaki boşluk dönüşüm matrisini sağlayarak, sinyalin yolculuk süresi ve faz farkı ile göreceli pozunu tahmin edilebilir. USBL ve SBL arasındaki en büyük fark, akustik alıcı-vericiler arasındaki boşluk mesafeleridir. USBL için, akustik alıcı-vericiler arasındaki mesafe bir metreden azdır. SBL sistemi genellikle 20-50 m mesafeli üçten fazla akustik alıcı-verici içerir. Platform uzunluğuna bağlı olarak akustik alıcı-vericiler arasındaki mesafe artırılarak, ölçüm doğruluğu geliştirilebilir. Bununla birlikte, bu sensörlerin ana dezavantajı, kalibre edilmelerinin zor olmasıdır. (Kebkal ve Mashoshin, 2017)

LBL, bilinen bir göreceli konumla deniz tabanına yerleştirilmiş bir dizi akustik cevaplayıcı (transponder) kullanır. Temel uzunluğu 100 metre ile 20 km olan en az üç akustik istasyon ile, akustik sinyallerin kapsama alanı içindeki robotların konumları tahmin edilebilir. LBL sensörü yüksek ölçüm doğruluğu elde edebilir ve su derinliğinden etkilenmez, ancak bir sualtı akustik ağının düzenli olarak dağıtılması/yerleştirilmesi ve geri kazanılması/toplanması gerektiğinden sistemin kurulması ve bakımı yüksek maliyetlidir (Cong, Gu, Zhang ve Gao, 2021). USBL, SBL ve LBL çalışma prensibi Şekil 2’de gösterilmiştir.



Şekil 2. Akustik konumlandırma sistemleri a) SBL, b) USBL, c) LBL (Paull ve diğerleri, 2014)

**2.1.3 Jeofizik tabanlı sensörler.** Optik ve sonar olarak iki ana kategoride incelenebilir (Paull ve diğerleri, 2014). SLAM ve navigasyon için dış ortam çevresel özellikleri kullanılır.

*Optik sensörler:* Görsel odometri (VO) tabanlı bir strateji, hareket tahmini için bir araca sabit bir şekilde konumlandırılmış bir veya daha fazla kamera kullanılarak

yapılan bir navigasyon tekniğidir. Kısaca, görsel odometri algoritması, kameralar tarafından çekilen görüntüler üzerinde indüklenen hareketi analiz ederek tahmini araç konumunu günceller. Görsel odometri stratejileri yalnızca belirli koşullar doğrulanırsa performanslı çalışabilir. Sualtında görsel odometri; alınan görüntü üzerinde yeterli sayıda özellik tespiti, bulanıklık içermeyen berrak görüntü ve dalgalı yüzey ışık yansımalarının az olması ile eşit şekilde aydınlatılmış bir sahneye ihtiyaç duyar. Bu sınırlamalara rağmen, optik kameraların azalan maliyeti nedeniyle görsel odometri, mobil robotikte en aktif araştırma konularından biri haline gelmiştir. Bu değerlendirmelerin ardından, ilk görsel odometri uygulamaları, konumlandırma için küresel navigasyon uydu sistemlerinin kullanılmadığı kapalı ortamlarda mobil robotların otonom navigasyonu ile ilgiliydi. Görsel odometri alanında yapılan araştırmalar neticesinde algoritmalarının uygulanabilirliği deniz ve hava araçlarında kullanılmak üzere genişletilmeye çalışılmaktadır. (Bucci, Zacchini, Franchi, Ridolfi ve Allotta, 2022).


Günümüzde karasal robotlarda sıklıkla kullanılan, görüş tabanlı (VO) hareket tahmini, kamera sensör fiyatlarının ulaşılabilir olması sebebiyle yoğun olarak kullanılmakta ve konum tespiti yaklaşımları son derece umut vericidir. LBL veya USBL gibi sistemleri ile karşılaştırıldığında, kamera görüntüleri sualtındaki şartlar uygun olması, bulanıklık giderme, düşük görüş şartlarında çalışabilme, derin ve karanlık sularda öznitelik tespit edebilecek filtre algoritmalarının gelişmesi durumunda daha bol bilgi sağlayabilir (Bucci ve diğerleri, 2022; D. Yang, Ai, Liu ve He, 2022). Bu da gelecekte görsel odometrinin sualtında daha da yaygın olarak kullanılabilmesi fikrini desteklemektedir. Fakat, halen günümüzde sualtı şartlarının doğası gereği kameradan alınan bilgiler kısa mesafe içinde gerçekleşmekte, havuz gibi ışık ve görüşün iyi durumda olduğu platformlarda güzel sonuçlar elde edilebilmesine karşın, kamera sensörleri ile uzak mesafelerde görüşün bozulması nedeniyle, akustik sistemler kadar iyi sonuçlar elde edilememektedir (B. Zhang, Ji, Liu, Zhu ve Xu, 2023).

Görmeye dayalı hareket tahmini zorlaştıran durumlarından biri de üç boyutlu ortamın kamera görüntüsünde iki boyutlu olarak gösterilebilmesine ve projeksiyon sürecinde derinlik bilgisi kaybolduğu için nesnenin/sahnenin yalnızca iki boyutlu projeksiyonu ile hareket çıkarılamazken, iki görünüm geometrisi teorilerine göre,

kamera oryantasyonu ve hareket yönü ile ölçeklenmiş üç boyutlu nesne ve derinlik bilgisi, en az iki perspektiften hesaplanabilir (D. Yang ve diğerleri, 2022).


*Akustik sensörler:* Ses dalgaları suda çok etkili bir şekilde hareket eder bu nedenle, sualtı robotik uygulamalarında yayılan ve yansıyan ses dalgalarına dayanan sonar sistemleri çok yaygın olarak kullanılmaktadır. Sonar kelimesi *Sound Navigation And Range*'in kısaltmasıdır. Ses dalgalarının sualtında yayılması, ulaştığı bir noktadan yansyarak geri dönüşünün süresine bağlı olarak mesafe ölçümü prensibine bağlı çalışan cihazlardır. Kullanıldığı alanlara ve tiplerine göre çalışma prensipleri aynı, teknikleri farklılık göstermesi ile çeşitlenmişlerdir. Sonar çeşitlerine ait çalışma görselleri Şekil 3'de gösterilmiştir.

Kullanıldığı alanlara ve ihtiyaca göre çeşitli görüntüleme sonarları bulunmaktadır. İleri bakış sonarı (FLS), mekanik taramalı sonar (MSS), yandan taramalı sonar (SSS-Side Scan Sonar), çok hüzmeli sonar (multi beam sonar), tek hüzmeli sonar (single beam sonar) vb. bunlardan bazılarıdır.



a) Yandan Taramalı Sonar (SSS)

b) Mekanik Tarama Sonarı (MSS)



c) İleri Bakış Sonarı (FLS)

Şekil 3. Sonar çeşitleri

*Yandan taramalı sonar;* genellikle kullanım alanı sualtında kaybolan bir cismin aranması ve konumunun tespit edilmesi, askeri alanlarda mayın tespiti amaçlı da kullanılmaktadır. Otonom veya su üstündeki platform vasıtası ile dipten çekilmek suretiyle kullanılırlar. Dipten belirli bir yükseklikten hareket eden yandan taramalı sonar, sancak (sağ tarafı) ve iskelesinde (sol tarafı) bulunan akustik vericiden

gönderilen ses dalgalarının sualtında bir nesneye çarparak geri yansıyan bu ses dalgalarının algılanması prensibine bağlı çalışırlar. Yüzölçümü büyük alanlarda kullanıma daha uygundur. Kullanım alanına, çalışma derinliğine göre çeşitliliği olmakla beraber, menzilleri sancak ve iskele olmak üzere her iki tarafta frekansına bağlı olarak 25-600m'dir.

*Mekanik taramalı sonar;* belirli bir frekansta ses sinyalleri göndererek sinyallerin sualtındaki bir objeden yansıyarak algılanması ile konum ve büyüklük tespitinde kullanılırlar. Basit olarak sonar vericisi, bir motor tarafından döndürülürken transmisyona devam eder, yansıyan sinyallerin çeşitli açılardan toplanmasını sağlar. Motor dönüş hızı, vericinin ürettiği ses sinyalleri frekansına bağlıdır. Bu sayede, yansıyan sinyallerin farklı açılarda algılanması, sualtındaki nesnelerin konumunu ve boyutunu daha doğru bir şekilde belirlemeye yardımcı olur. Genellikle mekanik taramalı sonarlar tek bir hüzmeye çalışırlar. Bu hüzmelerin bir temastan yansımından sonra tekrar aynı temasa gönderilebilmesi için taramanın dönerek aynı noktaya gelmesi için süreye ihtiyacı vardır. Eş zamanlı navigasyon uygulamalarında veri toplanması için bu tarz bir sonarda sabit durulması veya beklenmesi gerekmektedir. Şekil 3b'de mekanik taramalı sonar çalışma görüntüleri sunulmuştur. Mekanik taramalı ve ileri bakış görüntüleme sonarları araştırma grupları tarafından sıklıkla tercih edilen bir teknoloji olmasının yanında, gelişen teknolojilere bağlı olarak, maliyetleri ulaşılabilir düzeylere inen ve anlık olarak çok daha fazla veri sağlayan ileri bakış görüntüleme sonarlarına göre mekanik taramalı sonarlar daha az tercih edilen bir teknoloji durumuna düşmüştür.

*İleri bakış görüntüleme sonarları;* günümüzde araştırma grupları, endüstri, ticari ve askeri alanlarda teknolojik gelişmelere bağlı avantajlarından dolayı daha fazla tercih edilmektedir. Taramalı sonarlara göre avantajı çok hüzmeli olmasıdır. Frekansına ve hüzmeye sayısına bağlı olarak sualtı nesnelere ait daha yüksek çözünürlükte veri elde edebilmektedir. Genel olarak belirli bir sektörde görüntüleme almakta, bakmadığı yönler kör olarak değerlendirilmektedir. Çalışma sektörüne bağlı olarak 3, 4 adet ileri bakış görüntüleme sonarı kullanılarak kör sektörler yok edilebilir, 360 derece görüntü sağlanabilir.

*Mesafe sonarları;* tek bir sinyal ve bir nesneye çarparak yansımaları ile dönüşündeki zamana bağlı mesafe ölçümü veren sonarlardır. Genellikle basit olarak yüzeyden (iskandil) veya bulunulan derinlikten tabana olan mesafeyi (altimetre) bulmak için kullanılan basit yapıdaki sonarlardır. Tekne altındaki derinliği ölçmeye yarayan akustik iskandiller bunlara örnektir.

## **2.2 Sualtında Nesne Tanıma ve Sınıflandırma.**

Su altının doğal ve birbirine benzeyen dip yapısı, suda yaşayan mikro organizmaların yüksek yoğunluğu, suyun bulanık olması ve su yüzeyi ışıklarının dalgalara bağlı düzensiz yansımaları (sığ sularda) gibi faktörler optik görüntüleme sistemlerinin seçicilik özelliğinde azalma meydana getirir. Seçicilik ve görüntü kayıplarını en aza indirmek için filtreler kullanılabilir olmasına karşın görüntünün netleştirilmesi veya keskinleştirilmesi kaynak görüntüye bağlı olarak belirli bir seviyeye kadar yapılabilmektedir (Bucci ve diğerleri, 2022). Optik görüntülerdeki bu tarz sınırlamalar, görüşün ötesindeki nesnelerin algılanması ve tanımlanmasını olanaksız hale getirirler. Görüntüleme sonarlarının suyun bulanıklığından ve görüş ile ilgili sınırlamalardan bağımsız olarak, daha uzun mesafelerden nesne tespiti konusunda güvenilir sonuçlar sağlarlar (Fuchs, Gällström ve Folkesson, 2018). Sonarlar algısal mesafeyi görüş açısını genişletse de ortaya çıkan görüntüler farklı bir projeksiyon modelinde oluşur, bu da daha az sezgisel ve düşük çözünürlüklü görüntülerin elde edilmesi anlamına gelir ki operatörler tarafından kolayca tanımlanamayabilirler. Bunlara ek olarak akustik sensörlerin fiziksel özelliklerinden dolayı sualtı görüntüsünde önemli düzeyde gürültü oluşur. Bu gürültüler de sonar verileri ile görüntüdeki nesnenin analizi ve tanımlamasındaki güvenilirliğini azaltır (S. Lee, Park ve Kim, 2018).

Görüntü sonarları düşük veya sıfır görüş koşullarında dahi su altı ortamlarının görüntülenmesini sağlayabilirler. Sonarlarda bu görüş kısıtlarını ortadan kaldıran yeteneğin, sualtı insan yapımı nesnelerin tespiti için yararlı ve kullanılabilir olduğu yapılan çalışmalarda kanıtlanmıştır (Y. Lee, Choi, Ko ve Choi, 2017; Y. Lee, Kim ve Choi, 2014). Denizcilik teknolojisindeki yapılan araştırma ve gelişmelerin artmasına bağlı olarak, otonom sualtı aracındaki (AUV) sonar ile toplanan veriler, insan müdahalesi olmaksızın bir görevi yerine getirmek için kullanılabilir. İnsan

yapımı nesnelere üzerinde algılama ve anlık müdahale, işlemci yönünden maliyetli görevlerdir. Bu nedenle, toplanan verilere eş zamanlı veya kısa sürede tepki verebilmesi bir öncelik olup, görevin gerçekleştirilebilmesi için gerçek zamanlı olarak nesnelere üzerinde algılama ve sınıflandırma yapabilen algoritmalara ihtiyaç duyulmaktadır (Galceran, Djapic, Carreras ve Williams, 2012).

Sualtı ortamındaki doğal nesnelere sabit olmayan ve karmaşık şekilleri vardır, görüntüleme açısı, sonarın yüksekliği, eğimi gibi etkenlerde onları tanımayı zorlaştırır. Ayrıca, aynı bölgedeki sonar gürültüsü ve kararsız yoğunluk gibi nedenlerle akustik görüntünün özellikleri çok kararsızdır. Y. Lee vd. (2014), yaptıkları çalışmada, görüntüleme sonarının özelliklerini dikkate alan yapay bir yer işareti geliştirdiler. Tasarlanan yapay işaret, önerdikleri nesne tanıma algoritmasını doğrulamak için kullanıldı ve farklı yapay işaretleri sınıflandırmayı gerçekleştirdiler.

Derin öğrenme su üstü görsel algılama alanında devrim yaratan konvolüsyonel sinir ağlarına (CNN-Convolutional Neural Network) paralel olarak, bu tür yöntemlerin sualtı optik ve akustik algılama için de uygulanması için yoğun çabalar sarf edilmektedir. Denizcilik alanında bu tür yöntemleri uygulamak için önemli bir zorluk, tespit edilecek nesne özelinde veri toplanması ve makine öğrenimi için veri setlerinin oluşturulmasıdır.

Karimanzira, Renkewitz, Shea ve Albiez (2020), çalışmalarında iki farklı ileri bakış görüntüleme sonarı ile sualtı veri setleri oluşturarak eğitim modeli sağlamışlar, sualtında nesne tespitinde CNN kullanarak boru yapılarını ve sualtı istasyonlarının tespiti için kullanmışlardır. Eğitimde kullanılan veri setinde ilk olarak 200 görüntüden 137'si doğru olarak sınıflandırılmış, veri artırımı yöntemleri (döndürme, büyütme veya küçültme vb.) kullanılarak testlerdeki değer 187 doğru tanımlama gerçekleştirerek yaklaşık %95 oranında doğru tahminleme yapılmıştır. Veri artırma teknikleri ile %26 oranında doğruluk oranı artmıştır. Görüntü işlemenin hesap maliyetinin yüksek olması sebebiyle hesaplamada GPU kullanmışlar, buna rağmen kullandıkları donanımla yaklaşık 1.2sn'lik görüntü gecikmesi yaşadıklarını belirtmişlerdir.

