

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI**

**SU ALTI OTONOM ARAÇLARDA NAVİGASYON VE YOL
PLANLAMA ÇÖZÜMLERİ**

YÜKSEK LİSANS TEZİ

METİN BAYDARAKÇI

DENİZLİ, ARALIK - 2023

T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



SU ALTI OTONOM ARAÇLARDA NAVİGASYON VE YOL
PLANLAMA ÇÖZÜMLERİ

YÜKSEK LİSANS TEZİ

METİN BAYDARAKÇI

DENİZLİ, ARALIK - 2023

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu çalışmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan çalışmalara atfedildiđine beyan ederim.

Metin BAYDARAKÇI

ÖZET

**SU ALTI OTONOM ARAÇLARDA NAVİGASYON VE YOL
PLANLAMA ÇÖZÜMLERİ
YÜKSEK LİSANS TEZİ
METİN BAYDARAKÇI
PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: DR. ÖĞR. Ü. H. HİLAL EZERCAN KAYIR)**

DENİZLİ, ARALIK - 2023

Teknolojinin hızlı ilerlemesi, insansız su altı sistemlerine olan ilgiyi artırmıştır. Bu sistemler, keşif, gözlem ve su altı operasyonları gibi çeşitli alanlarda kullanılmaktadır. Ancak, su altındaki konum belirleme işlemi, hava ve kara sistemlerinde yaygın olarak kullanılan GPS teknolojisi ile mümkün değildir.

Bu ihtiyaca cevap olarak geliştirilen insansız su altı araçları, konumlarını belirlemek için akustik yöntemler veya su yüzeyindeki istasyonlardan alınan GPS referansları ile su altı sensörleri kullanarak çalışırlar. Açık denizlerde yapılan konumlandırma çözümleri oldukça pahalı sistemlerdir. Kapalı bir alan içinde bu tarz sistemler yerine daha uygulanabilir yöntemler yapılması gerekmektedir.

Bu çalışma, iki aşamalı bir süreci içermektedir. İlk aşamada, su altı aracı bir kapalı havuz ortamına bırakılır ve üzerinde bulunan 360 derece tarama sonarı ile çevresini tarar. Elde edilen tarama verileri, K-means algoritması kullanılarak sınıflandırılır ve köşe bulma yöntemi ile aracın havuz içindeki konumu belirlenir. Daha sonra, aracın üzerinde bulunan mesafe sensörü verileri, makine öğrenme algoritmaları kullanılarak modellenir. Yapılan modellemede, Doğrusal Regresyon, KNN, Karar Ağacı ve Rastgele Orman algoritmaları arasında en iyi sonuçları Rastgele Orman algoritması verir. Bu modelle, su altı aracının hareketi sırasında kat ettiği mesafe tahmin edilebilmektedir.

ANAHTAR KELİMELER: Su Altı Otonom Araçlar, Makine Öğrenmesi, Akustik Navigasyon, Ataletsel Navigasyon

ABSTRACT

NAVIGATION AND PATH PLANNING SOLUTIONS FOR UNDERWATER AUTONOMOUS VEHICLES

MSC THESIS

METİN BAYDARAKÇI

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE

ELECTRICAL AND ELECTRONICS ENGINEERING

(SUPERVISOR: ASSIST. PROF. DR. H. HİLAL EZERCAN KAYIR)

DENİZLİ, DECEMBER 2023

The rapid advancement of technology has increased interest in unmanned underwater systems. These systems are utilized in various fields such as exploration, observation, and underwater operations. However, the process of determining the location underwater is not feasible with the widely used GPS technology in air and land systems.

In response to this need, unmanned underwater vehicles have been developed to determine their locations using acoustic methods or GPS references obtained from surface stations in conjunction with underwater sensors. Positioning solutions in open seas can be expensive, prompting the exploration of more practical alternatives within enclosed spaces.

This study involves a two-stage process. In the first stage, the underwater vehicle is placed in a closed pool environment and scans its surroundings using a 360-degree scanning sonar. The acquired scanning data is classified using the K-means algorithm, and the vehicle's position within the pool is determined using a corner detection method. Subsequently, the data from the distance sensor on the vehicle is modeled using machine learning algorithms. In the modeling process, Random Forest algorithm yielded the best results among Linear Regression, KNN, Decision Tree, and Random Forest algorithms. This model allows the prediction of the distance traveled by the underwater vehicle during its movement.

KEYWORDS: Underwater Autonomous Vehicles, Machine Learning, Acoustic Navigation, Inertial Navigation

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	v
TABLO LİSTESİ	vii
SEMBOL LİSTESİ	viii
KISALTMALAR LİSTESİ	ix
ÖNSÖZ.....	x
1. GİRİŞ.....	1
1.1 Genel Bilgiler	1
1.2 Literatür Özeti	3
1.3 Tezin Amacı	8
2. İNSANSIZ SU ALTI SİSTEMLERİ	9
2.1 İSAA Matematiksel Modelleme.....	10
2.2 Navigasyon Sistemleri.....	15
2.2.1 Ataletsel Navigasyon	16
2.2.2 Akustik Navigasyon.....	18
2.2.3 Jeofiziksel Navigasyon Sistemi	21
3. SINIFLANDIRMA VE KÖŞE ÇIKARMA ALGORİTMALARI.....	22
3.1 Harris-Stephens Köşe Çıkarma Algoritması	22
3.2 Shi-Tomasi Köşe Çıkarma Algoritması	24
3.3 Förstner Köşe Tespiti	25
3.4 K-means Algoritması	27
4. ÖĞRENME ALGORİTMALARI	30
4.1 Denetimsiz Öğrenme	31
4.2 Takviyeli Öğrenme	31
4.3 Denetimli Öğrenme	31
4.3.1 Doğrusal Regresyon Algoritması.....	32
4.3.2 K-NN Algoritması	33
4.3.3 Karar Ağacı Algoritması.....	35
4.3.4 Rastgele Orman Algoritması	37
4.4 Öğrenme Algoritmalarında Değerlendirme Kriterleri.....	38
4.4.1 Ortalama Kare Hatası (MSE).....	39
4.4.2 Kök Ortalama Kare Hatası (RMSE)	39
4.4.3 Ortak Mutlak Hata (MAE).....	40
4.4.4 R² Determinasyon Katsayısı	40
5. YÖNTEM.....	42
6. UYGULAMA VE ÇIKTILAR	44
6.1 Tez Çalışmasında Kullanılan Malzemeler.....	44
6.1.1 Tarama Sonarı	44
6.1.2 Ping Sonar Altimeter and Echosounder	46
6.1.3 Basınç Sensörü.....	48
6.1.4 Pixhawk	49
6.1.5 Arduino Mega Pro	50
6.1.6 NVIDIA Jetson Nano 4gb	51

6.1.7	Pusat Su Altı Aracı	53
6.2	Tez Çalışması Uygulaması	54
6.2.1	Köşe Bulma ve Konumlandırma İşlemi.....	55
6.2.2	Yol Tahmin Çalışması	64
6.2.2.1	Veri Setinin Belirlenmesi.....	64
6.2.2.2	Veri Setlerinin Sınıflandırılması	66
6.2.2.3	Model Çıktıları Ve Sonuçların Değerlendirilmesi	66
6.2.2.3.1	Doğrusal Regresyon Algoritması Sonuçları	66
6.2.2.3.2	KNN Algoritması Sonuçları	67
6.2.2.3.3	Karar Ağaçları Algoritması Sonuçları	68
6.2.2.3.4	Rastgele Orman Algoritması Sonuçları	69
6.2.2.4	Algoritma Tahmin Deney Çalışması.....	70
7.	SONUÇLAR VE ÖNERİLER.....	72
8.	KAYNAKLAR.....	74
9.	ÖZGEÇMİŞ	77

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: ULİSAR Projesi Su Altı Aracı (Leblebicioğlu 2010).	3
Şekil 2.1: İnsansız Su Altı Sistemlerinin Sınıflandırılması.	9
Şekil 2.2: İlk insansız su altı aracı örneği POODLE (Jehangir 2019).	10
Şekil 2.3: 6-DoF Eksen Hareketleri.	11
Şekil 2.4: PUSAT Lura su altı test aracı ve Dünya referans koordinat sistemi.	11
Şekil 2.5: Su altı navigasyon sistemi sınıflandırılması.	16
Şekil 2.6: DVL sensör ile konumlandırma ve hareket (Robotics 2023).	17
Şekil 2.7: LBL Navigasyon Sistemi (Gode 2015).	18
Şekil 2.8: Kısa Tabanlı Hat (SBL) Navigasyon Sistemi (Ardusab 2023).	19
Şekil 2.9: Ultra Kısa Tabanlı Hat (USBL) Navigasyon Sistemi (Ardusub 2023).	20
Şekil 3.1: Shi-Tomasi ile Harris-Stephen dedektörü (Gandhi 2018).	25
Şekil 3.2: Förstner Köşe Tespiti (Wikipedia 2012).	27
Şekil 3.3: K-means algoritma akış diyagramı.	29
Şekil 4.1: Makine Öğrenimi Çeşitleri.	30
Şekil 4.2: Doğrusal Regrasyon Modeli Çıktısı (Şener 2020).	32
Şekil 4.3: KNN yapısı (Tafralı 2022).	34
Şekil 4.4: Karar Ağacı Yapısı.	36
Şekil 4.5: Rastgele Orman yapısı.	38
Şekil 6.1: PİNG360 Tarama Sonarı.	44
Şekil 6.2: Havuz ortamında örnek bir tarama çıktısı.	45
Şekil 6.3: Tarama verileri ayarları.	46
Şekil 6.4: Su altı mesafe sonarı.	46
Şekil 6.5: Örnek bir mesafe ölçümü.	47
Şekil 6.6: Su altı basınç (derinlik) sensörü.	48
Şekil 6.7: Pixhawk hareket kontrol kartı.	49
Şekil 6.8: Arduino mega pro mikrodenetleyici.	50
Şekil 6.9: NVIDIA Jetson Nano 4gb developer kit.	52
Şekil 6.10: PUSAT takımı su altı test aracı.	53
Şekil 6.11: Kontrol Sistemi Şematik Yapısı.	54
Şekil 6.12: Ping360 tarama sonucu kartezyen koordinat sisteminde gösterimi.	55
Şekil 6.13: a) Kutupsal Kordinat Sistemine Dönüştürülmüş tarama verileri b) Normalizasyon işlemi sonrası.	56
Şekil 6.14: Tarama mesafesine göre oranlanmış veriler.	57
Şekil 6.15: K-means kümeleme ve merkezlerin belirlenmesi.	58
Şekil 6.16: Bulunan Köşelerin Gösterimi.	60
Şekil 6.17: Büyük Havuz Test Ortamı Tarama.	61
Şekil 6.18: Büyük Havuz Test Ortamı İlerleme.	61
Şekil 6.19: Köşe Bulma Uygulaması 1. Kısım.	62
Şekil 6.20: Köşe Bulma Uygulaması 2. Kısım.	63
Şekil 6.21: Aracın Kontrol Yönleri.	65
Şekil 6.22: Havuz Test Ortamı.	66
Şekil 6.23: Doğrusal Regresyon Algoritması Eğitim Modeli Sonuçları.	67

Şekil 6.24: KNN Algoritması Eğitim Modeli Sonuçları.	68
Şekil 6.25: Karar Ağacı Algoritması Eğitim Modeli Sonuçları.	69
Şekil 6.26: Rastgele Orman Algoritması Eğitim Modeli Sonuçları.	70
Şekil 6.27: Aracın Hareketinin Karşılaştırılması Uygulama Sonucu:1.	71
Şekil 6.28: Aracın Hareketinin Karşılaştırılması Uygulama Sonucu:2.	71

TABLO LİSTESİ

Sayfa

Tablo 5.1: Köşe Tespiti Algoritması Akış Diyagramı.	42
Tablo 5.2: Tahmin Algoritması Akış Diyagramı.	43
Tablo 6.1: Ping Sonar teknik özellikleri.....	47
Tablo 6.2: Basınç(derinlik) sensörü teknik özellikleri.....	48
Tablo 6.3: Pixhawk Teknik Özellikleri.....	50
Tablo 6.4: Mikrodenetleyici teknik özellikleri.....	51
Tablo 6.5: NVIDIA Jetson Nano teknik özellikleri.....	52
Tablo 6.6: Tahmin Modeli İçin Giriş ve Çıkış Değerleri.....	64
Tablo 6.7: Doğrusal Regresyon Modeli Değerlendirmesi.	67
Tablo 6.8: KNN Modeli Değerlendirmesi.....	68
Tablo 6.9: Karar Ağacı Modeli Değerlendirmesi.....	69
Tablo 6.10: Rastgele Orman Modeli Değerlendirmesi.	70

SEMBOL LİSTESİ

$\mathbf{C}(\mathbf{v})$: Coriolis ve merkezkaç matrisini
$\mathbf{D}(\mathbf{v})$: Hidrodinamik sönümlenme matrisini
$\mathbf{G}(\boldsymbol{\eta})$: Moment vektörü
$\boldsymbol{\tau}$: Su altı aracı sistem kontrol girişleri
$\boldsymbol{\tau}_{d'}$: Dalga etkileri, akıntı veya çevresel bozulma nedeni ile ortaya çıkan dış etkiler
$\boldsymbol{\eta}$: Aracın konum ve yönelme vektörü
$\mathbf{j}(\boldsymbol{\eta})$: $\boldsymbol{\eta}$ 'nin konum ve yönelmesine bağlı olarak değişen bir Jakobiyen matrisidir
\mathbf{v}^n	: Aracın Dünya referans koordinat sistemine göre hızı
$\mathbf{R}_b^n(\boldsymbol{\Theta})$: Doğrusal hız ifadesi için Euler dönüşüm matrisi
$\mathbf{T}_\theta(\boldsymbol{\Theta})$: Açısal hız ifadesi için Euler dönüşüm matrisi
\mathbf{v}^b	: Aracın kendi koordinat sistemine (body frame) hızı
\mathbf{M}_{RB}	: Kütle ve eylemsizlik matrisi
$\mathbf{g}(\boldsymbol{\eta})$: Su altı aracına yer çekimi etkisi
$\mathbf{c}(\mathbf{x}, \mathbf{y})$: Otokorelasyon fonksiyonu
\mathbf{R}	: Köşe olasılık fonksiyonu
$\mathbf{T}_{x'}(\mathbf{x})$: Köşe noktasının teğet çizgisinin denklem ifadesi
ϕ	: Roll açısı
θ	: Pitch açısı
ψ	: Yaw açısı
$\dot{\mathbf{p}}$: Dönüştürülmüş doğrusal hız ifadesi
$\dot{\boldsymbol{\Theta}}$: Dönüştürülmüş açısal hız ifadesi
\mathbf{B}	: Araç üzerine etki eden batma kuvveti
\mathbf{W}	: Araç üzerine etki eden ağırlık
$\tilde{\mathbf{d}}_{min}$: Normalize edilmiş hata terimi
μ_i	: K-means denklem eşitliği
\mathbf{DC}	: Doğru Akım
$\mathbf{x}_{uzaklık}$: Tarama sonucu her bir noktanın araca olan uzaklık ifadesini x koordinatında değeri
$\mathbf{y}_{uzaklık}$: Tarama sonucu her bir noktanın araca olan uzaklık ifadesini y koordinatında değeri
$\boldsymbol{\theta}_k$: Kümeleme sonucu elde edilen merkez noktaların başlangıç noktasına göre açı değeri
\mathbf{MN}_i	: Kümelere ayrılan noktaların merkezleri

KISALTMALAR LİSTESİ

İSAA	: İnsansız Su Altı Araçları
ROV	: Kablolu Su Altı Aracı (Remote Operation Vehicle)
AUV	: Otonom Su Altı Aracı (Autonomous Underwater Vehicle)
GPS	: Küresel Konumlandırma Sistemi (Global Position System)
ULİSAR	: Ulusal İnsansız Su Altı Aracı
INS	: Ataletsel Navigasyon Sistemi (Inertial Navigation System)
SKF	: Basit Kalman Filtresi (Simple Kalman Filter)
EKF	: Genişletilmiş Kalman Filtresi (Extended Kalman Filter)
DVL	: Doopler Hız Günlüğü (Doppler Velocity Log)
USBL	: Ultra Kısa Temel Çizgisi (Ultra Short Base Line)
LBL	: Uzun Temel Çizgisi (Long Base Line)
SBL	: Kısa Temel Çizgisi (Short Base Line)
SLAM	: Eş Zamanlı Konumlama ve Haritalama (Simultaneous Localization and Mapping)
MSIS	: Mekanik Tarama Görüntüleme Sonarı MSISpIC
MSISpIC	: Mekanik Tarama Görüntüleme Sonarı Olasılık Yinemeli Uyum)
DS	: Denizaltı Yerleştirme İstasyonu
RRT	: Rastgele Keşfedilen Ağaçlar (Rapidly-Exploring Random Trees)
UKF	: Kokusuz Kalman Filtresi (Unspected Kalman Filter)
SONAR	: Ses ile Haritalama ve Mesafe (Sound Navigation and Ranging)
PRM	: Olasılık Yol Haritası
PWM	: Darbe genişlik modülasyonu
DC	: Doğru akım
DOF	: Serbestlik derecesi (degrees of Freedom)
Li-Po	: Lityum Polimer
DR	: Doğrusal regresyon
KNN	: K-En yakın komşu
KA	: Karar Ağacı
RO	: Rastgele Orman
SVM	: Destek vektör makineleri (Support vector machine)
MAE	: Ortalama mutlak hata
R²	: Determinasyon katsayısı
OFT	: Ortalama farkların toplamı
RMSE	: Kök ortalama kare hata
HKT	: Hata karelerinin toplamı
MSE	: Ortalama kare hata
UART	: Asenkron seri alıcı-verici haberleşme sistemi

ÖNSÖZ

Tez çalışması boyunca yaşadığım tüm zorluklarda beni destekleyen, dinleyen sabırla bekleyen aileme ve kız arkadaşına çok teşekkür ederim.

Lisans dönemim ve yüksek lisans çalışma sürem boyunca desteklerini esirgemeyen, bana yol gösteren bilgi ve tecrübelerini sabırla bana aktaran değerli tez danışmanım saygı değer hocam Dr. Öğr Ü. Hatice Hilal EZERCAN KAYIR' a saygılarımı sunar ve kendisine çok teşekkür ederim.