Christensen, Mogensen, Galeazzi ve Andersen, (2018), balık ve balık türlerinin optik görüntüleri ile tanımlama ve sınıflandırma yapmak için nesne algılama modeli

eğitmişlerdir. Fuchs vd. (2018); Valdenegro-Toro Matias, (2017) algılama modellerini, ileri bakış sonarları ile alınan görüntülerde nesnenin tespiti ve sınıflandırması için öğretmişlerdir. Benzer şekilde, Horimoto Hiroumi, Kofuji Kazuya, Maki Toshihiro ve Kofuji Kazuya, (2018), yaptığı çalışmada, sonar görüntülerinde deniz kaplumbağalarının tespiti üzerine algılama modelini Darknet framework'ü üzerinde YoloV2 kullanarak eğitmişler, olumlu sonuçlar elde etmişlerdir.

CNN algoritmaları kullanılarak yapılan çalışmaların geneline bakıldığında, optik sensörlere göre daha düşük çözünürlükte veri sağlayan sualtı görüntüleme sonarlarında tespit edilen yansımaların sınıflandırılmasında CNN'lerin kullanılması ve buna bağlı olarak sualtı konumlandırma sistemlerinde alternatif yaklaşımların ortaya çıkması konusu ümit vericidir.

### **2.3 Sualtıda Konumlandırma**

Sualtıda uzaktan kumandalı veya otonom birçok cihaz, yer aldığı operasyonlarda konumlandırmaya ihtiyaç duyarlar. Kesin konum bilgisi olmadan toplanan verilerin sualtı uygulamalarında yetersiz veya yanlış olacağı aşikardır. Sualtının doğal zorlu yapısından kaynaklı konum belirleme yöntemleri karadaki konumlandırma sistemlerine göre farklı zorluklar içerir. Karasal uygulamalarda küresel konumlandırma sistemlerini kullanmak en yaygın yöntemdir. Yine karasal ortamda, küresel konumlandırma sistemlerinin kullanılmadığı kapalı veya iç alanlarda wifi, bluetooth, vb. radyo sinyallerinin kaynak ve hedef arasındaki varış zamanı (ToA-Time Of Arrival), varış zamanı farkı (TDoA-Time Difference of Arrival), varış/geliş açısı (AoA-Angle of Arrival), alınan sinyalin gücü (RSSI-Received Signal Strength Indicator) dahil olmak üzere değişken teknikler kullanılarak mesafe veya açı tahminleri elde edilerek bu verilerin belli algoritmalar ile kullanımıyla konum bilgileri hesaplanabilmektedir (Pande ve Ibwe, 2021).

Sualtı kablosuz sensör ağları (UWSN, Underwater Wireless Sensor Networks) ile sualtında konum bilgisi de karadaki kapalı veya iç alanlardaki konumlandırma sistemlerine benzer şekilde elde edilebilir. Konum doğruluğu sualtı ortamının birçok faktöründen büyük ölçüde etkilenir (Chatpadol ve Itthisek, 2017). İyi bilinen ve

yaygınca kullanılan konumlandırma tekniđi, nirengi/üçgenleme (triangulation) ve laterasyondur (lateration). Nirengi, üçgenlerin geometrik ilkelerini kullanırken, laterasyon konum tespit etmek için mesafe tabanlı kesişen çemberleri kullanır. Laterasyon, küresel konumlandırma sistemi tarafından da yaygın olarak kullanılan bir tekniktir (Erol-Kantarci, Mouftah ve Oktug, 2011). Trilaterasyon tekniklerini kullanmak için en az üç referans düğümü gereklidir. Geleneksel trilaterasyon yöntemindeki varsayım, üç veya daha fazla çemberin kesişmesidir (Pande ve Ibwe, 2021). Bu yöntemler sualtında aksutik sensörlerin yer aldığı LBL gibi sistemlerde, sinyalin uçuş süresine (ToA, TDoA) bađlı olarak mesafe tahminine dayalı, karadaki konumlandırma sistemlerine benzer şekilde yaygın olarak kullanılırlar.

Trilaterasyon yöntemi gürültülü veri, dolayısıyla mesafe ölçüm hataları ile referans noktalarının geometrik olarak ölçüm noktasına göre konumuna bađlı olarak, ölçüm noktasının gerçek konumunda kesişmeyebilir, hatta hiç kesişmeyebilir. Bu nedenle trilaterasyon konusunda optimum sonuç üreten yaklaşımlara ihtiyaç duyulmaktadır. Bu bağlamda Zhou (2009)'nun yaptığı çalışmasında cebirsel olarak doğrusal olmayan veriyi en küçük kareler regresyon yöntemi kullanarak olumlu sonuçlar elde eden trilaterasyon yaklaşımı sunmuştur. Benzer şekilde Norrdine (2012), kapalı iç mekanlar için multilaterasyon problemine cebirsel bir çözüm yaklaşımı sunmuştur.

## Bölüm 3

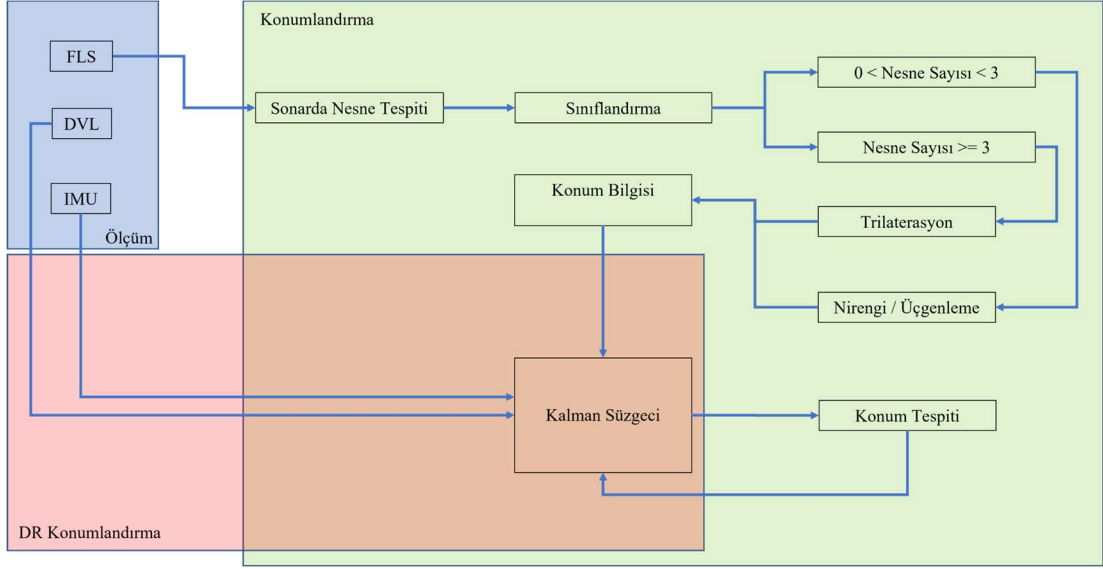
### Yöntem

Bu bölümde, daha sonra açıklanacak olan önerilen yaklaşımların uygulanabilmesi için gerekli yöntem ve materyaller sunulacaktır.

Genel olarak simülasyonda sualtı aracının üzerinde suyun tabanındaki hedeflerden yansıma alacak çok ışınlı (hüzmeli) ileri bakış sonarı, aracın hızını ölçecek bir DVL ve cihazın oryantasyonunu, ivmesini ölçen bir IMU bulunduğu varsayılarak, bu cihaz ve araçlara ait çıktı üreten sensör verileri gazebo simülasyon ortamında belirli gürültü değerleri eklenerek işlenecektir.

Eş zamanlı olarak alınan sonar verileri görüntüleri bir dizi görüntü işleme algoritmalarından sonra makine öğrenmesi ile nesne tanıma ve sınıflandırması yapılan temaslara ait veriler işlenerek sonrasında zahiri konumları, gerçek konuma dönüştürülerek uygun olan trilaterasyon veya nirengi-üçgenleme yöntemleri kullanılarak sonarın üzerinde bulunduğu cihazın (robot) konumu tahmin edilecektir. Sualtının doğası gereği ölçümlenen gürültülü veriler, Kalman süzgecine sokularak minimum hata ile optimum konumun tahmin edilmesi amaçlanmaktadır.

Sonardan temas alınamaması durumunda DVL, IMU ve yönelim bilgileri kullanılarak ataletsel olarak DR ilerleme sağlanması hedeflenmekte, tekrar bir yansıma veren nesne ile karşılaşıldığında konumun güncellenmesi gerçekleşecektir. Bu döngünün sürekli olarak devam etmesi planlanmaktadır. Genel hatlarıyla konum tahmini yöntem akışı Şekil 4'te sunulmuştur.



Şekil 4. Genel hatlarıyla konumlandırma yöntem akışı

### 3.1 Kullanılacak Platform ve Materyaller

Çalışmanın genel hatlarında kullanılacak olan görüntü işleme, nesne tespiti ve sınıflandırılması ile hesaplama işlemleri Python dili kullanılarak ROS ve Gazebo simülasyon ortamında gerçekleştirilmiştir.

Çalışma, Intel i7, 7700K işlemci, 32GB RAM, Nvidia 1080-GTX 8GB GPU'ya sahip bilgisayar üzerinde Linux işletim sistemi (Ubuntu 20.04 LTS) kullanılarak yapılmıştır.

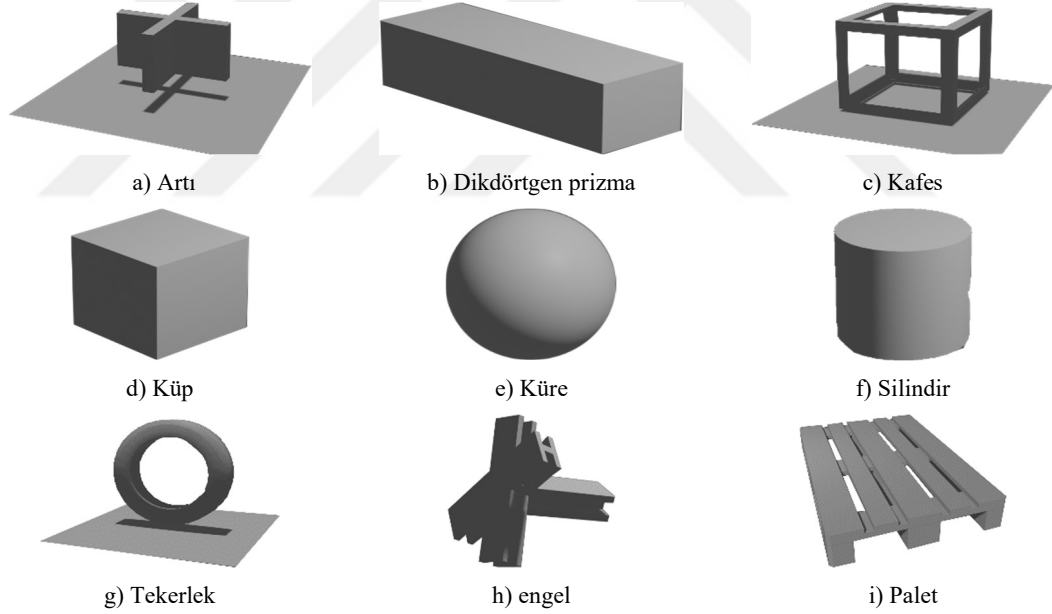
**3.1.1 Çok hüzmeli ileri bakış sonarı.** Choi ve diğerleri, 2021'nin yaptığı çalışmada Teledyne Marine BlueView P900 ileri bakış sonarı baz alınarak, ROS ortamında çalışmaya uygun çok ışınlı/hüzmeli ileri bakış sonar simülatörü tasarlamışlardır. Bu çalışmadaki nesne tespiti sınıflandırma ve diğer hesaplama işlemlerine ait sonuçlar bu simülatör üzerinde gözlemlenecek ve gerçekleştirilecek olup simülatörün ham haline Github deposundaki ROS derlemesine Field-Robotics-Lab. altında ulaşılabilir.

Tablo 1

*BlueView P900 İleri Bakış Sonarı Özellikleri (Choi ve diğerleri, 2021)*

Sonar Özellikleri	Değerleri
Frekans	900 kHz
Band Genişliği	2.95 kHz
Görüş Alanı	90°
Çalışma Menzili	10-60 m
Hüzme Genişliği	1° × 20°
Hüzme Başluğu	0.18°
Hüzme Sayısı	512
Hüzmedeki Işın Sayısı	11-114
Kaynak seviyesi	220 dB re $\mu$ Pa


**3.1.2 Sualtı objelerinin hazırlanması.** Gazebo ortamında, tasarlanmış sonar simülatorüne veri sağlayacak 3D modeller açık kaynak Blender uygulaması kullanılarak hazırlanmış, Şekil 5’te sunulmuştur.



Şekil 5. Öğrenmede kullanılacak sualtı obje modelleri

Objelerin sualtında gürültülü yansılarda oluşacak görüntü çözünürlük açısından düşük ve 3D projeksiyonunun 2D’ye dönüşmesi sebebiyle net olmayıp, sınıflandırılmaları zorlaşmaktadır. Sonarlarda objelerin bir ayırt edici özelliği de objenin arkasında bıraktığı gölgedir (Şekil 6). Görüntünün alındığı zamandaki sonar

eđimi, nesneye hangi taraftan hangi aı ile bakıldıđı gibi etmenler oluřacak grntde ve glgede farklılıklara sebep olacaktır. Objelerin tasarımında genel olarak simetrik olması amalanmıřtır, engel objesi simetrik yapılmamıřtır. Genel olarak objelerin en, boy, ykseklik ve ap miktarları 0.5m'dir. Őekilleri sebebiyle bazı objelerde bu miktar deđiřkenlik gstermektedir.




Őekil 6. Teker, kafes ve dikdrtgen prizması objelerinin sonar grnts.

### 3.2 Nesne Tanıma

YOLO (You Only Look Once), konvolsyonel sinir ađları (CNN) kullanarak nesne tespiti yapan algoritmalardan biridir. Nesnelerin tespiti ve sınıflandırılması konusunda gerek zamanlı nesne tespitini bu alandaki diđer algoritmalardan daha hızlı ve dođruluk payı yksek Őekilde yapabilmesi ayrıca tespit edilen nesnelerin boyutları ve konumları hakkında bilgi sađlaması sebebiyle YOLOv4 algoritması kullanılmıřtır (Bochkovskiy, Wang ve Liao, 2020).

Nesne tanıma bu arařtırmanın en hassas konularından biri ve dđm noktasıdır. Makine đreniminde kullanılacak nesnelerin tanıtılması ve YOLOv4 ile dođru nesne tespiti alıřmanın ana temelini oluřturur. alıřmadaki konumu bilinen nesnelerin dođru tahmin edilmesi, dođal olarak sonarın konumun tahminlenmesindeki en nemli faktrdr.

**3.2.1 Makine öğrenimi.** İleri bakış sonarı simülatöründe gözlemlenen 9 farklı modele sahip tasarlanan nesnenin YOLOv4 algoritmasına öğretilmesi için farklı zaman aralıkları, farklı konum, açı, irtifa ve hedefe olan farklı mesafe değerleri kullanılarak elde edilen sonar görüntüsü resim formatında kaydedilmiştir. Örnek resimler Şekil 7’de, veri seti oluşturulması için kaydedilen resim miktarları ise Tablo 2’de gösterilmiştir.



Şekil 7. Makine öğrenmesinde kullanılan örnek sonar görüntüleri

Kaydedilen görüntülerdeki obje yansımaları her bir görüntü için ayrı ayrı olarak açık kaynak labelImg uygulaması ile etiketlenmiştir. Etiketlenmenin sonucunda öğrenime katılması için fotoğraf içindeki nesnelerin konumu ve hangi obje olduğu belirtilmiştir.

Tablo 2

*Makine Öğrenmesi İçin Hazırlanan Veri Setine İlişkin Öğrenim ve Test Sayıları*

Obje İsmi	Öğretim resim sayısı	Test resim sayısı	Toplam resim sayısı
Dikdörtgen_P	246	23	269
Silindir	131	22	153
Küp	376	41	417
Küre	209	33	242
Palet	206	17	223
Tekerlek	408	40	448
Kafes	423	48	471
Artı	436	54	490
Engel	427	45	472
Karışık (Küp, Silindir, Küre)	268	24	292
Toplam	3130	347	3477

Kayıtlandırılan tüm sonar görüntüleri rastgele sıralanıp %89'u eğitim %11'i test için kullanılmıştır. Eğitim ve test işlemleri Google Colab platformunda YOLOv4 Darknet framework'ü üzerinde gerçekleştirilmiştir.