2021 yılından beri TEKNOFEST İNSANSIZ SU ALTI SİSTEMLERİ yarışmasına katıldığımız PUSAT takımı ekibinden , tez süresi boyunca çalışmalarda desteğini hiç bırakmayan havuz testlerinde yanımda olan Elektrik Elektronik Mühendisi öğrencisi değerli arkadaşım Yusuf GÜNGÖR' e , yapılan aracın Mekanik tasarımını ve üretimini beraber yürüttüğümüz Makine Mühendisi öğrencisi değerli arkadaşım Yiğit Turgut ARGITLI' ya ve tez araştırmalarımnda değerli fikirleri ve raporlama sürecinde verdiği desteklerden dolayı Elektrik Elektronik Mühendisi öğrencisi değerli arkadaşım Ertuna ÖZDERYA' ya çok teşekkür ederim. Farklı projelerde çalışma imkânı bulduğum ve her koşulda desteklerini hiç bırakmayan saygı değer hocam Dr. Öğr. Gör. Ömer BOYACI' ya çok teşekkür ederim.

1. GİRİŞ

1.1 Genel Bilgiler

Teknolojinin gün geçtikçe gelişmesiyle birlikte hava ve kara otonom araçlarında olduğu gibi su altı sistemlerindeki teknoloji de ilgi görmeye başlamıştır. Su altı dünyasının zorlu ve kimi zaman insan gücü ile ulaşmanın mümkün olmadığı ortamı araştırmacıları böyle şartlarda çalışma imkânı sunmaları, sağladıkları esnek hareket etme yetenekleri nedeniyle insansız su altı sistemlerine yönlendirmektedir. Ülkemizin coğrafi konumu sebebiyle su altı zenginliklerinin ortaya çıkarılması, su altı dünyasının araştırılması ve anlaşılması için de insansız su altı sistemlerinin gerekliliği gündün güne daha iyi anlaşılacaktır. Su altı çalışmaları ile, depremlerin gerekli ölçüde takibi ve analizi yapılmaktadır. Ayrıca, ülkemizin büyük gelir kaynaklarından olan dalış turizminde de dalgıç yardımcısı olarak insansız su araçlarının kullanımı çok popüler ve gerekli bir hale gelmiştir.

İnsansız su altı araçları (İSAA) iki türde incelenir. Yüzey istasyonundan uzaktan kablo ile kontrol edilebilen araçlara ROV (Remote Operating Vehicle) denilmektedir. Kablosuz şekilde otonom hareket edebilen araçlara ise AUV (Autonomous Underwater Vehicle) denilmektedir. ROV araçlarda bir su altı aracı ve bu aracı su yüzeyinden kontrol etmeyi sağlayan su üstü istasyonu ve operatörü mevcuttur. Bu araçlara takılacak sensörler ve robot kol manipülatörleri ile su altında çeşitli zorlu görevler yerine getirilebilmektedir. Ancak en büyük kısıt kablo mesafesinin sınırlı olmasıdır. AUV'ler ise kablo sınırını ortadan kaldırıp, güç sistemlerini de içinde barındırarak su altında tamamen bağımsız hareket etmeyi sağlamaktadır. Otonom şekilde önceden oluşturulmuş rotada hareket edebilmeyi sağlamaktadır. Üzerinde donatılmış sensörler ile engellerden kaçma nesne tespiti gibi sorunları çözebilir. AUV'lerde en büyük problemlerin başında su altında haberleşmenin sınırlı bant genişliklerinde belirli frekanslarda iletişim olmasından dolayı yüzey ile iletişim son derece kısıtlıdır. ROV'lar hassas kontrol, manipülasyon ve gerçek zamanlı karar verme gerektiren görevlerde mükemmel iş yaparlar ve çeşitli

uygulamalar için uygundur. Öte yandan, AUV'lar otonomi, hareketlilik ve menzil sunar, bu nedenle deniz tabanını haritalama, inceleme ve büyük su altı alanlarını izleme gibi görevler için idealdir. ROV'lar ve AUV'lar arasındaki seçim, su altı keşif ve araştırma alanında belirli görev hedeflerine ve işletme gereksinimlerine bağlıdır. Sıklıkla, bir görevde her iki aracın da avantajlarını en üst düzeye çıkarmak için kullanılır.

İnsansız su altı araçları (İSAA) bilinen ilk örneği Avusturya'da 1864'te Luppis-Whitehead Automobile tarafından geliştirilmiştir. Programmed Underwater Vehicle (PUV) adını verdiği aracı torpido şeklinde tasarımı ile uzaktan kablolu şekilde kontrol edilebilir şekilde geliştirmiştir. 1866 yılında Robert Whitehead, üç silindirli hava motoruyla çalışan su altı aracını geliştirmiştir. Poddle isimli bir diğer su altı aracı 1953 yılında Fransız bilim adamı, mühendis ve kâşif Dimitri Rebikoff tarafından tasarlanmıştır. Bu araç daha çok arkeolojik araştırmalar için kullanılmıştır. Tasarımı ile günümüzde yaygın olarak kullanılan su araçlarının ilk örnekleri olması öne çıkmaktadır (KURTOĞLU 2015). Ülkemizde ilk yıllarda genelde mayın ve patlayıcı imha ve temizleme amacıyla otonom özellikleri olmayan uzaktan kumandalı su altı aracı olarak sınıflandırılabilir bu araçlar kullanılmıştır. İnsansız su altı araçlarını ilk zamanlarda, okyanus dibinin haritasının çıkarılması ve deniz mayınlarının yerlerinin tespit edilmesinde kullanıldığı kaydedilmiştir. İlk tasarımlara bakıldığında torpido şeklinde ve uzaktan kumandalı olarak tasarlanan bu araçlar enerji problemi nedeniyle deniz altında uzun süre kalamamıştır. „Su altında kablosuz iletişim zor olmasından dolayı, yüzeyde pilot tarafından kontrol edilen insansız su altı araçlarının kablo sınırının olması gibi bir çok farklı sebepler nedeniyle kontrolleri çok zor olduğu gözlenmiştir.

Ülkemizde su altı araçlarında yapılan ilk çalışmalar Leblebicoglu ve ekibinin (2006-2009) TUBİTAK kapsamında Ulusal İnsansız Su Altı Aracı (ULİSAR) projesidir. Proje kapsamında su altı ve su üstü araç tasarımı üzerinde durulmuştur. İki araç birbirine fiber kablo ile bağlı olup haberleşme sistemi tasarlanmıştır. Su üstü araçta ana komuta gemisine RF ile haberleşmesi sağlanmıştır. Navigasyon sistemi bu sayede gerçek zamanlı sağlanmıştır. Mayın tarama gibi görevlerde ve keşif gözlem amaçlı tasarlanmış ve bu alandaki çalışmaların öncüsü olmuştur. 2010 yılında “Ağ yetenekli ve çok sensörlü su altı keşif sistemi” projesi ile ASELSAN “Dalgıç” isimli

su altı uzaktan kontrol edilebilen aynı zamanda otonom sürüş özelliğine sahip aracı geliştirmiştir. Su altı keşif gözleme, liman ve kritik alan güvenliği, kıyı güvenliği, mayın tanı, teşhis ve imhası, arama ve kurtarma görevlerini yerine getirmesi için üretilmiştir.



Şekil 1.1: ULİSAR Projesi Su Altı Aracı (Leblebicioglu 2010).

1.2 Literatür Özeti

Su altı sistemlerinde yerini bulma, haritalama ve navigasyon oldukça karmaşık bir süreçtir. Bu sistemlerde, sınırlı görünürlük, tuzluluk, su basıncı gibi çeşitli faktörler, yüzeydeki navigasyon tekniklerinin uygulanmasını engeller. Su altı araştırma araçları ve denizaltı robotları gibi su altı araçlarının, konumlarını doğru bir şekilde belirlemeleri ve su altı ortamını haritalamaları gerekmektedir. Bu amaçla, manyetik, akustik ve optik sensörler kullanılır. Ayrıca, GPS gibi yüzeydeki uydu tabanlı sistemler su altında işe yaramaz. Bu kapsamda su altında yönelim haritalama ve navigasyon çözümleri için Ataletsel Navigasyon Sistemi, Akustik Navigasyon sistemi gibi entegre çözümler ortaya çıkmıştır.

2004 yılında Loebis ve ark. birleştirilmiş bir sistem önermişlerdir. Bu sistemde GPS sensöründen aldığı konumu referans alıp ataletsel navigasyon sistemi ile

birleştirmiştir. Ataletsel Navigasyon sistemi (INS) IMU sensörü gibi hareketi ölçen sensörlerden aldığı verileri kullanarak ölü hesaplama yöntemiyle hareket planlamasına dayanmaktadır. INS sensörlerinden aldığı verilerdeki hataları filtrelemek için Basit Kalman Filtresi (SKF) ile Genişletilmiş Kalman Filtresini (EKF) kullanmışlardır. SKF ve EKF'nin kararlılığını ve performansını artırmak amacıyla bulanık mantık tekniklerinin uygulanması üzerinde odaklanmaktadır. SKF ve EKF'nin kararlılığını ve performansını ancak algoritmalar gerçek sensör gürültü özelliklerini içerdiğinde koruyabileceğinden, bu uyarlanabilir mekanizmanın gerekli olduğu düşünülmektedir. Bu yaklaşımın değerlendirilmesi için, elektronik pusula, IMU ve farklı gürültü özelliklerine sahip iki ek sensörle ölçülen Hammerhead yön modeli kullanılmıştır. Bu yaklaşımın sonucunda, SKF ve EKF'nin tahminini iyileştirerek genel doğruluğu artırmış ve gelecek vaat eden bir çalışma olmuştur (D Loebis ve diğ. 2004).

P.M. Lee ve arkadaşları (2006) DVL (Doppler Velocity Log), derinlik sensörü ve manyetik pusula ile alıcı ve verici sonar sensörünün birlikte kullanıldığı, ataletsel navigasyon sistemine uyarlanmış hibrit su altı navigasyon sistemlerini (SDINS) önermiştir. Yapılan çalışmada mesafe sonarı ile iki referans istasyon aktarıcı sonarlar kullanılmıştır. İki referans aktarıcı akustik verici olarak adlandırılmaktadır. Akustik yöntemlere dayalı bu sistemde kullanılan akustik aktarıcı sistemlerine, LBL (uzun temel çizgi), SBL (kısa temel çizgi), USBL (Ultra kısa temel çizgi) denilmektedir. 2 mesafe sesörü bir tanesi verici bir tanesi alıcı olarak, istasyondaki referans akustik sensörler vericiden gelen sinyali alıcı olarak kullanılan mesafe sensörüne aktarmak için kullanılmıştır. Buradan gelen veriler IMU sensörü ve DVL sensörü ile yapılan konumlandırma sistemine eklenmiştir. Sensördeki gürültüden kaynaklanan hataları optimum düzeye indirebilmek için Genişletilmiş Kalman Filtresi kullanılmıştır. Monte Carlo simülasyonu yöntemiyle sonuçlar değerlendirilmiştir. Geliştirilen navigasyon sisteminin ilk konum hatalarının ortadan kaldırıldığı görülmüştür. İkinci bir sensörün ilavesi ataletsel akustik navigasyon sistemi, su altı araçlarının konumunu istikrarlı bir şekilde tahmin edilebileceğini söylemişlerdir (P. M. Lee ve diğ. 2007).

Bu makale, otonom su altı araçları (AUV'ler) için bir konum belirleme ve haritalama tekniği olan Eşzamanlı Yerelleştirme ve Haritalama (SLAM) üzerinde odaklanmaktadır. Bu teknik, bilinmeyen ve muhtemelen yapılandırılmamış bir su altı ortamında seyreden bir AUV'nin konumunu belirlemek ve harita oluşturmak amacıyla

bir algoritma önermektedir. Doppler Velocity Logger (DVL) ve hareket referans biriminden (IMU) gelen verileri kullanarak AUV'nin ölü hesaplamalarını tahmin etmekte ve mekanik tarama görüntüleme sonarında (MSIS) alınan menzil taramalarını kullanarak olasılık tarama eşleştirmesini gerçekleştirmektedir. Algoritma, Mekanik Taramalı Görüntüleme Sonar Olasılıksal Yinelemeli Uyum (MSISpIC) adını taşımaktadır. Bu algoritma, akustik görüntüdeki bozulmaları aracın hareketinden kaynaklanan etkilerle ele alarak, bir Olasılıklı Yinelemeli Yazışma (pIC) algoritması temelinde çalışmaktadır. Doppler Velocity Logger'dan alınan hız ölçümleri ve IMU'dan gelen ivme, eğim, yuvarlanma ölçümleri kullanılarak bir sabit hız modeli ve genişletilmiş Kalman filtresi (EKF) uygulanmaktadır. Bu, AUV'nin tarama boyunca takip ettiği yörüngeyi tahmin etmek için kullanılır. Son olarak, makale, MSISpIC algoritmasının geliştirilmiş bir versiyonunu sunarak, bu yöntemin poz tabanlı SLAM çerçevesinde uygulanabilirliğini göstermektedir. Önerilen yöntem, Girona sahilinde bulunan terk edilmiş bir yat limanında gerçekleştirilen deneysel bir araştırma sırasında test edilmiştir. Deneyler, önerilen yöntemin, gerçek dünya verileri üzerinde başarılı bir şekilde test edildiğini ve konum düzeltme ile haritalama tekniklerinde önemli gelişmeler sağladığını göstermektedir (A. Mallios ve diğ. 2010).

Bu makale, eşzamanlı yerleştirme ve haritalama (SLAM) için bir yaklaşım sunarak, batimetrik haritalama görevlerinde etkili bir şekilde kullanılabilen bir yöntemi açıklamaktadır. Bu yaklaşım, açık tanımlama, izleme veya deniz tabanı özelliklerinin belirli bir şekilde ilişkilendirilmesine gerek duymayan, verimli bir SLAM metodunu temsil eder. Rao-Blackwellized parçacık filtresi kullanarak, çok ışınli sonar ile, iki boyutlu bir derinlik haritasını çıkaran bir yöntem üzerinde çalışmaktadır. Dağıtılmış parçacık eşleme, harita kopyalamanın hesaplama maliyetini azaltmak için yeniden örnekleme işlemi sırasında kullanılır. Önerilen yöntemin, otonom su altı aracı ve uzaktan kumandalı bir araçla toplanan çok ışınli sonar verileri kullanılarak küçük ve büyük zamanlı görevlerde başarıyla doğrulandığını belirtir. Sonuçlar, deniz tabanı yapısının gözlemlerinin, diğer gözlemlerle birleşmiş ölü hesaplamaya göre tahmini yörüngeyi ve haritayı nasıl iyileştirdiğini göstermektedir. Bu yaklaşımın, deniz dibi özelliklerini açıkça modellemeye gerek kalmadan haritalama görevlerinde doğruluk ve güvenilirlik sağlamak için kullanılabileceği belirtilir. Aynı zamanda, USBL veya LBL akustik konumlandırma sistemlerinin kurulumu için ek altyapı, zaman ve masraf gerektirmeden de uygulanabilir olduğu

söylenbilir. BPSLAM algoritmasının hesaplama verimliliğinde önemli bir gelişme sağladığı ve küçük ve büyük ölçekli görevler arasında iyi bir geçiş yapabildiği belirtilir (S. Barkby ve diğ. 2011).

M.F.Fallo ve arkadaşları sığ su okyanus ortamında mayına karşı önlemler gerçekleştirebilen Proviewer 900-kHz tarama sonarı ile çevre haritalaması yapmıştır. Bu çalışmada Ortam haritalamasını kara otonom araçlar için kullanılabilen SLAM (Eş zamanlı konum ve haritalama) algoritmasını kullanmıştır. Bu algoritma bir otonom aracın içinde bulunduğu ortamda hareketinden haritalama yapmayı sağlar. Deniz altında ses dalgasının yayılım etkisini göz önünde bulundurduğumuzda sonarın tarama mesafesinden 3 boyutlu ortamda bir haritalama yapmak mevcuttur. SLAM tekniğinin en büyük avantajı pahalı sistemlerin kullanılmasının önüne geçmektir. Savunma sistemlerinde kamikaze rolünde görev yapabilen sistemlerde kullanılabilir. Sistem mayın taramalarında kullanılmak üzere tasarlanmıştır. Olası mayın patlamalarında tek kullanımlık bir araç için IMU ve DVL içeren ataletsel bir navigasyon sisteminin kullanılması maddi açıdan büyük bir kayıp ortaya çıkarır. Küçükten orta dereceye kadar olan okyanus akıntıları için, aracın ilk araç dalışı sırasında rotadan çıkmaması için çevrimiçi bir akım tahmin hesaplaması vardır. İlk referans aldığı nokta GPS sisteminden aldığı konum referansı ile hareket etmektedir. Burada karşılaşılabilecek sorunlar ne kadar çevrimiçi akım tahmin hesaplaması bulursa da GPS sisteminden aldığı konumdan sonra yapılan hesaplamalarda bulunan ortam koşullarının zorluğu göz önüne alınırsa hata ihtimalleri çoğalmaktadır. Buna karşın önerilen çözüm maliyet açısından oldukça uygundur (M. F. Fallonve diğ.2013).

Prof. Dr. M. Kemal Leblebicioğlu ve ekibi 2015 yılında ULİSAR projesi kapsamında geliştirilen su altı aracında Sonar ve optik kamera görüntülerini birleştirerek navigasyon ve yol planlama önermişlerdir. Atalatsel Navigasyon Sistemi, Küresel Konumlama Sistemi (GPS), akustik sistemler ve görüntü sistemleri ile navigasyon önerilmiştir. Genişletilmiş kalman filtresi alınan ölçümlere uygulanarak gürültü engellenmiştir. Yapılan çalışmada ilk olarak sadece ataletsel navigasyon sistemi analiz edilmiş hatalar belirlenmiştir. Atalatsel navigasyon sistemiyle, USBL navigasyon birleştirilerek hatalar incelenmiştir. Son olarak ataletsel navigasyon sistemine akustik yöntemler ve kamera ile görüntüleme eklenerek yol planlama sırasında aracın hızı, konumu ve yönelimi incelenmiştir. Tarama sonarından alınan

veriler optik kamera ile birleştirilmiştir. Opto-akustik sistemde sonardan alınan tarama görüntüye dönüştürebilen bir simülator geliştirilmiştir (Lelebicioğlu ve diğ. 2015).