Öğrenime ait çizelge Şekil 8'de sunulmuş olup YOLOv4'de ortalama hassasiyet (mAP, Mean Average Precision) %99.66, ortalama kayıp değeri ise 0.5749 olarak hesaplanmıştır. Öğrenim, öğretilecek nesne sayısına bağlı olarak 18000 iterasyonda gerçekleştirilmiştir. Öğrenim sonucundaki testin değerlendirilmesi dört durumda ele alınır. Bu durumlar doğru pozitif (TP-True Positive), yanlış pozitif (FP-False Positive), yanlış negatif (FN-False Negative) ve doğru negatiftir (TN-True Negative). Makine öğreniminin ne kadar elverişli olduğunu belirleyen genel metrikler doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve f1-skoru'dur.


Doğruluk, doğru tahmin edilen kısımların toplamının, toplam veri sayısına oranını ifade eder  $((TP+TN) / (TP+TN + FP + FN))$ .

Hassasiyet, doğru pozitif tahminlerin toplam pozitif tahminlere oranıdır  $(TP/(TP+FP))$ .

Duyarlılık, gerçek pozitif tahminlerin, tüm gerçek pozitif tahminler içindeki oranını ifade eder  $(TP/(TP+FN))$ .

f1-Skoru, hassasiyet ve duyarlılığın harmonik ortalamasıdır.  $2 \times (\text{Hassasiyet} \times \text{Duyarlılık}) / (\text{Hassasiyet} + \text{Duyarlılık})$  formülüyle hesaplanır.

Ortalama Hassasiyet, nesne algılama gibi çok sınıflı görevde kullanılan bir metriktir. mAP, farklı sınıflar için ayrı ayrı hesaplanan hassasiyet değerlerinin ortalamasıdır. mAP değerinin yüksek olması daha iyi bir algılama performansını gösterir. Kayıp (loss) değeri ise tahminlerin gerçek değerden ne kadar farklı olduğunu ölçen bir metriktir. Öğrenimde ne kadar hata yapıldığını ifade eder (Aktaş, 2020; X. Yang ve diğerleri, 2022)



Şekil 8. YOLOv4 eğitim ve test çizelgesi.

Öğrenim sonucunda YOLO derin sinir ağı (DNN-Deep Neural Network) kullanılarak öğretilen nesnelerin sonarda tespiti, nesne veya nesnelerin genişliği ve yüksekliğine bağlı olarak da nesnenin orta nokta konumları tahmini yapılmıştır. Bu noktalardan referansla sonar veya sonarın üzerinde bulunduğu düşünülen cihazın konumu tespit edilebilecektir.

**3.2.2 Nesne tespiti.** Kullanılan simülatöre ait sonar görüntü verileri ROS'ta "sensor\_msgs/image" mesajı üzerinden 32FC1 formatında yayınlanmakta olup Python dilinde Opencv (Açık kaynak görüntü işleme kütüphanesi) kullanılarak görsel hale getirilmiştir. Opencv görüntü işleme kütüphanesi kullanılarak her bir görüntü çerçevesi için tüm piksellere 2x2 genişletme (dilata) uygulanarak nesne görüntülerindeki yoğunluk artırılarak seçicilik yükseltilmiştir. Sonarda elde edilen gürültülü verideki gürültü miktarının azaltılması için 3x3 bulanıklaştırma süzgeci

(gaussianblur) uygulanmıştır. Verilerden elde edilen sonar görüntüsü %20 oranında büyütülerek ekrandaki gözlem kalitesi arttırılmıştır.

Görüntü çerçevesinin sol üst köşesi sonar görüntü düzleminin (S, screen) orijinini ifade etmektedir. Sonar görüntü düzlemi yatayda x, düşeyde y eksenini ifade eder. x orijinden sağa doğru, y ise orijinden aşağı yönde artar. Sonar görüntüsü yatay olarak 512 pikselden oluşmakta ve her bir piksel sonardaki bir hüzmeyi (beam) ifade etmektedir. Sonar özelliklerine bağlı olarak hüzmeye içinde 114 ışın ise düşey görüntüde 399 piksel ile gösterilmektedir. Yatayda ve dikeyde %20 büyütülen görüntü çerçevesi 614 x 479 piksel olmuştur. Robot (body), sonar görüntü düzlemindeki konumu alt orta noktada bulunması sebebiyle,  ${}^S\mathbf{P}_B$  denklem (1) ile kolayca hesaplanabilir. Görüntü çerçevesinde yataydaki piksel sayısı  $hor_{px}$ , dikeydeki piksel sayısı  $ver_{px}$  ile ifade edilmiştir. Görüntü iki boyuttan oluşması sebebiyle konum matrisindeki z değeri derinlik sensöründen alınan ölçüm değeridir.

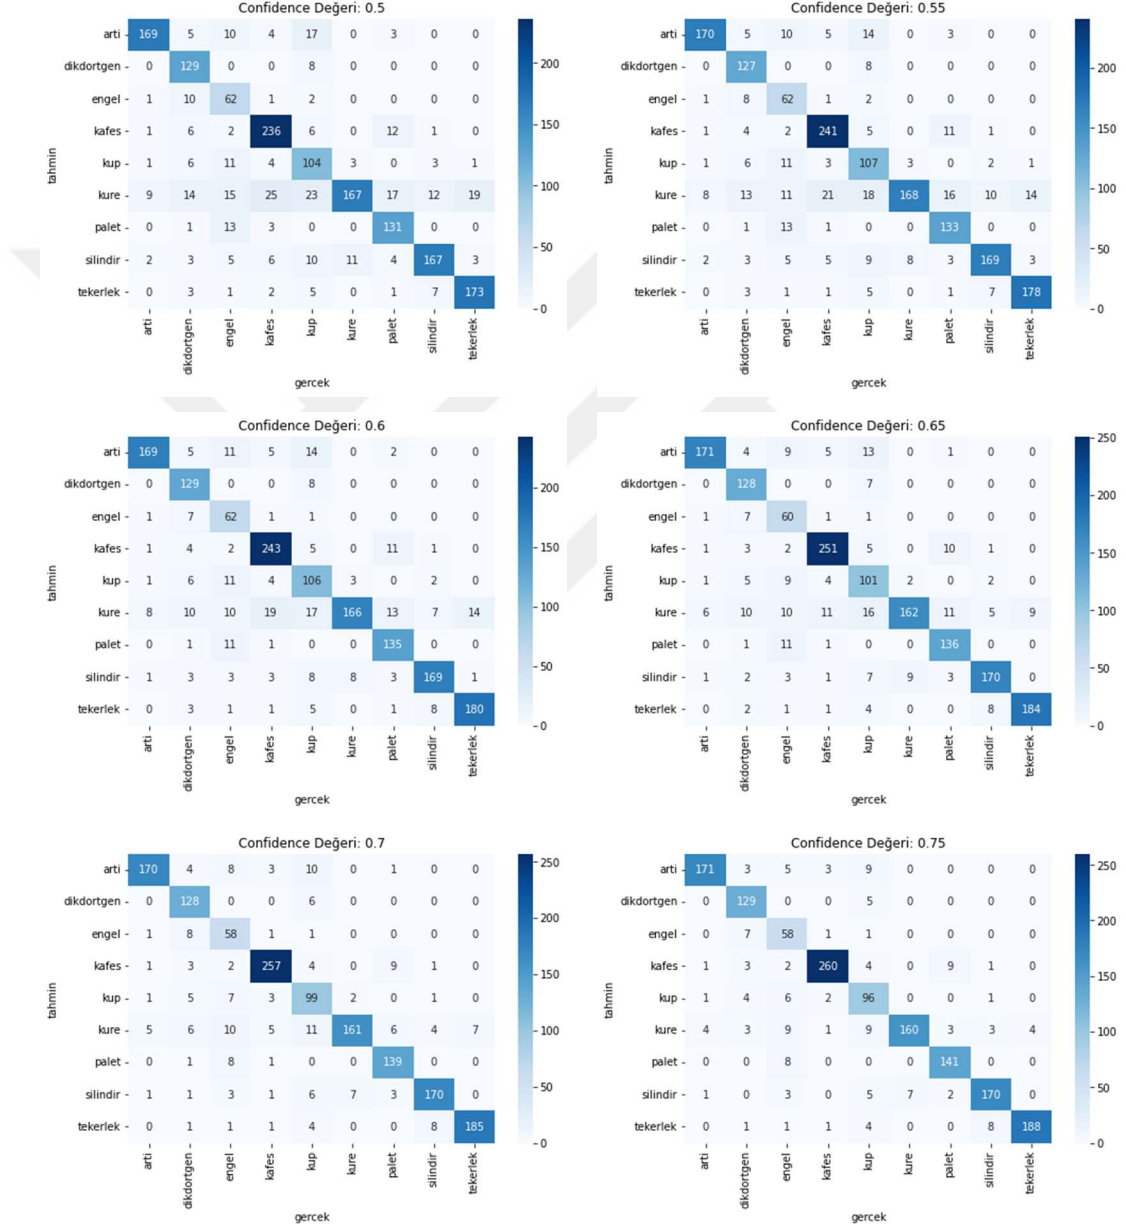
$${}^S\mathbf{P}_B = \begin{bmatrix} \frac{hor_{px}}{2} \\ ver_{px} \\ alt_{px} \end{bmatrix} \quad (1)$$

Robotun görüntü çerçevesindeki konumu, çerçevenin alt orta noktasıdır. Sonar simülöründe mesafe menzili (*range*) 10 ile 60 metre arasında seçilebilmekte ve konfigüre edilebilmektedir. Dikeydeki piksel sayısı sonar menziline eşit olması sebebiyle, sonar ekranında tespit edilen temas ile sonar arasındaki mesafelerin metrik olarak ifade edilmesinde kullanılacak olan piksel çözünürlüğünün ( $res_{px}$ ) hesaplanması denklem (2)'de gösterilmiştir.

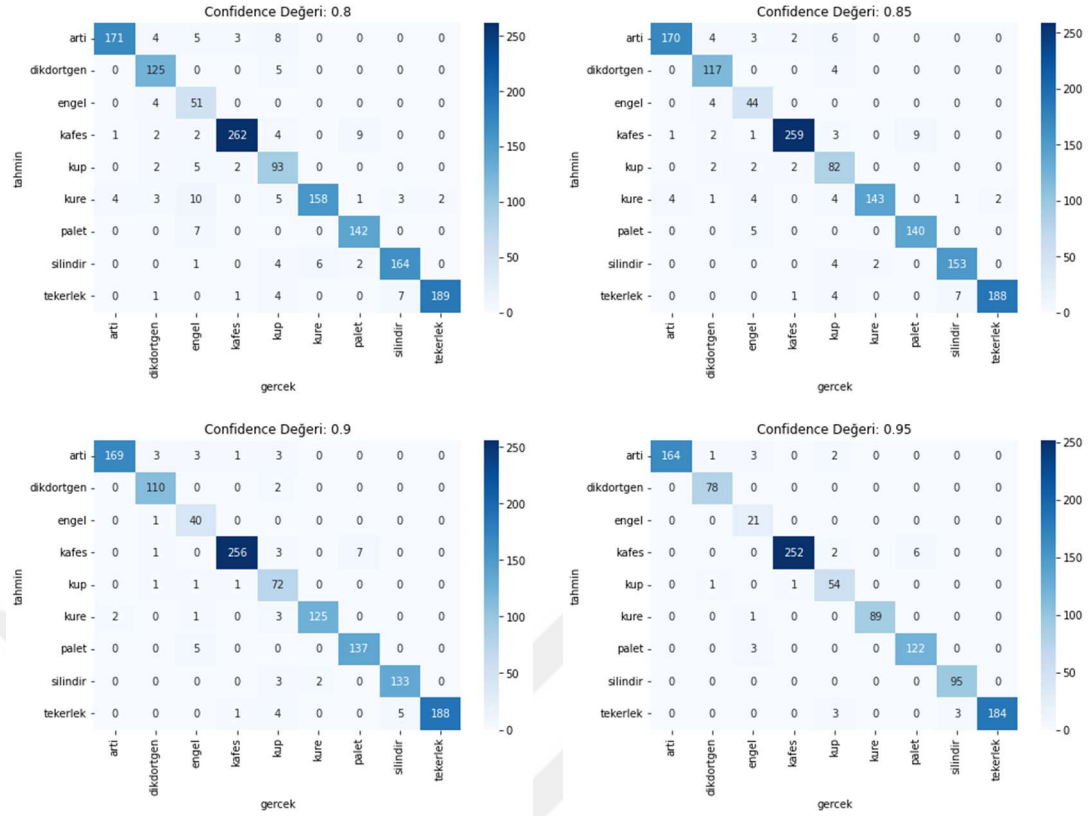
$$res_{px} = \frac{range}{ver_{px}} \quad (2)$$

Python'da Opencv kütüphanesi DNN sınıfı kullanılarak makine öğrenmesi sonucunda üretilen dosyalar dahil edilerek, her bir görüntü çerçevesi içerisinde nesne tespiti yapılmaya çalışılır. Varsayılan olarak kod bloğunda güvenilirlik derecesi olarak 0.78 değeri kullanılmıştır. Bu eşik değerinin üzerindeki güvenilirlik değerine sahip olan tespit edilmiş nesnelerin sınıflandırılması ve ölçülenmesi sağlanmıştır.

Optimum güvenilirlik derecesinin tespit edilebilmesi için oluşturulan simülasyon ortamında makine öğreniminde kullanılan resimlerin haricinde de sonar görüntü resimleri kayıtlandırılarak veri seti oluşturulmuştur. Bu veri setindeki resimler için 0.5-0.95 aralığında ve başlangıçtan 0.05 arttırılarak her bir güvenilirlik derecesi kullanılarak nesne tespiti yapılmış, elde edilen veriler ile karşılaştırmalı matrisler (confusion matrix) oluşturularak Şekil 9’da sunulmuştur.



Şekil 9. Güvenirlik derecesi tespiti karşılaştırmalı matrisleri



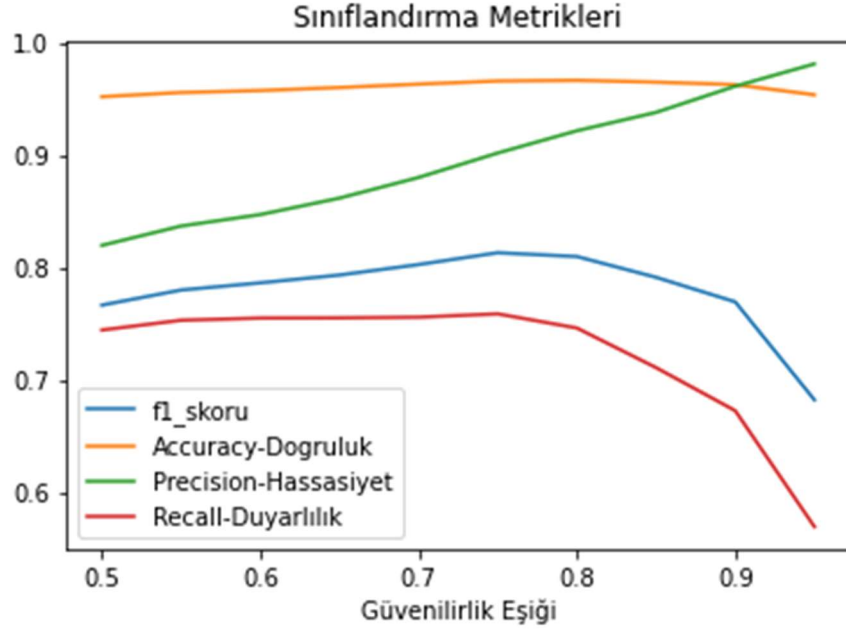
Şekil 9.(Devamı) Güvenirlilik derecesi tespiti karşılaştırmalı matrisleri

Her bir karşılaştırmalı matristeki veriler kullanılarak, her bir nesne sınıfı için doğruluk, hassasiyet, duyarlılık ve f1-skoru hesaplanarak elde edilen ortalama değerler Tablo 3’de sunulmuştur. Veri setinde yer alan nesnelerin hiç sınıflandırılmamış olması durumu FN olarak değerlendirilerek hesaplamaya dahil edilmiştir.

Tablo 3

Güvenirlilik Derecesi Tespiti İçin Sınıflandırma Metrik Değerleri.


Güvenirlilik Derecesi	Doğruluk	Hassasiyet	Duyarlılık	f1-skoru
0.5	0,9521	0,8198	0,7445	0,7666
0.55	0,9558	0,8370	0,7531	0,7800
0.6	0,9575	0,8472	0,7551	0,7864
0.65	0,9602	0,8618	0,7552	0,7934
0.7	0,9632	0,8802	0,7559	0,8027
0.75	0,9660	0,9019	0,7588	0,8132
0.8	0,9666	0,9218	0,7463	0,8099
0.85	0,9650	0,9381	0,7110	0,7914
0.9	0,9628	0,9614	0,6727	0,7695
0.95	0,9538	0,9812	0,5695	0,6823



Şekil 10. Sınıflandırma metrikleri.

Tablo 3'deki veriler ile oluşturulan grafik Şekil-10'da gösterilmiş olup, f1-skoru 0.78 güvenirlilik sevisinde en yüksek seviyeye ulaştığı tespit edilerek optimum sınıflandırmada kullanılacak eşik seviyesi olarak tercih edilmiştir.

Opencv kütüphanesi kullanılarak eşik değeri yüksek nesnelere tespit edilerek id tanımlaması yapılır, akabinde tespit edilen bir cisim üzerine kenarları teğet olacak şekilde, nesnenin büyüklü kadar dikdörtgen çerçeve çizer (Şekil 11). Dikdörtgene ait köşelerin koordinatlarını ve dikdörtgenin köşegenlerinin kesişim noktasının (dörtgenin merkezi) piksel değerlerini sonar görüntü çerçevesinde x,y,z koordinat düzlemine göre döndürür. Sonar görüntü çerçevesi iki boyutlu olmasından dolayı z eksenini, sınıflandırma yapılan nesnenin bilinen merkez yüksekliğinin piksel cinsinden değeridir.



Şekil 11. Tespit edilen nesnelerin kimlik ve güvenilirlik değeri ile gösterilmesi.

Doğru olarak gerçekleşen bir nesne tespiti ve buna bağlı olarak nesnelerin merkezlerinin, görüntü çerçevesindeki sonarın konumuna göre mesafe, kerteriz, eğim vb. değerler hesaplanabilir. Bu işlemler her bir görüntü çerçevesinde gerçek zamanlı gerçekleşebilir. Önemli olan nesnelerin tespitinin ve sınıflandırmasının doğru yapılmasıdır.

Çalışmada üç adet farklı düzlem bulunmaktadır. Nesne tespitinin yapıldığı sonar görüntü düzlemi (S, screen), robot düzlemi (B, body) ve gerçek Dünya düzlemidir (E, Earth). Sonar görüntü düzlemi piksel cinsinden ölçümlenmektedir. Sonar görüntü düzleminde tespit edilen bir nesneye (T, target) ait konum bilgileri ile ( ${}^S P_T = S_T$ ) gerçek dünya düzlemine rotasyonu sayesinde, konumları bilinen yapay nesnelere, robotun konum tahmini yapılabilecektir.

### 3.3 Konum Tahmin ve Tespiti

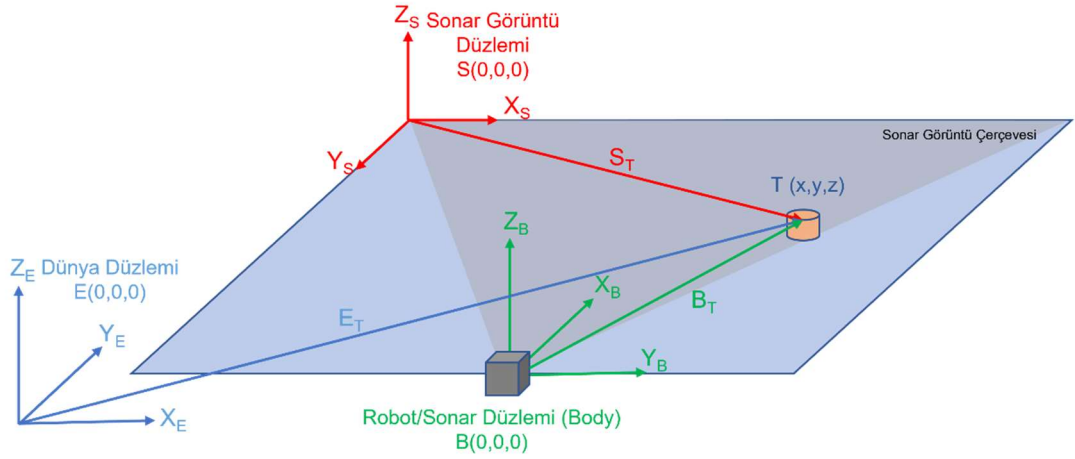
Sonar konumunun tespiti için bu çalışmadaki önerilen yaklaşımlar Şekil 4'te özetlendiği gibi sonarda eğer;

- 3'den az temas var ise tek bir nesneye bağlı olarak konum tespiti,
- 3 veya daha fazla temas olması durumunda trilaterasyon-multilaterasyon yöntemi,

- Herhangi bir temas olmaması durumunda son bilinen konum üzerinden cihaz üzerindeki IMU ve DVL’i simüle eden hız, ivme, yönelim ve zaman bilgileri ile DR konumlandırma yöntemi,

kullanılacaktır. Her üç yöntemde de elde edilen bilgiler ile konum tahmini, sonardaki gürültü ve sensörlerdeki ölçüm hata miktarı sebebiyle kalman süzgecinde sokularak en doğru tahmine ulaşılmaya çalışılacaktır.

**3.3.1 Tek temas ile konum tahmini.** OpenCV kütüphanesi ile sonarda tespit edilen ve sınıflandırması yapılan nesnelerin sonar görüntü düzlemindeki konum bilgileri piksel cinsinden alınmaktadır. Genel olarak sonar görüntü çerçevesi, robot düzlemi ve buna bağlı olarak Dünya düzlemini (E) açıklayan görsel Şekil 12’de gösterilmiştir.



Şekil 12. Çalışma düzlemleri

Sonar görüntü düzleminin robot düzlemine rotasyonu ( ${}^B_S\mathbf{R}$ ), eksenler arasında dönüş gerçekleşmemesi sebebiyle sabittir ve rotasyonu denklem (3)’de belirtilmiştir.

$${}^B_S\mathbf{R} = \begin{bmatrix} \cos(90^\circ) & \cos(180^\circ) & \cos(90^\circ) \\ \cos(0^\circ) & \cos(90^\circ) & \cos(90^\circ) \\ \cos(90^\circ) & \cos(90^\circ) & \cos(0^\circ) \end{bmatrix} = \begin{bmatrix} 0 & -1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3)$$

Sonar ekranında tespit edilen bir temasın, sonar görüntü düzlemindeki konumu ( ${}^S\mathbf{P}_T = \mathbf{S}_T$ ) OpenCV kütüphanesi ile belirlenmektedir. Bahse konu temasın, robot düzlemine göre konumu ( ${}^B\mathbf{P}_T$ ) denklem (4) ile hesaplanır.

$${}^B\mathbf{P}_T = {}^B_S\mathbf{R} \mathbf{S}_T + {}^B\mathbf{P}_S \quad (4)$$

${}^B P_S$  Sonar görüntü düzlemi orijininin, robot düzlemine göre konumunu ifade eder. Bir başka deyişle robotun, sonar görüntü düzlemi orijinine ötelenmesidir. Buna göre robot düşeydeki piksel sayısı ( $ver_{px}$ ) kadar  $X_B$  yönünde, yataydaki piksel sayısının ( $hor_{px}$ ) yarısı kadar negatif  $Y_B$  yönünde, robotun yerden yüksekliği ( $alt_{px}$ ) kadar da negatif  $Z_B$  yönünde ötelenmesidir. Robotun dünya düzlemindeki  $Z_E$  eksenindeki yüksekliği (altimetre değeri) metre cinsinden ölçülmektedir. Bu sebeple altimetre değerinin piksel çözünürlüğüne bölümü ile  $alt_{px}$  hesaplanır. Formülün açılmış hali denklem (5)'de sunulmuştur.

$${}^B P_T = \begin{bmatrix} 0 & -1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_S \\ y_S \\ z_S \end{bmatrix} + \begin{bmatrix} ver_{px} \\ -\frac{hor_{px}}{2} \\ -alt_{px} \end{bmatrix} \quad (5)$$

Robot eksenlerinin Dünya düzlemi eksenlerine göre başlangıçtaki pozisyonu denklem (6)'de belirtilmiştir.  ${}^E_B R_{init}$  Şekil 12'deki uzayların duruma göre oluşturulmuştur. Robotun başlangıç pozisyonuna göre kalibre edilerek denklem güncellenmelidir.

$${}^E_B R_{init} = \begin{bmatrix} \cos(90) & \cos(0) & \cos(90) \\ \cos(0) & \cos(90) & \cos(90) \\ \cos(90) & \cos(90) & \cos(0) \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (6)$$

Robotun gerçek dünya düzleminde yapabileceği tüm yönelimlere ait hesaplamayı sağlayacak dönüşüm matrisi denklem (8)'de belirtilmiştir. Sualtı cihazı üzerindeki pusula bize bu yönelim bilgisini sağlar. Açı değeri saat yönünde döndürülmelerde negatif değer alır. Buna bağlı olarak robotun gerçek dünya düzlemine göre rotasyonu denklem (7-8)'de gösterilmiş,

$$\mathbf{R} = R_x(\alpha) \cdot R_y(\beta) \cdot R_z(\theta) \quad (7)$$

$${}^E_B \mathbf{R} = {}^E_B \mathbf{R}_{init} \mathbf{R} \Rightarrow$$

$${}^E_B \mathbf{R} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\alpha) & -\sin(\alpha) \\ 0 & \sin(\alpha) & \cos(\alpha) \end{bmatrix} \begin{bmatrix} \cos(\beta) & 0 & \sin(\beta) \\ 0 & 1 & 0 \\ -\sin(\beta) & 0 & \cos(\beta) \end{bmatrix} \begin{bmatrix} \cos(\theta) & -\sin(\theta) & 0 \\ \sin(\theta) & \cos(\theta) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (8)$$


sonar görüntü düzlemi gerçek dünya düzlemine dönüştürülmüştür. Eldeki toplanan değerlere bakıldığında, sonar görüntü düzlemindeki bir T noktasına ait dünya

düzlemindeki konumu ( ${}^E\mathbf{P}_T = \mathbf{E}_T$ ) bilinmektedir. Robot düzlemindeki T noktasının konumu ( ${}^B\mathbf{P}_T = \mathbf{B}_T$ ) piksel olarak belirtilmesinden ve dünya düzleminde ölçümlerin metre olması sebebiyle piksel uzunluk değerleri metre cinsinden hesaplanmalıdır. Robot ile dünya düzlemi arasındaki dönüşüm bilinmekte olup son işlem olarak robotun dünya düzlemindeki konumunun ( ${}^E\mathbf{P}_B$ ) bulunması gerekmektedir. Denklem (9)'de robotun dünya düzlemindeki konumu hesaplanmaktadır.

$${}^E\mathbf{P}_B = {}^E\mathbf{P}_T - {}^E_B\mathbf{R}({}^B\mathbf{P}_T \text{ res}_{px}) \quad (9)$$

Sonar görüntü düzleminde tespit edilen bir temasa ait konum bilgisi ile yapılan transformasyon işlemleri sonucunda robotun gerçek dünyadaki konumu bulunur.

**3.3.2 Trilaterasyon.** Evrensel düzlemde konumu bilinmeyen nesnelerin konumlarının, konumları bilinen diğer noktalara olan uzaklıklarından hesaplanma tekniğine laterasyon denir. Bu teknik genel olarak 3 veya daha fazla konumu bilinen nesne, düğüm, referans noktası vb. değerlerin mesafelerinin kullanılması ile trilaterasyon, daha fazlaca bilinen nokta uzaklıkları kullanılıyorsa ismini multilaterasyon olarak almaktadır.



Şekil 13. Mesafe ölçümlerine dayalı trilaterasyon.

Trilaterasyon yöntemi  $T_1$ ,  $T_2$ ,  $T_3$  noktalarının dünya düzlemindeki yeri bilinmesi sebebiyle herhangi düzlemler arası rotasyon veya transformasyon işlemine gerek duymadan konum tahmini sağlar. Tahmini konum düşük işlem maliyeti ile elde edilebilir. (Norrdine, 2012)

Dünya düzleminde Şekil 13’de gösterilen üç referans noktası  $T_1(x_1, y_1, z_1)$ ,  $T_2(x_2, y_2, z_2)$ ,  $T_3(x_3, y_3, z_3)$  ve robot noktasına (B, body) olan mesafe ölçümleri  $d_1$ ,  $d_2$  ve  $d_3$  olarak belirlenmiştir. Sonar görüntü çerçevesinde  $T_1, T_2, T_3, T_n$  noktaları için hesaplanan mesafe değerleri piksel cinsinden olup denklem (2) ile metre cinsine dönüştürülmelidir.

B noktasının koordinatlarının  $(x, y, z)$  belirlenmesi, denklem (10)’deki ikinci dereceden denklem sisteminin çözümlerinin bulunması ile gerçekleştirilir.

$$\begin{cases} (x - x_1)^2 + (y - y_1)^2 + (z - z_1)^2 = d_1^2 \\ (x - x_2)^2 + (y - y_2)^2 + (z - z_2)^2 = d_2^2 \\ (x - x_3)^2 + (y - y_3)^2 + (z - z_3)^2 = d_3^2 \end{cases} \quad (10)$$

Denklem (10)’in açılmış ve düzenlenmiş pozisyonu denklem (11)’de gösterilmiştir.

$$\begin{cases} (x^2 + y^2 + z^2) - 2x_1x - 2y_1y - 2z_1z = d_1^2 - x_1^2 - y_1^2 - z_1^2 \\ (x^2 + y^2 + z^2) - 2x_2x - 2y_2y - 2z_2z = d_2^2 - x_2^2 - y_2^2 - z_2^2 \\ (x^2 + y^2 + z^2) - 2x_3x - 2y_3y - 2z_3z = d_3^2 - x_3^2 - y_3^2 - z_3^2 \end{cases} \quad (11)$$

Denklem (11)’in cebirsel olarak formülü ve ifadesi denklem (12-13)’de sunulmuştur.

$$\mathbf{Ax} = \mathbf{b} \quad (12)$$

$$\begin{bmatrix} 1 & -2x_1 & -2y_1 & -2z_1 \\ 1 & -2x_2 & -2y_2 & -2z_2 \\ 1 & -2x_3 & -2y_3 & -2z_3 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & -2x_n & -2y_n & -2z_n \end{bmatrix} \begin{bmatrix} x^2 + y^2 + z^2 \\ x \\ y \\ z \end{bmatrix} = \begin{bmatrix} d_1^2 - x_1^2 - y_1^2 - z_1^2 \\ d_2^2 - x_2^2 - y_2^2 - z_2^2 \\ d_3^2 - x_3^2 - y_3^2 - z_3^2 \\ \vdots \\ d_n^2 - x_n^2 - y_n^2 - z_n^2 \end{bmatrix} \quad (13)$$

$\hat{x}$ ’in çözümü denklem (14) ile sağlanır.

$$\hat{\mathbf{x}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} \quad (14)$$

A matrisinin satır sayısı sonarda tespit edilen temas sayısına bağlı olduğundan her zaman bir kare matris olmayacaktır. Bu durumlarda tersini bulma işlemi sözde matris tersi ile gerçekleştirilir (Pseudo Matrix Inverse).