Bu makale, akustik ve optik algılamayı birleştirerek bir Otonom Su altı Aracını (AUV) bir denizaltı yerleştirme istasyonuna (DS) yönlendirmek ve yerleştirmek için bir yöntem önermektedir. İstasyon herhangi bir akustik sensörün ölçüm aralığında olduğu düşünülmektedir. Önerilen yöntem iki aşamadan oluşmaktadır. İlk olarak su altı aracı üzerindeki akustik sensörler ile hareket halinde tarama yaparlar. Tarama sırasında istasyonu bulmak için Gauss Toplamı (soG) filtresi kullanır. İkinci aşamada kamera ile istasyonun görüş alanına girdiğinde kitlenme algoritması uygular. Burada SLAM algoritmasından yardım alır. Çalışma HIL simülasyonu ile incelenmiştir. Optik-akustik yöntemle Akustik yöntemler ve kamera ile görsel SLAM yaklaşımın birleştirilmesi, sadece tarama sonarları ile yapılan SLAM yöntemine göre daha efektif bir çalışma olduğunu ortaya çıkardığı söylenebilir (G.Vallicrosa ve diğ. 2016).

Bu tez çalışmasında otonom su altı araçları için hareketinin kontrolü ve yol üzerinde bulunan engellere göre gideceği yolların tahmini için farklı türde yöntemler önermektedir. Aracım kontrolünde ağırlıklı bir aralıklı Kalman filtresi (wIKF) önerilmektedir. Bu filtre genişletilmiş kalman filtresinin bir türüdür. Ölçümlerin sürekli olmadığı belli aralıklarla ölçüm istenmesi durumunda kullanılan bir algoritmadır. Yol planlaması için A*, Dijkstra, D* gibi deneysel arama algoritmaları ve çeşitli evrimsel optimizasyon algoritmalarının kullanıldığı belirtilmektedir. Ayrıca, hızla keşfeden rastgele ağaçlar algoritması (RRT), olasılık yol haritası algoritması (PRM) gibi, su altı robotlarının yol planlaması için önerildiği ifade edilmektedir. Bu algoritmalar, su altında rastgele yollar belirler bu yollar üzerinde çeşitli engeller karşısında maliyet fonksiyonuna göre yeni yollar bulur (R. Cui ve diğ. 2016).

Bu makalede, 6 serbestlik dereceli su altı insansız aracının doğrusal olmayan matematiksel modeli ile aracın pozisyon ve yönelim verileri elde edilmiştir. Sensör verilerine gürültü modeli eklenmiştir. Pozisyon ve yönelim bilgisi oluşturulmuştur. Daha sonra gürültü eklenmiş veri setini tahmin etmek ve hataları en aza indirebilmek için Genişletilmiş Kalman Filtresi(EKF) ve Unscented (Kokusuz) Kalman Filtresi (UKF) algoritmaları önerilmiştir. Doğrusal olmayan model, denge noktaları etrafında doğrusal hale getirilerek EKF uygulanmıştır. UKF'yi kullanmak için sistemi doğrusal hale getirmeye gerek yoktur. Su altı aracının doğrusal olmayan sistem modeli

kullanılmıştır. İki filtrenin tahmin performansı karşılaştırılmıştır. EKF ve UKF nin yüksek gürültülerdeki performanslarını iyileştirmek için makine öğrenme algoritmalarından faydalanılmıştır. Destek Vektör Makinesi (SVM) uygulanarak sensör verilerinin çok sapması ve çevresel faktörlerden fazla etkilendiği durumların önüne geçilmesi amaçlanmıştır. Tüm bu çalışma, MATLAB/Simulink ortamında modellenen sonuçlarda SVM algoritmasının belirlenen yol planlama çözümünde oldukça etkili olduğu gözlemlenmiştir (Berna, E ve diğ. 2021).

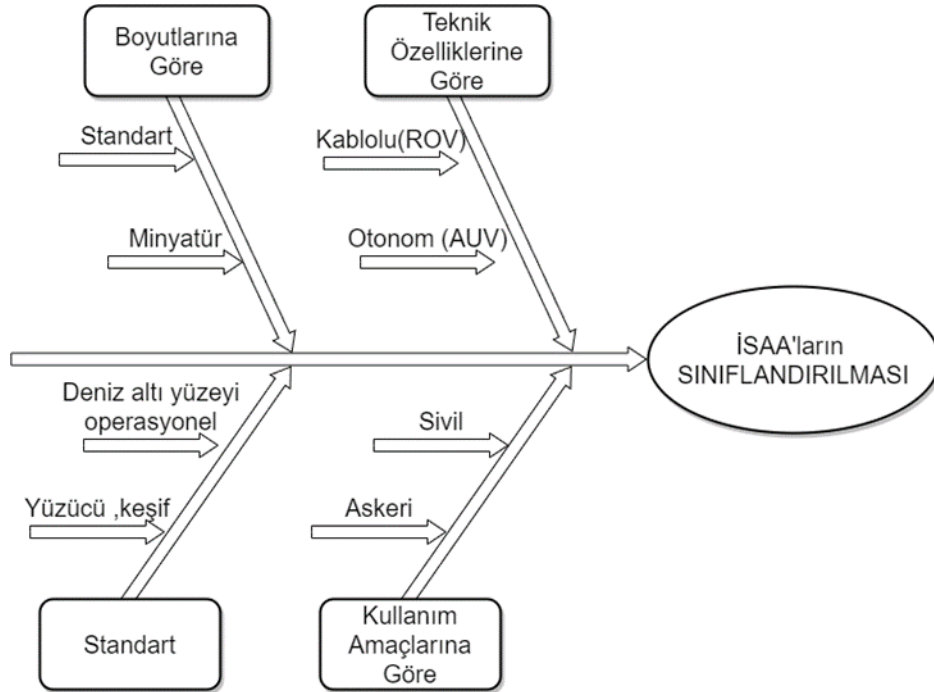
1.3 Tezin Amacı

Kara ve hava otonom araç teknolojisinde navigasyon ve sistemleri GPS, lidar, radar sistemleri ile sağlanmaktadır. Su altında sınırlı bant genişliklerinde belli frekanslarda iletişim olmasından dolayı eş zamanlı konumlandırma ve navigasyon sistemleri hava ve kara araçlarından çok daha zordur. Bu da su altında iletişimin önemli bir sorun olduğunu ortaya çıkarıyor. Bu tezin amacı Su altında konumlandırma ve haritalama sorunlarına uygulanabilir bir çözüm üretmektir. Açık denizlerde genellikle deniz tabanına yerleştirilen akustik vericiler (pingerlar) ile araçta bulunan sonar sistemlerinin birbirleri ile iletişimi ile konumlandırma çalışmaları yapılmaktadır. Kapalı alanlar için haritalama ve navigasyon için bu sistemler biraz pahalı olmaktadır.


Su altı aracının bilinmeyen bir ortama atıldığında, üzerinde bulunan 360 derece tarama sonarı sayesinde ortam haritasını çıkartıp geliştirilen köşe bulma algoritmaları sayesinde ortamda nerede olduğunu kestirilmesi amaçlanmaktadır. Aracın belirlenen yol üzerinde hareketi, ne kadar yol aldığı makine öğrenme algoritmalarıyla tahmin çalışması yapılacaktır. Yapay zekâ algoritmalarının kullanımı ile mesafe sensörlerinden alınan verileri eğitip bir model oluşturmak ve bu sensöre ihtiyaç kalmadan aracın yol aldığı mesafeyi hesap edebilmesi amaçlanmaktadır. Mesafe sensörünün modellenmek istenmesinin sebebi ise su altı aracının hareket halinde sensörün ölçüm verilerinden oluşabilecek hatalar ve aracın etrafında olabilecek engellerden dolayı mesafe sensörü verisinin bu engellerden olan uzaklıkları vermesidir.

2. İNSANSIZ SU ALTI SİSTEMLERİ

Günümüzde su altı keşifleri ve operasyonları, insansız su altı sistemleri sayesinde yeni bir boyut kazanmıştır. İnsansız su altı sistemleri, deniz altı görevlerini gerçekleştirmek için insan müdahalesine ihtiyaç duymadan, otomatik veya uzaktan kumandalı araçlar kullanarak su altı keşifleri, gözlem ve veri toplama işlemlerini gerçekleştirmek amacıyla geliştirilen teknolojik sistemlerdir. Bu sistemler, derin denizlerde, okyanus tabanında ve sığ sularda çeşitli görevlerde kullanılabilir. Araştırma, jeoloji, deniz biyolojisi, savunma ve sivil uygulamalar gibi birçok alanda insansız su altı sistemleri kullanılmaktadır. Özellikle bilimsel keşifler, denizaltı kaynaklarının araştırılması, su altı yapıların incelenmesi ve deniz güvenliği gibi konularda büyük öneme sahiptir. İnsansız su altı araçları (İSAA'lar), su altı dronları ve denizaltı robotları gibi farklı türlerde olabilir. Bu araçlar, yüzeydeki bir kontrol merkezinden yönetilebileceği gibi, özerk bir şekilde görevlerini yerine getirebilirler. Kameralar, sensörler, denizaltı haritalama sistemleri ve diğer veri toplama ekipmanlarıyla donatılmış olan bu sistemler, su altı dünyasını daha iyi anlamamıza ve kaynakları daha etkili bir şekilde yönetmemize olanak tanır.