**3.3.3 DR konum tespiti.** Robot üzerinde bulunan sonarda bir temas sağlanması durumunda konumun hesaplanmasına yönelik tek temas ile konum hesaplanması ve trilaterasyon yöntemlerinin kullanılacağından bahsedilmişti. Sonarda sualtı şartlarına bağlı olarak herhangi bir temas sağlanamaması durumunda; robota ait konum, cihaz üzerinde mevcut DVL, IMU'dan ölçülen hız ve ivme değerlerine bağlı olarak, son konumdan  $(x_{n-1}, y_{n-1}, z_{n-1})$  belirli bir zaman içinde  $(\Delta t)$  ölçümlenen hız  $(v)$  ve ivme  $(a)$  değerleri ile doğrusal olarak bir sonraki konum  $(x_n, y_n, z_n)$  tahmini basit olarak denklem (15)'de açıklanmıştır.

$$\begin{cases} \hat{x}_n = \hat{x}_{n-1} + v\Delta t + \frac{a\Delta t^2}{2} \\ \hat{y}_n = \hat{y}_{n-1} + v\Delta t + \frac{a\Delta t^2}{2} \\ \hat{z}_n = \hat{z}_{n-1} + v\Delta t + \frac{a\Delta t^2}{2} \end{cases} \quad (15)$$

Kalman süzgecinde durum geçiş matrisi, denklemde bu modele göre oluşturulacaktır. DR navigasyonda süreye bağlı olarak konum hata miktarı artacağından dolayı, şartlara bağlı olarak ilk fırsatta ölçümsel olarak güncellenmesi ile daha doğru konum tahmini elde edilmelidir.

**3.3.4 Kalman Süzgeci.** Kalman süzgeci belirli bir sisteme ait matematiksel modeli ve sisteme sağlanan girdiler ile bu sistemin durumunu tahmin etmek, sistemin daha düzgün ve iyi sonuçlar üretmesi için geri beslemeler üretebilen ve robotikte sıkça kullanılan bir yöntemdir. Doğrusal Kalman süzgeci (LKF-Linear Kalman Filter) modeli, doğrusal olmayan hareket ve ölçüm modellerinde kullanılamaz. Hareket ve ölçüm modelleri doğrusal olmayan proje ve çalışmalarda genişletilmiş ve kokusuz Kalman süzgeci (EKF- Extended Kalman Filter, UKF-Unscented Kalman Filter) algoritmaları kullanılabilir. Bu çalışmada doğrusal kalman süzgeci kullanılmıştır.

Kalman süzgeci döngüsü basitçe, bir başlangıç değeri ve ilk tahmin sonrasında sonsuz döngüde kullanılacak ölçüm, güncelleme ve tahmin fazlarından oluşmaktadır. Bu çalışmada kalman süzgeci ile robotun konumunu X, Y eksenlerinde tahmin edilmektedir. Z eksenini de denkleme dahil edilebilir, ancak robotun dipten yüksekliğini minimal ve sabit tutulması sebebiyle kalman süzgeci X, Y düzleminde

konumlandırma için açıklanacaktır. Aşağıda sunulan kalman süzgeci, sonarda tespit edilen en az bir temas olduğu ve ölçümle robotun tahmini konumunun hesaplandığı durumda ele alınmıştır.

*Hareket denklemi;*

$$\hat{\mathbf{x}}_{n+1,n} = \mathbf{F}\hat{\mathbf{x}}_{n,n} \quad (16)$$

Denklem içeriğinde;

$\hat{\mathbf{x}}_{n+1,n}$  n+1 zamanındaki öngörülen sistem durum vektörü,

$\hat{\mathbf{x}}_{n,n}$  n zamanındaki sistem durum vektörü tahmini,

**F** doğrusal dinamik sistem modeli durum geçiş matrisi

$$\hat{\mathbf{x}}_{n,n} = \begin{bmatrix} x_n \\ \dot{x}_n \\ \ddot{x}_n \\ y_n \\ \dot{y}_n \\ \ddot{y}_n \end{bmatrix} \quad (17)$$

$x_n, y_n$  sonarda tespit edilen temaslara ait bilgiler sonucunda hesaplanmış konum tahmini,  $\dot{x}_n, \dot{y}_n$  eksenler üzerindeki hızlar,  $\ddot{x}_n, \ddot{y}_n$  ise eksenler üzerinde oluşan ivme değerleridir.

DR olarak zaman, hız ve ivmeye bağlı aracın bir sonraki durumu denklem (18) ile açıklanabilir. ( $\Delta t$  = iki ölçüm arasında geçen zaman farkı)

$$\begin{cases} \hat{x}_{n+1,n} = \hat{x}_{n,n} + \hat{\dot{x}}_{n,n}\Delta t + \frac{1}{2}\hat{\ddot{x}}_{n,n}\Delta t^2 \\ \hat{\dot{x}}_{n+1,n} = \hat{\dot{x}}_{n,n} + \hat{\ddot{x}}_{n,n}\Delta t \\ \hat{\ddot{x}}_{n+1,n} = \hat{\ddot{x}}_{n,n} \\ \hat{y}_{n+1,n} = \hat{y}_{n,n} + \hat{\dot{y}}_{n,n}\Delta t + \frac{1}{2}\hat{\ddot{y}}_{n,n}\Delta t^2 \\ \hat{\dot{y}}_{n+1,n} = \hat{\dot{y}}_{n,n} + \hat{\ddot{y}}_{n,n}\Delta t \\ \hat{\ddot{y}}_{n+1,n} = \hat{\ddot{y}}_{n,n} \end{cases} \quad (18)$$

matris formuna dönüştürülmesi denklem (19)'de gösterilmiştir.

$$\begin{bmatrix} \hat{x}_{n+1,n} \\ \hat{\dot{x}}_{n+1,n} \\ \hat{\ddot{x}}_{n+1,n} \\ \hat{y}_{n+1,n} \\ \hat{\dot{y}}_{n+1,n} \\ \hat{\ddot{y}}_{n+1,n} \end{bmatrix} = \begin{bmatrix} 1 & \Delta t & 0.5\Delta t^2 & 0 & 0 & 0 \\ 0 & 1 & \Delta t & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & \Delta t & 0.5\Delta t^2 \\ 0 & 0 & 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \hat{x}_{n,n} \\ \hat{\dot{x}}_{n,n} \\ \hat{\ddot{x}}_{n,n} \\ \hat{y}_{n,n} \\ \hat{\dot{y}}_{n,n} \\ \hat{\ddot{y}}_{n,n} \end{bmatrix} \quad (19)$$

Kovaryans ekstrapolasyon denklemi;

$$\rho_{n+1,n} = F\rho_{n,n}F^T + Q \quad (20)$$

$\rho_{n,n}$  mevcut durum tahmininin belirsizlik (kovaryans) matrisi,

$\rho_{n+1,n}$  bir sonraki durum tahmininin belirsizlik matrisi,

$F$  doğrusal dinamik sistem modeli durum geçiş matrisi,

$Q$  süreç gürültü matrisidir.

Tahmin belirsizliği matris formunda denklem (21)'de sunulmuştur.

$$\rho = \begin{bmatrix} \rho_x & \rho_{x\dot{x}} & \rho_{x\ddot{x}} & \rho_{xy} & \rho_{x\dot{y}} & \rho_{x\ddot{y}} \\ \rho_{\dot{x}x} & \rho_{\dot{x}} & \rho_{\dot{x}\ddot{x}} & \rho_{\dot{x}y} & \rho_{\dot{x}\dot{y}} & \rho_{\dot{x}\ddot{y}} \\ \rho_{\ddot{x}x} & \rho_{\ddot{x}\dot{x}} & \rho_{\ddot{x}} & \rho_{\ddot{x}y} & \rho_{\ddot{x}\dot{y}} & \rho_{\ddot{x}\ddot{y}} \\ \rho_{yx} & \rho_{y\dot{x}} & \rho_{y\ddot{x}} & \rho_y & \rho_{y\dot{y}} & \rho_{y\ddot{y}} \\ \rho_{\dot{y}x} & \rho_{\dot{y}\dot{x}} & \rho_{\dot{y}\ddot{x}} & \rho_{\dot{y}y} & \rho_{\dot{y}} & \rho_{\dot{y}\ddot{y}} \\ \rho_{\ddot{y}x} & \rho_{\ddot{y}\dot{x}} & \rho_{\ddot{y}\ddot{x}} & \rho_{\ddot{y}y} & \rho_{\ddot{y}\dot{y}} & \rho_{\ddot{y}} \end{bmatrix} \quad (21)$$

$\rho_x$   $x$  koordinatı konum tahmininin varyansıdır,

$\rho_{\dot{x}}$   $x$  koordinatı hız tahmininin varyansıdır,

$\rho_{\ddot{x}}$   $x$  koordinatı ivme tahmininin varyansıdır,

$\rho_y$   $y$  koordinatı konum tahmininin varyansıdır,

$\rho_{\dot{y}}$   $y$  koordinatı hız tahmininin varyansıdır,

$\rho_{\ddot{y}}$   $y$  koordinatı ivme tahmininin varyansıdır.

Diyagonal olmayan girdiler kovaryanslardır.  $X$  ve  $Y$  eksenlerindeki tahmin hataları ilişkili olmaması sebebiyle karşılıklı terimler sıfırlanabilir. Bu durumda matris, denklem (22)'de olduğu gibi ifade edilebilir.

$$\rho = \begin{bmatrix} \rho_x & \rho_{x\dot{x}} & \rho_{x\ddot{x}} & 0 & 0 & 0 \\ \rho_{\dot{x}x} & \rho_{\dot{x}} & \rho_{\dot{x}\ddot{x}} & 0 & 0 & 0 \\ \rho_{\ddot{x}x} & \rho_{\ddot{x}\dot{x}} & \rho_{\ddot{x}} & 0 & 0 & 0 \\ 0 & 0 & 0 & \rho_y & \rho_{y\dot{y}} & \rho_{y\ddot{y}} \\ 0 & 0 & 0 & \rho_{\dot{y}y} & \rho_{\dot{y}} & \rho_{\dot{y}\ddot{y}} \\ 0 & 0 & 0 & \rho_{\ddot{y}y} & \rho_{\ddot{y}} & \rho_{\ddot{y}\ddot{y}} \end{bmatrix} \quad (22)$$

Süreç gürültü matrisi, iki boyutlu sabit ivme modeli denklem (23)'de gösterilmiştir.

$$Q = \begin{bmatrix} \sigma_x^2 & \sigma_{x\dot{x}}^2 & \sigma_{x\ddot{x}}^2 & \sigma_{x\dot{y}}^2 & \sigma_{x\ddot{y}}^2 & \sigma_{x\dot{y}\ddot{y}}^2 \\ \sigma_{\dot{x}x}^2 & \sigma_{\dot{x}}^2 & \sigma_{\dot{x}\ddot{x}}^2 & \sigma_{\dot{x}\dot{y}}^2 & \sigma_{\dot{x}\ddot{y}}^2 & \sigma_{\dot{x}\dot{y}\ddot{y}}^2 \\ \sigma_{\ddot{x}x}^2 & \sigma_{\ddot{x}\dot{x}}^2 & \sigma_{\ddot{x}}^2 & \sigma_{\ddot{x}\dot{y}}^2 & \sigma_{\ddot{x}\ddot{y}}^2 & \sigma_{\ddot{x}\dot{y}\ddot{y}}^2 \\ \sigma_{y\dot{x}}^2 & \sigma_{y\ddot{x}}^2 & \sigma_{y\dot{y}}^2 & \sigma_y^2 & \sigma_{y\dot{y}}^2 & \sigma_{y\dot{y}\ddot{y}}^2 \\ \sigma_{\dot{y}x}^2 & \sigma_{\dot{y}\dot{x}}^2 & \sigma_{\dot{y}\ddot{x}}^2 & \sigma_{\dot{y}\dot{y}}^2 & \sigma_{\dot{y}}^2 & \sigma_{\dot{y}\dot{y}\ddot{y}}^2 \\ \sigma_{\ddot{y}x}^2 & \sigma_{\ddot{y}\dot{x}}^2 & \sigma_{\ddot{y}\ddot{x}}^2 & \sigma_{\ddot{y}\dot{y}}^2 & \sigma_{\ddot{y}}^2 & \sigma_{\ddot{y}\dot{y}\ddot{y}}^2 \end{bmatrix} \quad (23)$$

X ve Y eksenlerindeki süreç gürültülerinin ilişkili olmaması sebebiyle karşılıklı terimler sıfırlanabilir. Bunun sonucunda süreç gürültü matrisi denklem (24)'de belirtilmiştir.

$$Q = \begin{bmatrix} \sigma_x^2 & \sigma_{x\dot{x}}^2 & \sigma_{x\ddot{x}}^2 & 0 & 0 & 0 \\ \sigma_{\dot{x}x}^2 & \sigma_{\dot{x}}^2 & \sigma_{\dot{x}\ddot{x}}^2 & 0 & 0 & 0 \\ \sigma_{\ddot{x}x}^2 & \sigma_{\ddot{x}\dot{x}}^2 & \sigma_{\ddot{x}}^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & \sigma_y^2 & \sigma_{y\dot{y}}^2 & \sigma_{y\dot{y}\ddot{y}}^2 \\ 0 & 0 & 0 & \sigma_{\dot{y}y}^2 & \sigma_{\dot{y}}^2 & \sigma_{\dot{y}\dot{y}\ddot{y}}^2 \\ 0 & 0 & 0 & \sigma_{\ddot{y}y}^2 & \sigma_{\ddot{y}}^2 & \sigma_{\ddot{y}\dot{y}\ddot{y}}^2 \end{bmatrix} \quad (24)$$

$\sigma_a^2$  ivmelenmedeki standart sapma varyansıdır. İki boyutlu sabit ivme modeli için süreç gürültü matrisi oluşturmak üzere denklemler denklem (25-28)'de sunulmuştur.

$$Q = FQ_aF^T \quad (25)$$

$$Q_a = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (26)$$

F durum geçiş matrisi denklem (18-19)'de belirtilmişti. Matrislerin formülde yerlerine konmasıyla;

$$Q = \begin{bmatrix} 1 & \Delta t & 0.5\Delta t^2 & 0 & 0 & 0 \\ 0 & 1 & \Delta t & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & \Delta t & 0.5\Delta t^2 \\ 0 & 0 & 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ \Delta t & 1 & 0 & 0 & 0 & 0 \\ 0.5\Delta t^2 & \Delta t & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & \Delta t & 1 & 0 \\ 0 & 0 & 0 & 0.5\Delta t^2 & \Delta t & 1 \end{bmatrix} \sigma_a^2 \quad (27)$$

Sabit ivmeli hareket modeli için süreç gürültü matrisi denklem (28)'de olduğu gibidir.

$$Q = \begin{bmatrix} \frac{\Delta t^4}{4} & \frac{\Delta t^3}{2} & \frac{\Delta t^2}{2} & 0 & 0 & 0 \\ \frac{\Delta t^3}{2} & \Delta t^2 & \Delta t & 0 & 0 & 0 \\ \frac{\Delta t^2}{2} & \Delta t & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{\Delta t^4}{4} & \frac{\Delta t^3}{2} & \frac{\Delta t^2}{2} \\ 0 & 0 & 0 & \frac{\Delta t^3}{2} & \Delta t^2 & \Delta t \\ 0 & 0 & 0 & \frac{\Delta t^2}{2} & \Delta t & 1 \end{bmatrix} \sigma_a^2 \quad (28)$$

Ölçüm denklemi;

$$z_n = H\hat{x}_n \quad (29)$$

Bu denklemde;  $z_n$  ölçüm yapılan girdilerdir. Bu çalışmada sonardan alınan temas bilgilerinin hesaplaması ile tahmini konumları ( $\hat{x}_n, \hat{y}_n$ ) bu denklemdeki ölçüm girdi değerleridir. Ayrıca robotta hız ve ivme değerlerini de sensörlerden ölçülmektedir.  $x_n$  matrisi denklem(17)'de gösterilmiştir.  $H$  matrisi;  $z_n$  ve  $x_n$  matrisleri aynı boyutlarda olması (6x1), ayrıca sistemdeki tüm girdiler (konum, hız, ivme) ölçülebildiğinden, birim matristir. DR olarak yapılan navigasyonda sisteme girdi hız ve ivme olacağı için  $H$  gözlem matrisi birim matristen farklı olacaktır.

$$\begin{bmatrix} x_{n,m} \\ \dot{x}_{n,m} \\ \ddot{x}_{n,m} \\ y_{n,m} \\ \dot{y}_{n,m} \\ \ddot{y}_{n,m} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \hat{x}_n \\ \hat{\dot{x}}_n \\ \hat{\ddot{x}}_n \\ \hat{y}_n \\ \hat{\dot{y}}_n \\ \hat{\ddot{y}}_n \end{bmatrix} \quad (30)$$

Sonarda temas alınamaması dolayısıyla sınıflandırma yapılamadığında konumlandırma ataletsel ölçüm ve hız girdileri ile gerçekleşecektir. Bu durumda; kalman süzgecinde girdi denklem (31)'deki gibi sağlanacaktır.

$$\mathbf{z}_n = \mathbf{H}\hat{\mathbf{x}}_n$$

$$\begin{bmatrix} \dot{x}_{n,m} \\ \ddot{x}_{n,m} \\ \dot{y}_{n,m} \\ \ddot{y}_{n,m} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \hat{\dot{x}}_n \\ \hat{\ddot{x}}_n \\ \hat{\dot{y}}_n \\ \hat{\ddot{y}}_n \end{bmatrix} \quad (31)$$

*Ölçüm belirsizliği;*

Denklem (31)'de gösterilen alt simge “m”, ölçümdeki belirsizliği ifade eder. Sualtının zorlu ortam şartları sebebiyle ölçüm belirsizlikleri bu çalışmada simüle edilmiştir. Sonardan alınan konum verilerinde, DVL'in ölçümlediği hız ve ataletsel sistemden elde edilen ivmelenme değerlerinde rastsal gürültü ve ölçüm belirsizliği mevcuttur. Ölçüm belirsizliği matrisi bu çalışma için sonarda temas olması durumunda denklem (32)'deki şekliyle oluşturulmuştur.

$$\mathbf{R}_n = \begin{bmatrix} \sigma_{x_m}^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & \sigma_{\dot{x}_m}^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & \sigma_{\ddot{x}_m}^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & \sigma_{y_m}^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & \sigma_{\dot{y}_m}^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & \sigma_{\ddot{y}_m}^2 \end{bmatrix} \quad (32)$$

Sonarda temas alınamaması ve ölçümü yapılamaması durumunda; ölçümü yapılamayan bir konum ve dolayısıyla konum ölçüm belirsizliği olmayacaktır. Bu duruma göre ölçüm belirsizliği denklem (33)'de verilmiştir.

$$\mathbf{R}_n = \begin{bmatrix} \sigma_{\hat{x}_m}^2 & 0 & 0 & 0 \\ 0 & \sigma_{\hat{x}_m}^2 & 0 & 0 \\ 0 & 0 & \sigma_{\hat{y}_m}^2 & 0 \\ 0 & 0 & 0 & \sigma_{\hat{y}_m}^2 \end{bmatrix} \quad (33)$$

*Kalman kazancı denklemi;*

Kalman kazancının hesaplamasını sağlayan denklem sonardan ölçüm alınması veya alınmaması durumunda da denklem (34)'de belirtildiği gibidir.

$$\mathbf{K}_n = \rho_{n,n-1} \mathbf{H}^T (\mathbf{H} \rho_{n,n-1} \mathbf{H}^T + \mathbf{R}_n)^{-1} \quad (34)$$

*Durum güncelleme denklemi;*

Durum güncelleme hesaplamasını sağlayan denklem (35) aşağıda gösterilmiştir.

$$\hat{\mathbf{x}}_{n,n} = \hat{\mathbf{x}}_{n,n-1} + \mathbf{K}_n (\mathbf{z}_n - \mathbf{H} \hat{\mathbf{x}}_{n,n-1}) \quad (35)$$

*Kovaryans güncelleme denklemi;*

Elde toplanan ve oluşturulan matrislerle birlikte kovaryans güncelleme denklem (36)'da gösterilmiştir.


$$\rho_{n,n} = (\mathbf{I} - \mathbf{K}_n \mathbf{H}) \rho_{n,n-1} (\mathbf{I} - \mathbf{K}_n \mathbf{H})^T + \mathbf{K}_n \mathbf{R}_n \mathbf{K}_n^T \quad (36)$$

## Bölüm 4

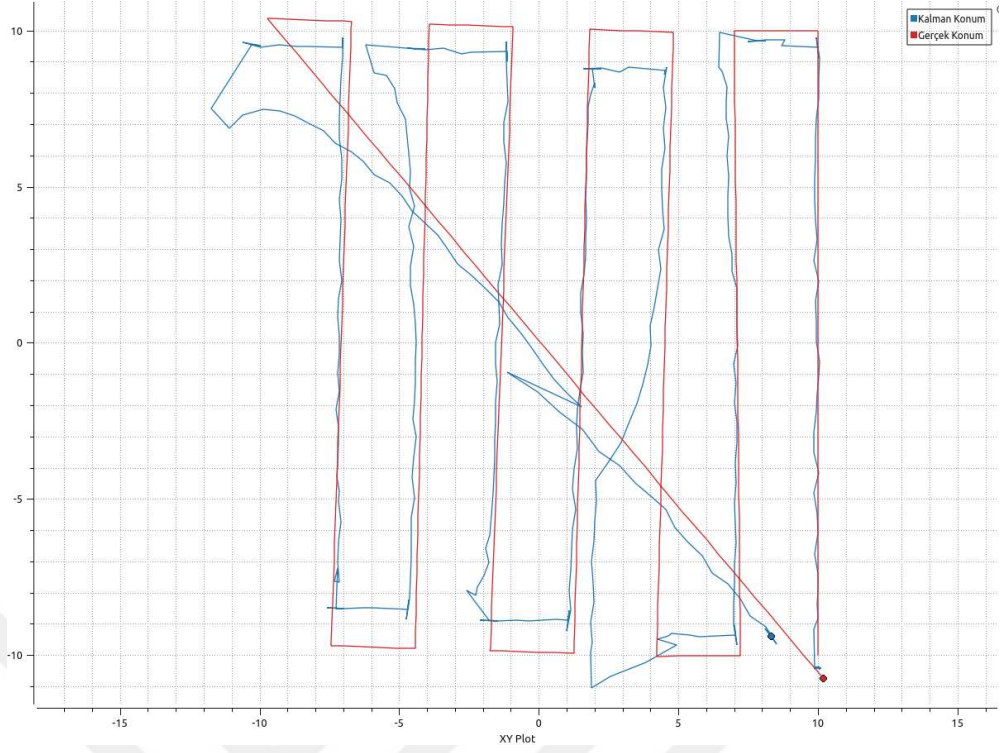
### Bulgular

Yöntem bölümündeki hesaplamalar dahilinde GAZEBO simülasyon ortamında 20 x 20 metre bir alanda zıt ve çapraz yönler içerecek şekilde bir rota paterni ile katı modeli kullanılan nesnelere belirli konumlara yerleştirilerek, DR ve sonardan alınan verilerin sınıflandırılması ile konum tahmini gerçekleştirilmiştir.


Çalışmada makine öğrenmesinde kullanılan objelerinin sınırlı sayıda olması, daha doğru istatistiğe ulaşmak ve daha fazla veri toplamak amacıyla tek temas, trilaterasyon-multilaterasyon ve DR yöntemleri kullanılarak veri toplamak için üç farklı ortam tasarlanmıştır (Şekil 14,16). Her üç ortamda da tüm yöntemler için veri toplanarak konum tahminleri analiz edilmiştir. Sonarın hareketli veya sabit pozisyonunda da olmak üzere, konum hesaplamaları için kullanılan tek temas, trilaterasyon-multilaterasyon ve DR yöntemlerinden elde edilen veriler csv dosyasında kayıtlandırılarak, gerçek konumları ile hesaplanan tahmini konumları arasındaki hata miktarları analiz edilmiştir. Veri toplama esnasındaki hareket planı ile konum tahmini ve gerçek konum pilot diagramı Şekil 15 ve Şekil 17'de gösterilmiştir.



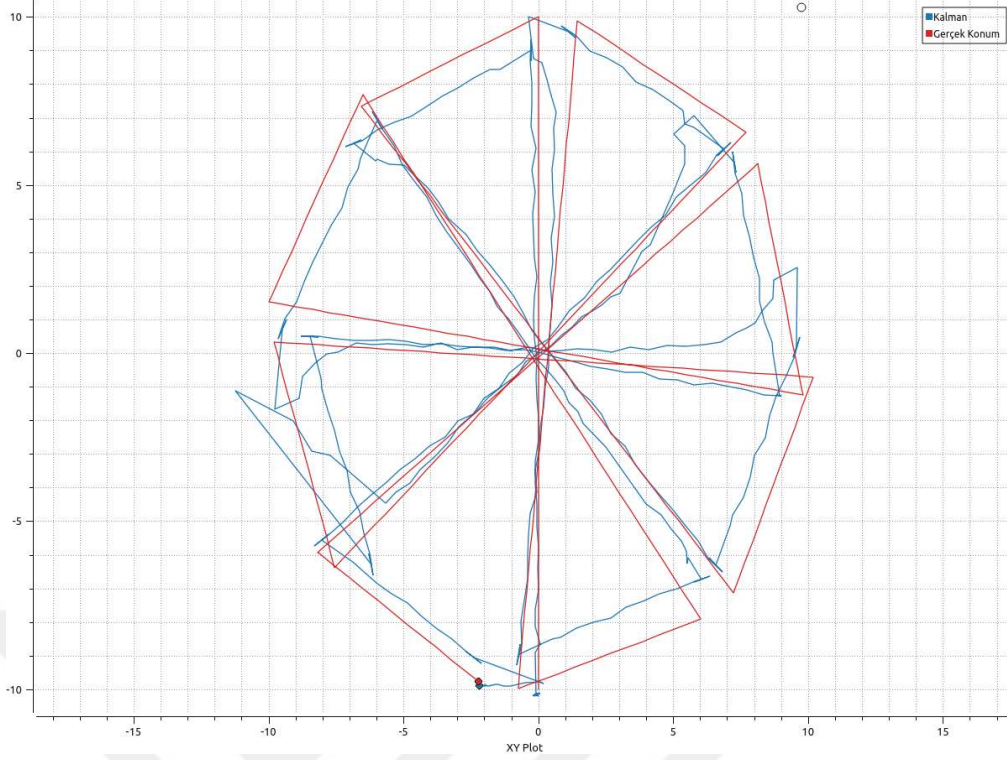
Şekil 14. Tek temas ile konumlandırma çalışma ortamı



Şekil 15. Tek Temas yöntemi ile veri toplamadaki sonar/robot hareket grafiği



Şekil 16. Trilaterasyon-Multilaterasyon çalışma ortamı.



Şekil 17. Trilaterasyon-Multilaterasyon yöntemi ile veri toplamadaki sonar/robot hareket grafiği

Tek temas yöntemi ile konum tahmini yapılacak ortam için nispi olarak kuzey, güney, doğu, batı yönlerini ve ara yönler kullanılacak şekilde bir rota paterni belirlenmiştir (Şekil 15). Sonarın hızı belirli rota bacakları üzerinde 0.5m/sn, diğer rota bacakları üzerinde 0.3m/sn olarak hareketi planlanmıştır. Alan içindeki bir döngüde 190m sonar uçuşu gerçekleşmekte olup, toplamda 27 döngü ile 5130m uçuş sağlanmıştır. Her bir döngü sonunda sonarın başlangıç konumuna dönmesi ile alan içinde bulunan nesnelerin konumları aralarında en az 7m mesafe bulunacak şekilde rastsal olarak tekrar konumlandırılarak her döngüde farklı bir senaryo yaratılmaya çalışılmıştır. Hareket planı içinde temas sağlandığı durumlarda veri kaydı gerçekleştirilerek gerçek konum ile tahminlenen konum arasındaki hata miktarları analiz edilmiştir.

Multilaterasyon yöntemi kullanılarak konum tahmini yapılacak ortamda en fazla veriyi elde edebilmek amacıyla ara ve ana yönleri içerecek şekilde sekizgen bir patern belirlenmiştir (Şekil 17). Paterni tamamlayan her bir döngüde 218m uçuş sağlanmakta ve 23 döngü ile toplamda 5017m uçuş gerçekleştirilmiştir. Her bir döngünün sonlanması esnasında nesnelere aralarında en az 3m mesafe olacak şekilde

rastsal olarak tekrar konumlandırılarak her bir döngü için farklı senaryo yaratılmaya çalışılmıştır. Patern içinde sadece multilaterasyon gerçekleşmesi sonucunda hesaplanan konum tahminleri kayıtlandırılarak gerçek konumları ile arasındaki hata miktarı analiz edilmiştir.

DR yöntemi kullanılarak konum tahmini yapmak ve kayıtlandırmak üzere tek temas yönteminde kullanılan hareket paterni kullanılmıştır. Başlangıç noktasında sonarın bir nesneyi sınıflandırması ve tahmini konumunu elde etmesi ile başlar, hareket başladıktan sonra ortamda bulunan başlangıç nesnesi kaldırılarak hareketin devamında sadece hız ve ivme değerleri kullanılarak hesaplanan konum tahmini kayıtlandırılmaktadır. Gerçek konum verileri arasındaki hata miktarı analiz edilerek Şekil 18’de sunulmuştur.

Her üç yöntem için toplanan ve elde edilen veri miktarları Tablo-4’te gösterilmiştir.

Tablo 4

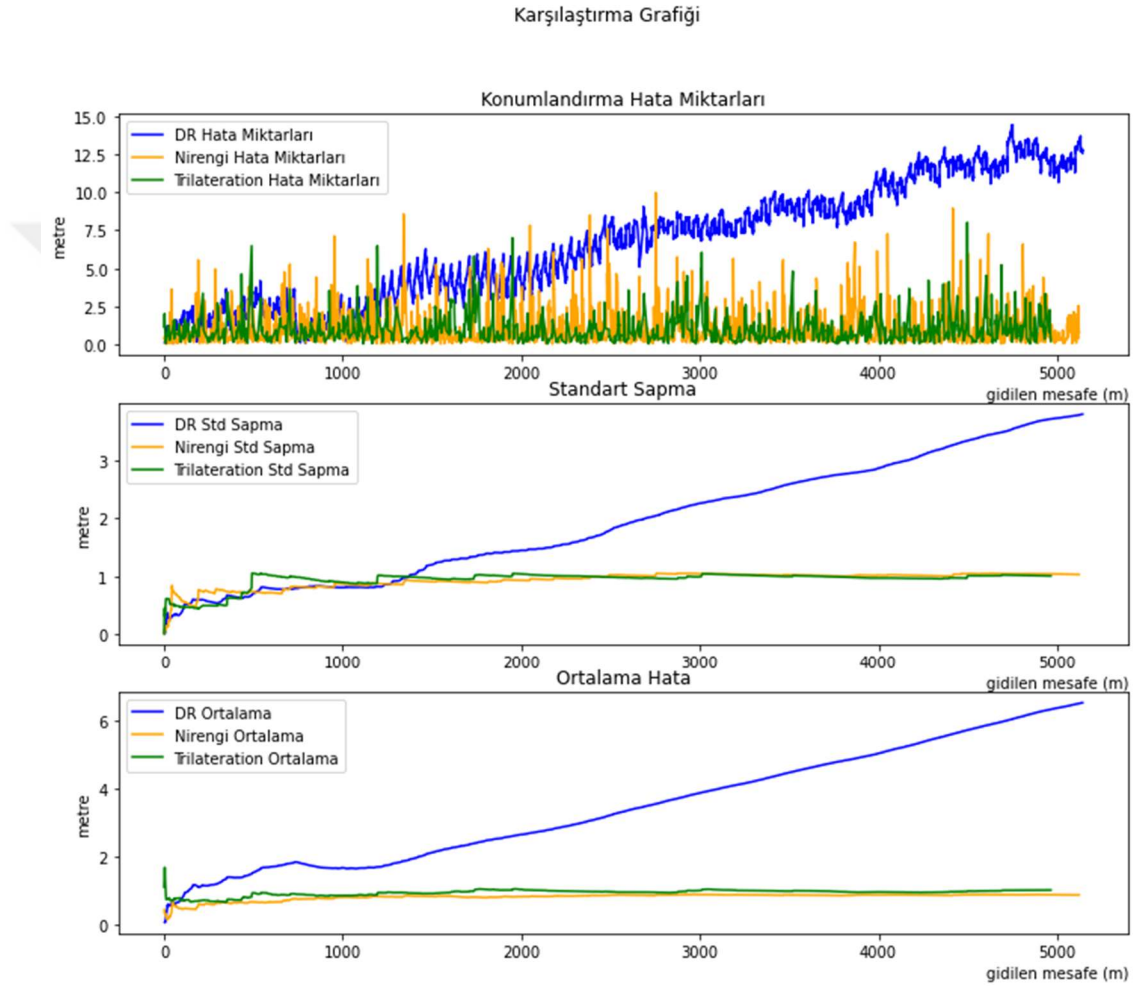
*Kullanılan Yönteme Göre Kayıtlandırılan Veri Miktarı*

Yöntem	Veri Sayısı	Gidilen Mesafe (m)
Tek temas ile konum tahmini	8911	5130
Trilaterasyon-Multilaterasyon ile konum tahmini	2983	5017
Dead Reckoning ile konum tahmini	11973	5130

Tek temas ve trilaterasyon yöntemleri ile konum tahmini yapmak üzere oluşturulan ortamda, YOLOv4 nesne tanıma algoritmasının makine öğrenimi ile hangi konumlarda hatalı sınıflandırma yaptığı değerlendirilmiştir. Gerçek konum ile konum tahmini arasındaki mesafenin 2m ve üstünde olması durumunda YOLOv4’ün yanlış sınıflandırma yaptığı kabul edilmiştir. Buna bağlı olarak tek temas yöntemi kullanıldığında YOLOv4’nun sınıflandırdığı temaslarda 8911 veriden 981 tanesinde hata miktarı 2m ve üstündedir. Dolayısıyla YOLOv4 %11.00 oranında hatalı sınıflandırma yapmış, %89.00 oranında doğru sınıflandırma gerçekleştirmiştir. Trilaterasyon-multilaterasyon yöntemi kullanıldığında 2983 veriden 391 tanesinde gerçek konum ile tahmini konum arasındaki mesafe farkı 2m’den büyüktür. Bahse

konu yöntem ile YOLOv4 %13.11 hata ile sınıflandırma yapmış, doğruluk oranı ise %86.89 oranında gerçekleşmiştir. Makine öğrenimindeki test sonuçlarında %99.66 olan YOLOv4'ün doğruluk oranı, simülasyon ortamındaki sınıflandırmaya bağlı olarak her iki yöntemde ortalama hata oranı %87.94 olarak gerçekleşmiştir.