Şekil 2.1: İnsansız Su Altı Sistemlerinin Sınıflandırılması.




Şekil 2.2: İlk insansız su altı aracı örneği POODLE (Jehangir 2019).

2.1 İSAA Matematiksel Modelleme


Genel olarak, su altı araçlarının dinamiklerinin matematiksel modeli ağırlık, yüzerlik, çerçeve geometrisi, pervanelerin sayısı ve konfigürasyonu ve diğer özellikler gibi özelliklere bağlıdır. Su altı araçlarının matematiksel olarak modelinin tam olarak oluşturmak biraz karmaşıktır. Bunun sebebi aracın eklenmiş kütle, doğrusal ve doğrusal olmayan sönümlenme katsayılarını ifade etmenin zorluğudur. Bu katsayılar hidrodinamik tasarımı değerleri olarak adlandırılır. Bu zorluk, araçların düşük hızlarda hareket etmeleri, düz bir çeviri hareketi veya sabit bir durum tarif etmeleri ve yavaş pervane dinamiğine sahip olmalarından kaynaklanır. (Muñoz, F,2021)

Serbestlik derecesi, bir sistemdeki bağımsız hareket edebilen eksenlerin sayısını ifade etmektedir. Hareket etme özgürlüğü olarak da tanımlanabilir. Fizikte, mühendislikte ve mekanik sistemlerde sıklıkla kullanılan bir terimdir. Bir su altı aracını hareket kabiliyeti motor yerleşimleri ile belirlenmektedir. Örneğin 8 motor düzeninde tasarlanan su altı aracı 6 serbest eksen derecesine sahiptir. Bu eksenler x ekseninde ileri-geri hareketi, y ekseninde sağa ve sola hareket ve z ekseninde yukarı aşağı hareketi temsil etmektedir. X eksenine göre yalpalama adı verilen bir eksen hareketi 'roll', y eksenine göre 'yunuslama' hareketi olarak adlandırılan 'pitch' ifadesi, z eksenine göre aracın yönelme açısı olarak adlandırılan 'yaw' hareketidir. 8 motorlu

bir araç tasarımında Toplam da 6 eksen bir hareket sağlanmış olur. Aşağıdaki şekilde eksen takımlarının hareketleri temsil edilmektedir.



Şekil 2.3: 6-DoF Eksen Hareketleri.



Şekil 2.4: PUSAT Lura su altı test aracı ve Dünya referans koordinat sistemi.

6 Serbestlik dercesine sahip bir su altı aracının en genel anlamda ifadesi Newton-Euler ile matris formunda aşağıdaki gibi gösterilir. (Fossen,2011)

$$M\dot{v} + C(v) + D(v)v + G(\eta) = \tau + \tau_d \quad (2.1)$$

Burada M , atalet matrisini; $C(v)$, Coriolis ve merkezkaç matrisini; $D(v)$, hidrodinamik sönümlenme matrisini ve $G(\eta)$, moment vektörünü temsil eder. τ vektörü sistemin kontrol girişidir. Genellikle itici motorların ve momentlerin uygulanmasını ifade eder. Aracın kontrol edilebilir olmasını sağlar. $\tau_{d'}$ vektör ifadesi, dalga etkileri, akıntılar veya diğer çevresel bozulmalar nedeniyle ortaya çıkan dış etkileri temsil eder. Çevresel koşullara tepki olarak ifade edilebilir.

$$\dot{\eta} = j(\eta)v \quad (2.2)$$

Bu ifade su altı aracının geometrik yönleri açıklar. Aracın kendi referans koordinat ekseninin Dünya referans koordinat eksenine ifadesi ve kinematik modeli açıklar. Aracın konum ve yönelmesindeki değişimin, hız vektörü ve Jakobiyen matrisi aracılığıyla nasıl hesaplandığını gösterir. Jakobiyen matrisi, konum ve yönelme değişkenlerinin hızlara nasıl dönüştürüldüğünü temsil eder. $\dot{\eta}$, aracın konum ve yönelme vektörünün zamanla değişimini temsil eder. η , aracın konum ve yönelme vektörünü ifade eder. $j(\eta)$, η 'nin konum ve yönelmesine bağlı olarak değişen bir Jakobiyen matrisidir. Aracın doğrusal hız vektörü v ile ifade edilmektedir.

Bu eşitliklerin matris formunda gösterimi aşağıdaki gibidir.

$$\eta = [x \ y \ z \ \phi \ \theta \ \psi]^T \quad (2.3)$$

$$v = [u \ v \ w \ p \ q \ r]^T \quad (2.4)$$

$$\tau = [X \ Y \ Z \ K \ M \ N]^T \quad (2.5)$$

Bir su altı aracının kendi koordinat sistemini hareket sırasında modelleyebilmesi için Dünya referans koordinat sistemine dönüştürmesi gerekir. Bu dönüşüm için Euler açı dönüşüm dönüşüm formülasyonu ile Quaternion Dönüşüm formülleri kullanılmaktadır. Quaternion dönüşümleri Euler açıların tekil noktalarını ve süreksizliklerini önlemek amacıyla kullanılır. Aracın doğrusal ve açısal hızların dönüşüm matrisleri ile çarpılmasıyla elde edilen euler dönüşüm ifadesi aşağıdaki gibidir (Wu, C. J. 2018).

$$v^n = R_b^n(\Theta)v^b \quad (2.6)$$

$$\dot{\Theta} = T_q(\Theta)w^b \quad (2.7)$$

$$R_b^n(\Theta) = R_z(\psi)R_Y(\theta)R_z(\phi) \quad (2.8)$$

$$R_b^n(\Theta) = \begin{bmatrix} \cos\psi\cos\theta & -\sin\psi\cos\phi + \cos\psi\sin\theta\sin\phi & \sin\psi\sin\phi + \cos\psi\cos\phi\sin\theta \\ \sin\psi\cos\theta & \cos\psi\cos\phi + \sin\psi\sin\theta\sin\phi & -\cos\psi\sin\phi + \sin\theta\sin\psi\cos\phi \\ -\sin\theta & \cos\theta\sin\phi & \cos\theta\cos\phi \end{bmatrix} \quad (2.9)$$

$$T_\Theta(\Theta) = \begin{bmatrix} 1 & \sin\phi\tan\theta & \cos\phi\tan\theta \\ 0 & \cos\phi & -\sin\phi \\ 0 & \sin\phi/\cos\theta & \cos\phi/\cos\theta \end{bmatrix} \quad (2.10)$$

Doğrusal ve açısal hız ifadelerini tek bir matris formatında ele alırsak, 6 serbestlik derecesine sahip bir aracın dönüşüm matrisleri ile denklem eşitliği aşağıdaki gibi olur.

$$\dot{\eta} = j(\eta) \dots \dots \dots \begin{bmatrix} \dot{p} \\ \dot{\Theta} \end{bmatrix} = \begin{bmatrix} R_b^n(\Theta) & 0_{3 \times 3} \\ 0_{3 \times 3} & T_\Theta(\Theta) \end{bmatrix} \begin{bmatrix} v^b \\ w^b \end{bmatrix} \quad (2.11)$$

Su altı aracının Dünya referans koordinat sistemine göre dönüştürülmüş genel sistem modeli ifadesi;

$$M_{RB}\dot{v} + C_{RB}(v)v + M_A\dot{v}_w + C_A(v_w)v_w + D(v_w)v_w + g(\eta) = \tau \quad (2.12)$$

M_{RB} aracın kütle ve eylemsizlik matrisini C_{RB} aracın hızının karesine bağlı olarak ortaya çıkan Coriolis matrisini, M_A Eklenmiş kütle matrisi, aracın suda ilerlerken etkileşime girdiği ek kütleleri içerir. \dot{v}_w Su hızının zamanla ifadesi, $C_A(v_w)$ Eklenmiş kütle Coriolis matrisi, su hızının karesine bağlı olarak ortaya çıkan Coriolis, $D(v_w)$ Su altı aracının suda ilerlerken karşılaştığı direnç matrisidir. $g(\eta)$, aracın yerçekimi etkisi altındaki duruşunu ifade eden bir terim. Genellikle aracın derinliğini ifade eder (Wu, C. J. 2018).

$$M_{RB} = \begin{bmatrix} m & 0 & 0 & 0 & mZ_g & -my_g \\ 0 & m & 0 & -mZ_g & 0 & mx_g \\ 0 & 0 & m & my_g & -mx_g & 0 \\ 0 & -mz_g & my_g & I_x & -I_{xy} & -I_{xz} \\ mz_g & 0 & -mx_g & -I_{yx} & I_y & -I_{yz} \\ -my_g & mx_g & 0 & -I_{zx} & -I_{zy} & -I_z \end{bmatrix} \quad (2.13)$$

I_x, I_y, I_z aracın eylemsizlik moment ifadelerini, $I_{xy}, I_{xz}, I_{yx}, I_{yz}, I_{zx}, I_{zy}$ ifadeleri koordinat sisteminde eksenlerin birbirine etkileyen momentleridir. Belirli bir eksen etrafında dönme hareketi yaparken, bu eksenle aynı doğrultuda olmayan bir kuvvetin etkisiyle oluşan momenttir. Genellikle bir cismin dönme hareketini etkiler ve cismin dönme eksenini etrafındaki dönme hareketine katkıda bulunur veya buna karşı bir direnç oluşturabilir.