Toplanan veriler analiz edildiğinde kullanılan yöntemlere göre karşılaştırmalı ortalama konumlandırma hatası ve standart sapma grafiği Şekil-18'de gösterilmiştir.

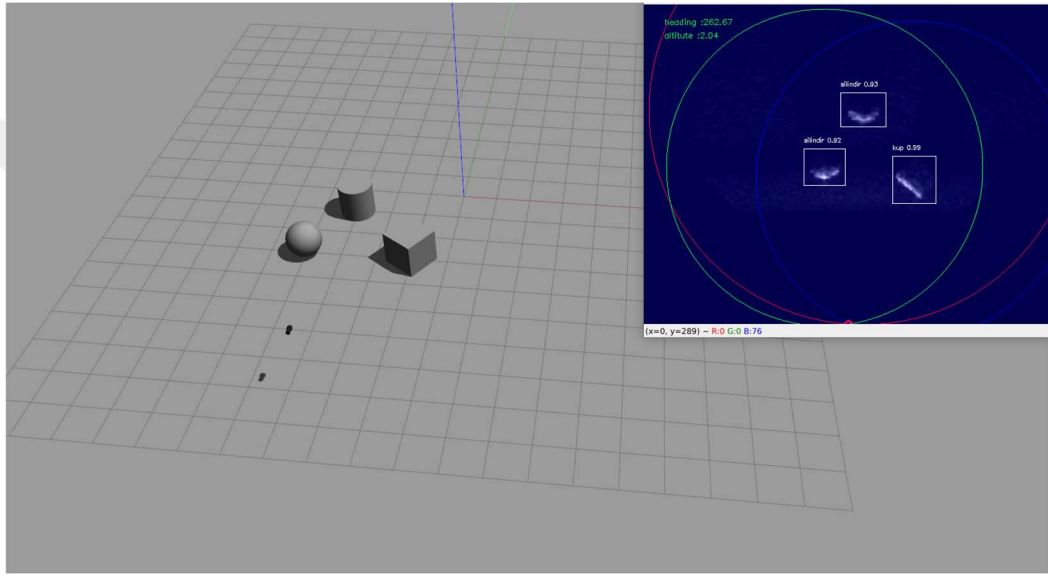


Şekil 18. Hata miktarlarının karşılaştırılması.

Tüm yöntemlere ait veriler incelendiğinde tek temas kullanarak konum tahmini yönteminde ortalama hata miktarı 0.886m, standart sapması 1.024m, trilaterasyon-multilaterasyon yöntemi ortalama hata miktarı 1.030m, standart sapması 0.998m ve hiç temas sınıflandırılması yapılmadığında DR konumlandırmada 5130m hareketine göre ortalama hata miktarı 6.547m, standart sapması 3.808m olarak tespit edilmiştir.

DR konumlandırma hataları akümüle olarak 5000m sürüş mesafesinde 15m'ye kadar çıkmıştır.

Çalışmanın veri toplama aşamasında sonar görüntüsünde objelerin sınıflandırılması gözlemlendiğinde, keskin yansıma veren objeler daha doğru sınıflandırılmıştır. (teker, kafes, palet, artı) Birbirine yakın yapıda bulunan ve daha basit katı modellerde hata yapması daha fazlalaşmıştır. Silindir objesini küre objesinden ayırt edilmesinde problemler gözlenmiş, bazı zamanlarda küp objesi ile de karıştırılmış, dolayısıyla konum tahmininde sapmalar meydana gelmiştir.



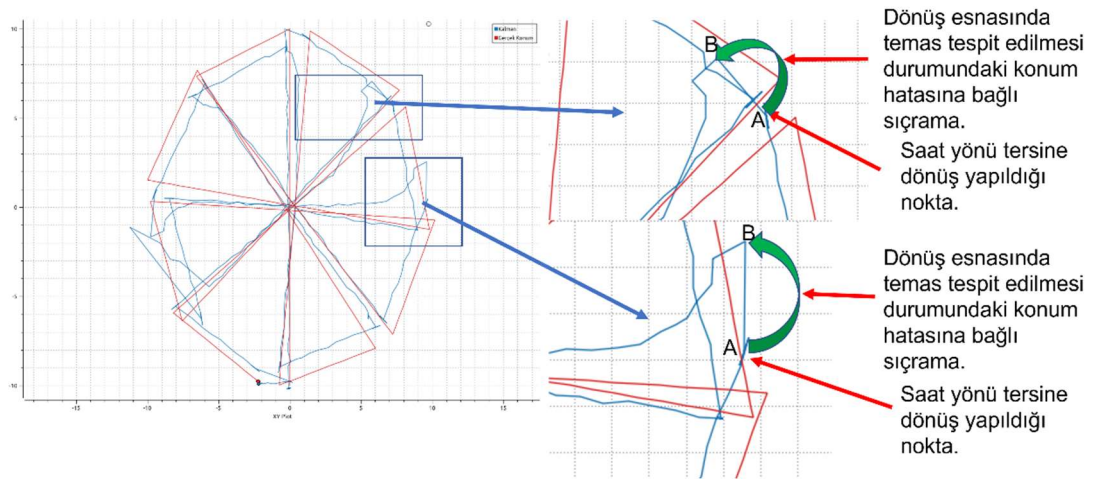
Şekil 19. Hatalı sınıflandırma örneği

Nesnelerin sınıflandırılmasında sonar menziline girmekte veya sonar menzilinden çıkmakta olan nesnelerin sınıflandırılmasında hatalar yaşandığı tespit edilmiştir. Nesnenin yarısı gözükmesi durumunda ve bazı nesnelerin ayrıtlarının birbirlerine benzemesi sebebiyle (küp, dikdörtgen prizması) yanlış sınıflandırmalar gözlemlenmiştir.

Yüzeyleri karmaşık olmayan nesnelere (küp, silindir) yansımalarının sınıflandırılmasında sonarın konumlandırıldığı noktada yer düzlemiyle yaptığı açı, yerden yüksekliği etkili bir faktördür. Tabandan yüksekliği ve açısına bağlı olarak sonarın önünde bir miktar kör, yoğun gürültülü bir saha oluşur. Bu sebeple yakın mesafelerde üst yüzeyleri bulunan ve dik duran silindir ile küpün yansımaları birbirine benzemesinden dolayı hatalı sınıflandırmaların yapıldığı tespit edilmiştir.

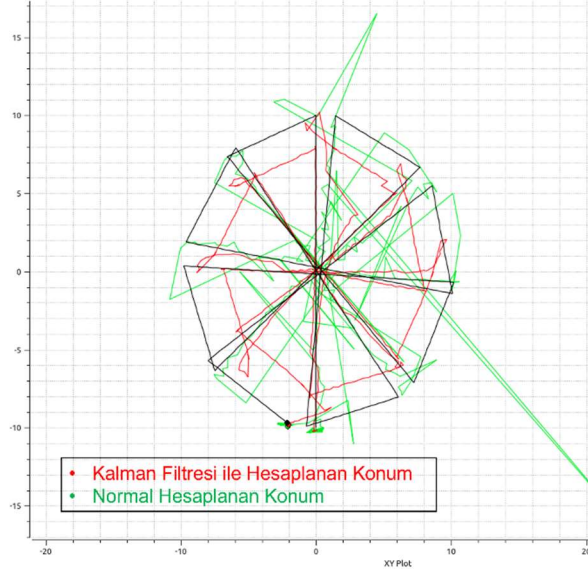
Benzer şekilde sonarın mesafesine bağlı olarak üst yüzeylerinin ayır edilmediği ve sadece kesit yansıması veren durumlarda, dik olarak yerleştirilen bir silindir ile kürenin sınıflandırılmasında hatalar tespit edilmiştir (Şekil-19). Yapay nesnelere arasındaki mesafeye bağlı olarak, ayır edicilik sağlayan gölge üzerinde başka bir nesnenin konumlanmış olması da sınıflandırma açısından olumsuz bir etki yaratmaktadır.

Robot ileri hareketi bulunmadan (bulduğu konumu değiştirmeden) kendi etrafında dönme hareketi yaptığı esnada, sonarda tespit edilen temasların hızlı bir şekilde açı değiştirmesi sonucunda yanlış konum hesaplamaları yaptığı fark edilmiştir (Şekil-20), robot ileri yol kazanmasıyla konum değerlerinin olası değerlere yaklaştığı gözlemlenmiştir. Doğrusal hızın 0.0m/sn olduğu ve açısal hızın sıfırdan büyük olduğu durumlarda (sonarın rota paterni dönüş noktalarında bulunduğu konumda kendi etrafında dönmesi) konum hesaplaması yapılmamış, ölçüm verisi en son alınan değer olarak girdi sağlanarak bahse konu hatalı hesaplama minimize edilmiştir.



Şekil 20. Hatalı konum hesap örneği

Zorlu sualtı ortamında sensörlerden elde edilen verilerdeki hata miktarları ve bu veriler ile elde edilen hesaplamalardaki sonucu optimum düzeyde sağlamak için bu araştırmada doğrusal Kalman süzgeci kullanılmıştır. Otonom sualtı cihazlarında navigasyon kontrolcüsünün hataya düşmemesi veya minimum düzeyde hatalı emir sağlaması açısından Kalman süzgecinin gerekliliği, olması ile olmaması arasındaki kıyaslama Şekil-21’de gösterilmiştir.



Şekil 21. Kalman Süzgeci karşılaştırmalı kullanımı

## Bölüm 5

### Tartışma ve Sonuçlar

Araştırma esnasında toplanan veriler, gözlemler ve elde edilen bulgularla beraber bu çalışmadan çıkarılan sonuçlar aşağıdaki paragraflarda açıklanmıştır.

Bu çalışmada ileri bakış sonarı ile makine öğrenimi yapılmış yapay nesnelerin sualtında tespit edilmesi, eş zamanlı sınıflandırılması ve bu sınıflandırmaya bağlı olarak yapay nesneden referansla robot konumunun hesaplanmasında, klasik karasal robotlar ve sualtı akustik sensör ağlarında kullanılan mesafe ve kerteriz tabanlı trilaterasyon ile nirengi-üçgenleme yaklaşımları kullanılmıştır.

Robotun konumunun hassasiyetle hesaplanabilmesi için bu çalışmada en önemli faktörlerden biri yapay nesnelere için doğru tespit ve doğru sınıflandırma yapılmasıdır. Yapay nesnelerin sonarda verdiği ayırt edilebilir yansıma, nesnelerin arkasında oluşturduğu gölge tanımlanmayı arttıran faktörlerdir. Bu sebeple kullanılması planlanan objelerin tasarımında keskin yansımalar veren ve birbirinde ayırt edilmesini sağlayacak özellikler ile tasarlanması nesne tespitindeki doğruluk oranını arttıracaktır. CNN tabanlı nesne tespit algoritmalarının her geçen gün gelişmesiyle ve sualtı çalışmalarında daha fazla veri seti oluşturulmasıyla çok daha iyi sonuçlar elde edilebilecektir.

Fuchs vd. (2018), yaptığı çalışmada ARACATI veri setleri ile CNN-Softmax ve CNN-SVM sınıflandırma modellerini kullanarak, 5 farklı nesne için ortalama %85 seviyelerinde doğru sınıflandırma yaptıklarını, bir eşik seviyesi sayısının geçilmesinden sonra daha fazla veri olmasının doğruluk oranını çok fazla arttırmayacağını belirtmişlerdir. Bu çalışmadan farklı olarak çalışmamızda 9 farklı nesne için 3477 resim etiketlenerek veri seti oluşturulmuştur. Fuchs vd. (2018), yaptığı çalışmadaki veri setinin yaklaşık 3.5 katından daha fazla veri kullanılmış olup makine öğrenimindeki testte %99.66, simülasyon ortamındaki çalışmalarda eş zamanlı olarak %87.94 oranında doğru sınıflandırma yaptığı tespit edilmiştir. Bu sonuçlar ile veri setindeki veri artışı ile sınıflandırma doğruluk oranının da arttırdığı gözlemlenmiştir.

Buna benzer olarak Horimoto vd. (2018), yaptığı çalışmada su kaplumbağalarını ileri bakış sonarında tespit edilmesi amacıyla havuz ortamında gerçek kaplumbağa ile toplam 541 adet sonar görüntüsü ile veri seti oluşturulmuştur. Bu veri seti YOLOv2 algoritmasının eğitimi için kullanılmış, gerçek ortamda yapılan testlerde 649 görüntünün, 405 adedinde doğru sınıflandırma yapılmış, 53 görüntüde kaplumbağa olmasına karşın tespit edilememiş ve 245 tane yanlış sınıflandırma gerçekleşmiştir. %50'ye yakın yanlış tespit gerçekleşmiş olup yaptığımız bu araştırmada simülasyon ortamında ortalama %12.05 hatalı sınıflandırma yapılmıştır. Aradaki ciddi farkın, veri setinin oluşturulduğu simülasyon ile gerçek ortamdaki gürültü ve ortam şartlarının farklı olması, nesnelerin sabit veya hareketli olması ayrıca veri sayısının az olduğu değerlendirilmektedir. Buna bağlı olarak sınıflandırma için oluşturulacak veri setlerinin, robotun kullanılacağı ortamdan toplanması veya elde edilmesi ile tespit ve sınıflandırmada daha doğru sonuçlar elde edileceği tahmin edilmektedir.

Y. Lee vd. (2017), yaptığı çalışmada, yüksek çözünürlüklü sualtı görüntüleme sonarı ile yapay nesnelere sınıflandırması üzerine görüntü özellik tespit algoritması (Hough circle transform) kullanmış, sadece dairevi yapay nesnelere tanınmasında başarılı sonuçlar elde etmişler, ancak boru hatları, mayın tespiti veya doğal sualtı nesnelere sınıflandırılmasında halen zorluklar içereceğini belirtmişlerdir. Yaptığımız bu araştırmada sadece dairevi olmamakla 9 farklı nesne modeli kullanılmış, makine öğrenimi sonrasında, yapılan sınıflandırma testlerinde olumlu sonuçlar elde edilmiştir.

Sınıflandırma ile ilgili olarak nesnelere sonar menziline girmesi veya menzilden çıkmak üzere olduğu durumlarda yansımalarının yarısı veya bir kısmı gözükmemektedir. Buna bağlı olarak da yanlış sınıflandırma yapılması daha olası hale gelmektedir. Yanlış sınıflandırmanın yapılmasını minimuma indirmek amacıyla makine öğreniminde bu nesnelere yarım veya eksik görüntülerinin de veri setleri içinde bulunması doğru sınıflandırma yapılması adına daha da etkili olacağı değerlendirilmektedir.

Sualtı robotlarının optimum navigasyonu konumunun minimum hata payı ile hesaplanmasına bağlıdır. Literatürde sonar tabanlı olarak tespit edilen yapay nesnelere referans ile mesafe ve yönelime bağlı konum tahmini konusunda sualtında yapılan benzer çalışmaya rastlanmamış ancak karasal ortamda yapılan araştırmalarda benzer yaklaşımlar sunan kaynaklar tespit edilmiştir. Norrdine (2012), çalışmasında kapalı ortamlarda navigasyon sağlayacak mesafe tabanlı konumlandırma konusunda laterasyon problemine cebirsel çözüm yaklaşımı sunmuştur. Norrdine (2012), bu çalışmasında referans noktalarından ultra geniş bant elektromanyetik sinyaller üzerinden mesafe ölçümleme ile konum tahmini yapmıştır. Bu araştırmada benzer şekilde, sonarda tespit edilen ve sınıflandırılması yapılan konumu belli yapay nesnelere mesafe ölçümleri ile laterasyon kullanılarak robotun konumu hesaplanmıştır. Karasal ortamlarda referans noktalarından ölçülen mesafe miktarları, sualtındaki ölçümlere göre daha küçük hatalar ile yapılabilmekte, sualtı şartlarında doğal gürültüler sebebiyle bu ölçümler karadaki ölçümlere oranla daha hatalı olabilmektedir. Ayrıca karasal ortamdaki aynı yaklaşımlarda referans noktalarının sınıflandırılması gibi problem içermediğinden sonar tabanlı nesne tespit ve sınıflandırılması, bu araştırmada ayrı bir adım daha oluşturmaktadır. Norrdine (2012), çalışmasındaki mesafe hataları sabit test noktaları için 1.47-13.09cm aralığında gerçekleşmiştir. Ayrıca hareketli nesnelere konum tahmini yapılmamıştır. Bu araştırmada ise mesafe ölçüm hatalarına değil, ölçülen mesafeler ile konum tahminindeki hata miktarlarına odaklanılmıştır. Sualtı şartları göz önüne alındığında hareketli robot konumunun eş zamanlı hesaplanmasındaki hata miktarı ortalama 1.030m olarak gerçekleşmiştir.

Nirengi/üçgenleme ile sonarda tespit ve sınıflandırılması yapılan nesnelere mesafe ve açısına (kerteriz) bağlı olarak konum tahmini basit trigonometrik işlemler ile cebirsel olarak yapılmıştır. Simülasyon ortamında eş zamanlı elde edilen sonuçlara bakıldığında ortalama mesafe hata miktarı 0.886m olarak gerçekleşmiştir.

DR olarak gerçekleştirilen yöntemde hata miktarlarının hareket süresine bağlı olarak birikerek arttığı açıkça görülmekte olup bunun yanında kullanılan nirengi ve trilaterasyon yöntemlerinde sınıflandırılması yapılan yapay nesnelere konumlandırılması ile biriken konum tahmini hata miktarlarını düzeltmekte ve minimize etmektedir. Bunun sonucunda görülmektedir ki, ataletsel ve hız

sensörlerinin yanında diğer sensörlerden alınan verilerin belirli normlarda kullanılması ile hata miktarları ciddi oranda düşürülebileceği görülmüştür.

Görüntü işleme yüksek işlemci gücüne ihtiyaç duyması ve hesaplama sürelerinin artması sebebiyle düğümler arasındaki gecikme

lerin önlenmesi veya optimum duruma getirilebilmesi için asenkron işlemler yürütecek yapılar kullanılmasının gecikmelere bağlı hesap hatalarını en aza indirebileceği değerlendirilmektedir. Ayrıca sistem üzerinde farklı çalışma frekanslarına sahip sensörlerden alınan verilerin kullanılmasında zaman senkronizasyonu (eşleme) sağlanarak, zaman paketlerinin kullanılması ile aynı zamana ait verilerin işleme sokulmasıyla hata miktarlarının düşeceği öngörülmektedir. Bununla beraber yüksek işlem gücü gerektiren yapılarıdaki gecikme miktarlarına bağlı olarak sensörlerin frekans seviyelerini aynı şekilde minimum seviyede tutmak da sensörlerden eş zamanlı bilgi elde etmeyi sağlayacaktır.

Sualtının zorlu şartlarında sensör verilerinden gelen gürültülü bilgiler sebebiyle hesaplama hatalarının optimum düzeyde işlem görmesi açısından Kalman süzgeci algoritmasının iyi düzeyde çalıştığı gözlemlenmiştir (Şekil 21)

Yapılan bu araştırmadaki elde edilen veriler ile; maliyetleri yüksek akustik sualtı konumlandırma sistemlerine ihtiyaç duyulmadan belirli bir alan içinde çalışabilecek sualtı otonom veya uzaktan kumandalı cihazların konumunun tespit edilmesi maksadıyla maliyet etkin yaklaşım sunulmuş ve verilere bakıldığında alınan sonuçlar ümit vericidir.

Sualtı otonom cihazlarının sualtında navigasyonunun sağlanması açısından gelecekte yapılacak araştırmalarda, veri setlerinin gerçek sonar ile çalışma ortamında toplanmasının, sualtında daha büyük bir çalışma alanında işlem yapılması durumunda, sonarda birbirinden ayırt edilebilen çok daha fazla sayıda yapay nesnelerinin tasarlanmasına, gelişen teknolojilere paralel olarak ileri bakış sonarlarının 360° görüntülemesi ile sonar tabanlı navigasyon problemlerinin çok daha etkin bir şekilde çözülebileceği düşünülmektedir.

Sualtı otonom cihazlarında doğruluğu yüksek optimum konumlandırma sağlanmasıyla, sonarda alınacak her bir görüntü çerçevesinin mozaiklenmesi ile

sualtı haritalarının oluşturulması, bu haritalar üzerinde çok daha etkin navigasyon sağlanması geçmişten farklı olarak ileriki süreçlerde çok daha olası görülmektedir. İleri bakış sonarlarının teknolojisindeki ilerlemeler ile çok daha yüksek frekansta çalışan, çok daha yüksek çözünürlükte görüntüleme olanağı sunan sonarların maliyeti ulaşılabilir düzeylere gelmesi ile sualtı arařtırmalarında evrensel olarak çok daha iyi bir düzeye ulaşılması kaçınılmazdır.



## KAYNAKLAR

- Aktaş, A. (2020). *Derin Öğrenme Yöntemleri ile Görüntü İşleme Uygulamaları*. Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Andrews, F. A. (1970). Underwater Navigation. *Hydronautics*, 229-276. doi:10.1016/B978-0-12-639150-3.50010-4
- Aulinas, J., Carreras, M., Llado, X., Salvi, J., Garcia, R., Prados, R. ve Petillot, Y. R. (2011). Feature Extraction for Underwater Visual SLAM. *OCEANS 2011 IEEE - Spain* içinde (ss. 1-7). IEEE. doi:10.1109/Oceans-Spain.2011.6003474
- Bergert, F. B. (1957). The Nature of Doppler Velocity Measurement. *IRE Transactions on Aeronautical and Navigational Electronics ( Volume: ANE-4, Issue: 3, Sept. 1957)*. doi:10.1109/TANE3.1957.4201534
- Bochkovski, A., Wang, C.-Y. ve Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. <http://arxiv.org/abs/2004.10934> adresinden erişildi.
- Bucci, A., Zacchini, L., Franchi, M., Ridolfi, A. ve Allotta, B. (2022). Comparison of Feature Detection and Outlier Removal Strategies in a Mono Visual Odometry Algorithm for Underwater Navigation. *Applied Ocean Research*, 118. doi:10.1016/j.apor.2021.102961
- Carrasco, P. L. N., Bonin-Font, F. ve Codina, G. O. (2016). Stereo Graph-SLAM for Autonomous Underwater Vehicles. *Advances in Intelligent Systems and Computing* içinde (C. 302, ss. 351-360). Springer Verlag. doi:10.1007/978-3-319-08338-4\_26
- Chatpadol, K. ve Itthisek, N. (2017). Acoustic Underwater Positioning System Using Fast Fourier Transform and Trilateration Algorithm. *14th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)* içinde (ss. 521-524).

- Choi, W. S., Olson, D. R., Davis, D., Zhang, M., Racson, A., Bingham, B., ... Herman, J. (2021). Physics-Based Modelling and Simulation of Multibeam Echosounder Perception for Autonomous Underwater Manipulation. *Frontiers in Robotics and AI*, 8, 1. doi:10.3389/frobt.2021.706646
- Christensen, J. H., Mogensen, L. V., Galeazzi, R. ve Andersen, J. C. (2018). Detection, Localization and Classification of Fish and Fish Species in Poor Conditions using Convolutional Neural Networks. *IEEE/OES Autonomous Underwater Vehicle Workshop (AUV)*, içinde (ss. 1-6). Porto, Portugal: IEEE. doi:10.1109/AUV.2018.8729798
- Cong, Y., Gu, C., Zhang, T. ve Gao, Y. (2021). Underwater Robot Sensing Technology: A Survey. *Fundamental Research*, 1(3), 337-345. doi:10.1016/J.FMRE.2021.03.002
- Dylan, R. ve Timothy, A. W. (2012). Doppler Velocity Log Theory and Preliminary Considerations for Design and Construction. *Proceedings of IEEE Southeastcon* içinde (ss. 1-7). Orlando, FL, USA., doi:10.1109/SECon.2012.6196918
- El-Sheimy, N. ve Youssef, A. (2020). Inertial Sensors Technologies for Navigation Applications: State of The Art and Future Trends. *Satellite Navigation*, 1(2). doi:10.1186/s43020-019-0001-5
- Erol Kantarci, M., Mouftah, H. T. ve Oktug, S. (2011). A Survey of Architectures and Localization Techniques for Underwater Acoustic Sensor Networks. *IEEE Communications Surveys and Tutorials*, 13(3), 487-502. doi:10.1109/SURV.2011.020211.00035
- Ferreira, F., Djapic, V., Micheli, M. ve Caccia, M. (2015). Forward Looking Sonar Mosaicing for Mine Countermeasures. *Annual Reviews in Control*, 40, 212-226. doi:10.1016/j.arcontrol.2015.09.014
- Fuchs, L. R., Gällström, A. ve Folkesson, J. (2018). Object Recognition in Forward Looking Sonar Images Using Transfer Learning. *IEEE/OES Autonomous Underwater Vehicle Workshop (AUV)* içinde (ss. 1-6). doi:10.1109/AUV.2018.8729686

- Galceran, E., Djapic, V., Carreras, M. ve Williams, D. P. (2012). A Real-Time Underwater Object Detection Algorithm for Multi-Beam Forward Looking Sonar. *IFAC Proceedings Volumes*, 45(5), 306-311. doi:10.3182/20120410-3-PT-4028.00051
- Horimoto, H., Kofuji, K., Maki, T. ve Kofuji, K. (2018). Autonomous Sea Turtle Detection Using Multi-Beam Imaging Sonar: Toward Autonomous Tracking. *IEEE/OES Autonomous Underwater Vehicle Workshop (AUV)* içinde (ss. 1-4). Porto, Portugal: IEEE. doi:10.1109/AUV.2018.8729723
- Karimanzira, D., Renkewitz, H., Shea, D. ve Albiez, J. (2020). Object detection in sonar images. *Electronics (Switzerland)*, 9(7), 1-16. doi:10.3390/ELECTRONICS9071180
- Kebkal, K. G. ve Mashoshin, A. I. (2017). AUV acoustic positioning methods. *Gyroscopy and Navigation*, 8(1), 80-89. doi:10.1134/S2075108717010059
- Lee, P. M., Jun, B. H., Kim, K., Lee, J., Aoki, T. ve Hyakudome, T. (2007). Simulation of an Inertial Acoustic Navigation System With Range Aiding for an Autonomous Underwater Vehicle. *IEEE Journal of Oceanic Engineering*, 32(2), 327-345. doi:10.1109/JOE.2006.880585
- Lee, S., Park, B. ve Kim, A. (2018, 18 Ekim). Deep Learning from Shallow Dives: Sonar Image Generation and Training for Underwater Object Detection. *arXiv preprint arXiv:1810.07990*. <http://arxiv.org/abs/1810.07990> adresinden erişildi.
- Lee, Y., Choi, J., Ko, N. Y. ve Choi, H. T. (2017). Probability-based recognition framework for underwater landmarks using sonar images. *Sensors (Switzerland)*, 17(9). doi:10.3390/s17091953
- Lee, Y., Kim, T. G. ve Choi, H. T. (2014). A New Approach of Detection and Recognition for Artificial Landmarks from Noisy Acoustic Images. *Advances in Intelligent Systems and Computing* içinde (C. 274, ss. 851-858). Springer Verlag. doi:10.1007/978-3-319-05582-4\_75

- Norrdine, A. (2012). An Algebraic Solution to the Multilateration Problem. *International Conference on Indoor Positioning and Indoor Navigation* içinde (C. 13, ss. 15-18). Sydney.
- Pande, S. ve Ibwe, K. S. (2021). Robust Trilateration Based Algorithm for Indoor Positioning Systems. *Tanzania Journal of Science*, 47(3), 1195-1210. doi:10.4314/tjs.v47i3.28
- Paull, L., Saeedi, S., Seto, M. ve Li, H. (2014). AUV Navigation and Localization: A Review. *IEEE Journal of Oceanic Engineering*, 39(1), 131-149. doi:10.1109/JOE.2013.2278891
- Sahoo, A., Dwivedy, S. K. ve Robi, P. S. (2019). Advancements in The Field of Autonomous Underwater Vehicle. *Ocean Engineering*, 181, 145-160. doi:10.1016/j.oceaneng.2019.04.011
- Valdenegro-Toro, M. (2017). Best Practices in Convolutional Networks for Forward-Looking Sonar Image Recognition. *OCEANS* içinde (ss. 1-9). UK. doi:10.1109/OCEANSE.2017.8084987
- Wang, L., Halstead, D. R., Monte, T. D., Khan, J. A., Brunner, J. ve Kits van Heyningen, M. A. (2019). Low-cost, High-end Tactical-grade Fiber Optic Gyroscope Based on Photonic Integrated Circuit. *IEEE International Symposium on Inertial Sensors and Systems (INERTIAL)* içinde (ss. 1-2). Naples, FL, USA: IEEE. doi:10.1109/ISS.2019.8739700
- Wang, Y., Ma, X., Wang, J. ve Wang, H. (2020). Pseudo-3D Vision-Inertia Based Underwater Self-Localization for AUVs. *IEEE Transactions on Vehicular Technology*, 69(7), 7895-7907. doi:10.1109/TVT.2020.2993715
- Wu, Y., Ta, X., Xiao, R., Wei, Y., An, D. ve Li, D. (2019). Survey of Underwater Robot Positioning Navigation. *Applied Ocean Research*", 90, 1-15. doi:10.1016/j.apor.2019.06.002
- Yang, D., Ai, H., Liu, J. ve He, B. (2022). Absolute Scale Estimation for Underwater Monocular Visual Odometry Based on 2-D Imaging Sonar. *Measurement*:

*Journal of the International Measurement Confederation*, 190.  
doi:10.1016/j.measurement.2021.110665

Yang, X., Zhao, J., Zhang, H., Dai, C., Zhao, L., Ji, Z. ve Ganchev, I. (2022). Remote Sensing Image Detection Based on YOLOv4 Improvements. *IEEE Access*, 10, 95527-95538. doi:10.1109/ACCESS.2022.3204053

Zhang, B., Ji, D., Liu, S., Zhu, X. ve Xu, W. (2023, 1 Nisan). Autonomous Underwater Vehicle navigation: A review. *Ocean Engineering*. Elsevier Ltd. doi:10.1016/j.oceaneng.2023.113861

Zhang, L., Liu, L. ve Zhang, L. (2020). Research on Position Correction Method for AUV Large Depth Navigation Based on Ranging Positioning. *Computer Communications*, 150, 747-756. doi:10.1016/j.comcom.2019.11.038

Zhou, Y. (2009). An efficient least-squares trilateration algorithm for mobile robot localization. *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems, IROS 2009*, 3474-3479. doi:10.1109/IROS.2009.5354370