$$C_{RB}(v) = \begin{bmatrix} 0 & 0 & 0 & 0 & mw & 0 \\ 0 & 0 & 0 & -mw & 0 & 0 \\ 0 & 0 & 0 & mv & -mu & 0 \\ 0 & mw & -mv & 0 & I_z r & -I_y q \\ -mw & 0 & -mu & -I_z r & 0 & I_x p \\ mv & -mu & 0 & I_y q & -I_x p & 0 \end{bmatrix} \quad (2.14)$$

Eklenmiş kütle ve Coriolis matrislerine göre aracın hidrodinamik eşitliği aşağıdaki gibi gösterilir.

$$M_A = - \begin{bmatrix} X_{\dot{u}} & X_{\dot{v}} & X_{\dot{w}} & X_{\dot{p}} & X_{\dot{q}} & X_{\dot{r}} \\ Y_{\dot{u}} & Y_{\dot{v}} & Y_{\dot{w}} & Y_{\dot{p}} & Y_{\dot{q}} & Y_{\dot{r}} \\ Z_{\dot{u}} & Z_{\dot{v}} & Z_{\dot{w}} & Z_{\dot{p}} & Z_{\dot{q}} & Z_{\dot{r}} \\ K_{\dot{u}} & K_{\dot{v}} & K_{\dot{w}} & K_{\dot{p}} & K_{\dot{q}} & K_{\dot{r}} \\ M_{\dot{u}} & M_{\dot{v}} & M_{\dot{w}} & M_{\dot{p}} & M_{\dot{q}} & M_{\dot{r}} \\ N_{\dot{u}} & N_{\dot{v}} & N_{\dot{w}} & N_{\dot{p}} & N_{\dot{q}} & N_{\dot{r}} \end{bmatrix} \quad (2.15)$$

$$C_A(v) = \begin{bmatrix} 0 & 0 & 0 & 0 & z_{\dot{w}} w & 0 \\ 0 & 0 & 0 & -z_{\dot{w}} w & 0 & X_{\dot{u}} u \\ 0 & 0 & 0 & -Y_{\dot{v}} v & X_{\dot{u}} u & 0 \\ 0 & -z_{\dot{w}} w & Y_{\dot{v}} v & 0 & -N_{\dot{r}} r & M_{\dot{q}} q \\ z_{\dot{w}} w & 0 & -X_{\dot{u}} u & N_{\dot{r}} r & 0 & -K_{\dot{p}} p \\ -Y_{\dot{v}} v & X_{\dot{u}} u & 0 & -M_{\dot{q}} q & K_{\dot{p}} p & 0 \end{bmatrix} \quad (2.16)$$

Su altı aracının suda ilerlerken karşılaştığı direnç matrisi $D(v)$ ve suyun kaldırma kuvveti nedeniyle etki eden kuvvetler ve momentler "restoratif kuvvetler" olarak adlandırılır. B ve W değerleri araç üzerine etki eden batma kuvveti ve ağırlığı ifade etmektedir Doğrusal olmayan hidrodinamik sönümlenme olayları ise sırasıyla X_u , Y_v , Z_w , N_r ve $X_{u|u}|u|$, $Y_{v|v}|v|$, $Z_{w|w}|w|$, $N_{r|r}|r|$ katsayılarıyla karakterize edilir (Fossen,2011).

$$a = X_u + X_{u|u}|u|, b = Y_v + Y_{v|v}|v|, c = Z_w + Z_{w|w}|w|, d = K_p + K_{p|p}|p|,$$

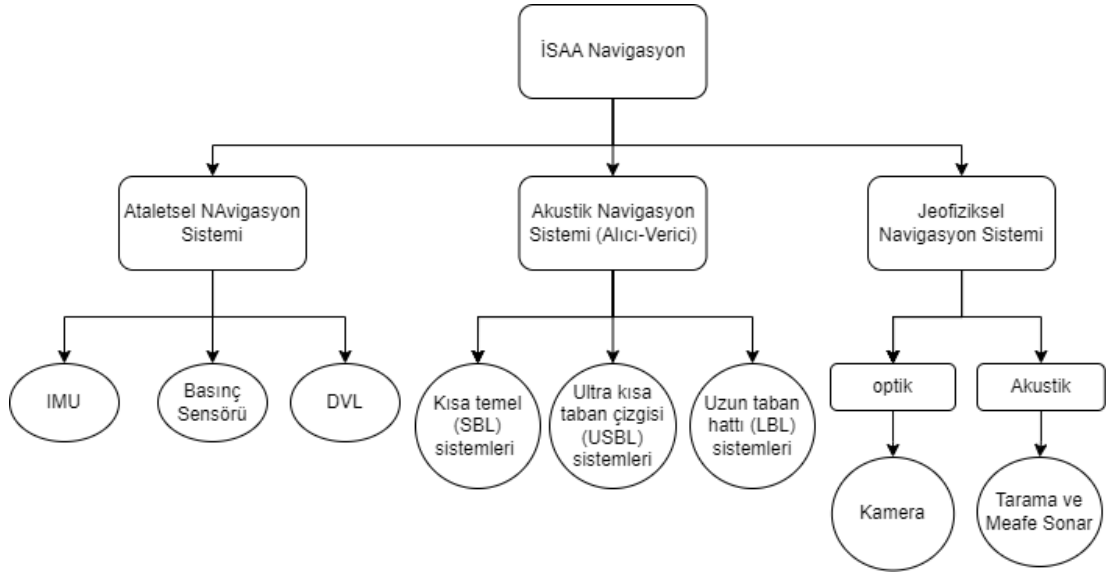
$$e = M_q + M_{q|q}|q|, f = N + N_{r|r}|r|$$

$$D(v) = - \begin{bmatrix} a & 0 & 0 & 0 & 0 & 0 \\ 0 & b & 0 & 0 & 0 & 0 \\ 0 & 0 & c & 0 & 0 & 0 \\ 0 & 0 & 0 & d & 0 & 0 \\ 0 & 0 & 0 & 0 & e & 0 \\ 0 & 0 & 0 & 0 & 0 & f \end{bmatrix} \quad (2.17)$$

$$G(\eta) = \begin{bmatrix} (W - B)\sin\theta \\ -(W - B)\cos\theta\sin\phi \\ -(W - B)\cos\theta\cos\phi \\ z_g W \cos\theta \sin\phi \\ z_g W \sin\theta \\ 0 \end{bmatrix} \quad (2.18)$$

2.2 Navigasyon Sistemleri

Su altı araçlarda haberleşme, kontrol ve navigasyon kabiliyetleri, insansız platformların görevlerini başarıyla yerine getirmesinde belki de en önemli unsurlardır. Kara, hava ve su üstünde görev yapan insansız platformlarda seyrüsefer sistemleri, uydu tabanlı konum belirleme teknolojilerini örneğin in GPS sistemlerine dayanmaktadır. Ancak deniz suyunun, elektromanyetik spektrum dahilinde sadece akustik ve optik bantlardaki frekanslara belirli ölçüde geçirgen davranıyor olması, su altı araçlarda yeni ve farklı yöntemler kullanılması zorunluluğunu doğurmuştur.



Şekil 2.5: Su altı navigasyon sistemi sınıflandırılması.

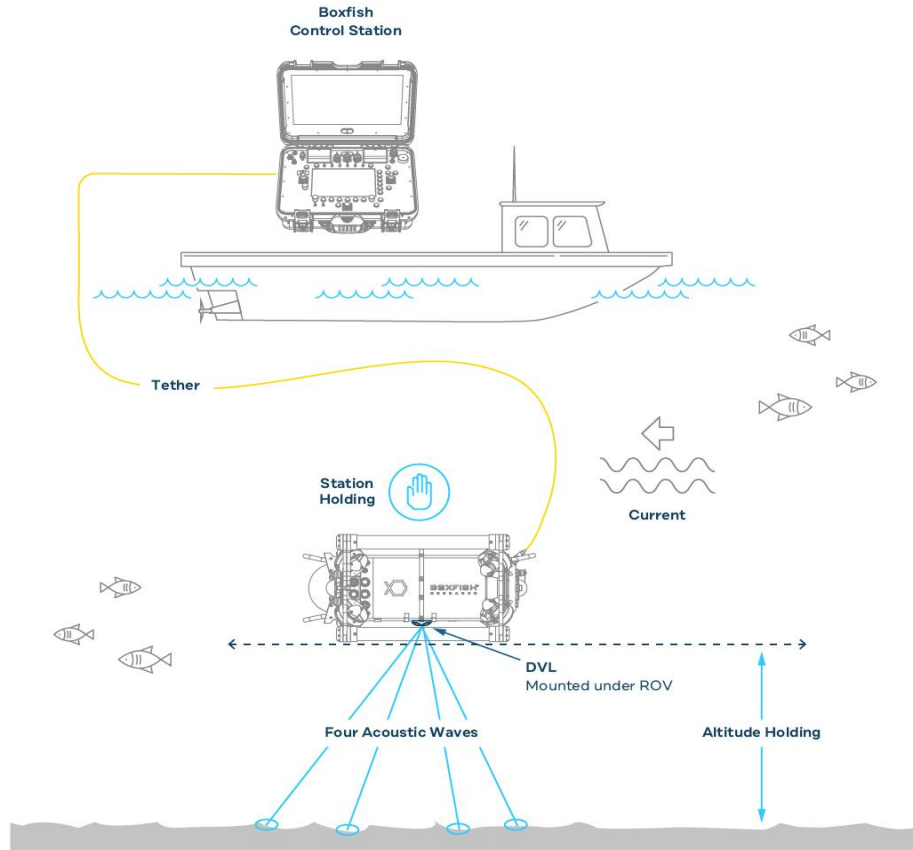
2.2.1 Ataletsel Navigasyon

Kablolu su altı araçlarında (ROV) navigasyon desteği amaçlı konum bilgilerinin, GPS imkânı olan bir su üstü platformu ile kurulan kablolu bir bağlantı üzerinden referans olarak aracın koordinatı saptanır. Bu koordinat aracın kendi başlangıç noktası olarak kabul edilir. Ataletsel Navigasyon, başlangıç noktasına, yönelimine ve hıza göre konumunu ve yönünü izlemek için ivmeölçerler ve jiroskoplar tarafından sağlanan ölçümlerin kullanıldığı sistemlere denir. Bu sisteme ölü hesaplama yöntemi denilmektedir. Atalet ölçü sistemlerinde tipik olarak sırasıyla açışal hızı ve doğrusal ivme gibi veriler kullanılmaktadır. IMU sensörü ile uygulama örneklerinden biridir. Bu sensördeki veriler çeşitli filtrelerden geçirilerek, konumunu ve su altı aracının yönünü izlenebilir hale gelmektedir. Ancak otonom su altı araçlar için aracın kendi konumu doğru tahmin edebilmesi için belli aralıklarda yüzeye çıkması gerekmektedir.

Ataletsel navigasyonda IMU sensörleri gibi kullanılan bir başka cihaz DVL sensördür. Doppler hız günlüğü olarak adlandırılmaktadır. Su altı araştırmalarında kullanılan bir cihazdır. DVL, su altındaki araçların hızını ve yönünü ölçmek için Doppler etkisini kullanır. Bu teknoloji, su altında seyreden araçların konumunu daha hassas bir şekilde belirlemelerine yardımcı olur. Doppler etkisi, bir kaynaktan yayılan ses dalgalarının hareket eden bir nesneye çarptığında frekansında değişiklik meydana

gelmesidir. Bu etki, DVL'de kullanılan akustik dalgalar için de geçerlidir. DVL, deniz altında bulunan yüzeylerden veya hareket eden nesnelere yansıyan akustik dalgaları algılar ve bu dalgaların frekansındaki değişiklikleri analiz ederek aracın hızını ve yönünü hesaplar.

DVL, denizaltı arařtırmaları, su altı robotları, denizaltı keřifleri ve derin deniz navigasyonunda yaygın olarak kullanılmaktadır. Bu cihazlar, su altında navigasyon yaparken, dalgaların neden olduđu araç hareketinin etkilerini hesaplamak için DVL'nin sağladığı hız ve yön bilgilerini kullanırlar. Ayrıca, DVL, denizaltıların deniz tabanı ile olan mesafesini kontrol etmelerine ve denizaltının yerini daha hassas bir şekilde belirlemelerine yardımcı olur. DVL'nin avantajlarından biri, GPS sinyallerinin su altında etkisiz hale gelmesi durumunda bile bağımsız bir şekilde çalışabilmesidir. Bu özellik, denizaltı keřifleri ve su altı navigasyonu gibi alanlarda büyük bir avantaj sağlar.



Şekil 2.6: DVL sensör ile konumlandırma ve hareket (Robotics 2023).


2.2.2 Akustik Navigasyon

Bir su altı akustik konumlandırma sistemi ses dalgalarının mesafe ve/veya yön ölçümleri ile su altı araçlarının veya dalgıçların izlenmesi ve navigasyonu için bir sistemdir. Geniş bir uygulama yelpazesi içinde kullanılmaktadır. Bu sistemler, petrol ve gaz arama, okyanus bilimleri, kurtarma operasyonları, deniz arkeolojisi, askeri faaliyetler gibi alanlarda yaygın olarak tercih edilmektedir.

Akustik sistemlerin çalışma mesafesi uygulama frekansına bağlı olarak birkaç cm'den kilometrelerce mesafelere kadar uzanabilir. Sistemin performansını birçok faktör etkileyebilir. Bu ölçütler akustik sensörün modeline ve yapısına, ortamın özelliklerine çevresel faktörler olarak özetlenebilir.

Su altı akustik konumlandırma sistemleri üç türde incelenmektedir. Akustik sensörlerin konumlandırmasına ve iletim hattına göre uzun taban hattı (LBL), kısa temel (SBL), Ultra kısa taban çizgisi (USBL) olarak sınıflandırılmaktadır.


➤ Uzun Taban Hattı (LBL)



Şekil 2.7: LBL Navigasyon Sistemi (Gode 2015).

Uzun Taban (LBL) sistemleri, su altındaki aktarıcılarının(transponder) belirli konumlara yerleştirildiği okyanus tabanında oluşturulan akustik bir ağı dayanan bir navigasyon sistemidir. Bu sistemlerin çalışma frekansı 8 ile 15 kHz aralığındadır. Sinyali aktarma yetenekleri 5 ile 10 km mesafeler olarak ifade edilmektedir. Yüzeydeki geminin alt kısmına yerleştirilen bir verici su altındaki aktarıcılara sinyaller gönderir. Bu aktarıcılar ile su altı aracı arasında bilgi alışverişi olur. Her aktarıcı, kendine özgü bir sesle yanıt verir ve bu yanıtlar alıcı tarafından tekrar toplanır. Bilgisayarlar, gemi veya aracın kesin konumunu belirlemek için işaretlerden uzaklığı hesaplamak üzere basit geometri ve temel matematik kullanır. 3 farklı noktadan mesafe verileri alınıp matematiksel işleme sokulur. Bu işlem triangülasyon olarak ifade edilir. Triangülasyon yöntemi, belirlenen noktalar arasındaki mesafeleri ve açı değerlerinden, bir alan ve şeklin parçalarına ayrılmasını sağlar. Harita çıkarma, sayısal modelleme gibi uygulamalarda tercih edilmektedir. Kısaca veriler ile üçgenlerin oluşturulması ve bu üçgenler yardımıyla konum tahmini işlemidir. Bilgisayarlar, aktarıcılarının ölçülen üç mesafesinin kesiştiği benzersiz noktayı hesaplar. LBL sistemleri, özellikle derin sularda geniş alan taramaları yapmak için uygundur.


➤ **Kısa Temel Hat (SBL) sistemler**



Şekil 2.8: Kısa Tabanlı Hat (SBL) Navigasyon Sistemi (Ardusab 2023).

Kısa Tabanlı (SBL) akustik konumlandırma sistemi, su altı araçları üzerinde bulunan bir akustik verici tarafından zamanlanmış akustik darbelerin iletilmesine dayanır. Bu darbeler, yüzeyde belirli bir geometrik düzen içinde konumlandırılmış birden çok alıcı tarafından alınır. Her bir alıcı, akustik darbenin gönderildiği anı kaydettiği "uçuş süresi"ni hesaplar. Ardından, bu bilgiler kullanılarak su altı aracının konumu belirlenir. SBL sistemleri, özellikle yansıtıcı ortamlarda daha yüksek konumlandırma hassasiyeti sağlayabilen ayarlanabilir alıcı konumlarına sahiptir. Yüzeydeki düzenli konumlanmış alıcılar, akustik darbelerin daha iyi bir şekilde izlenmesine ve analiz edilmesine imkân tanır. Bu özellik, su altı araçlarının çeşitli koşullarda daha doğru bir konumlandırma elde etmelerine olanak sağlar. Bu sistem, özellikle denizaltı keşif operasyonları, deniz araştırmaları ve su altındaki diğer bilimsel çalışmalar için önemli bir araçtır.

➤ **Ultra Kısa Temel Hat (USBL) sistemler**



Şekil 2.9: Ultra Kısa Tabanlı Hat (USBL) Navigasyon Sistemi (Ardusub 2023).

Ultra-kısa tabanlı (USBL) akustik konumlandırma sistemi, su altı araçlarından iletilen akustik darbelerin yüzeydeki bir alıcı tarafından alınması esasına dayanır, bu bakımdan SBL sistemine benzer. Ancak, USBL sistemi sadece akustik darbenin "uçuş süresini" hesaplamakla kalmaz, aynı zamanda menzil ve yön hesaplamalarını da

gerçekleştirir. USBL sistemi, kompakt bir tasarıma sahiptir; çünkü alıcı aktarıcılar, tek bir verici başlığında sabitlenmiştir. Bu durum, sistem kurulumunu ve kullanımını kolaylaştırır, taşınabilirlik avantajı sağlar ve uygulama esnekliğini artırır. Verici başlığında sabitlenmiş aktarıcılar, su altı aracının konumunu daha hassas bir şekilde belirlemeye olanak tanır.

2.2.3 Jeofiziksel Navigasyon Sistemi

Jeofiziksel navigasyon, konum belirleme işleminin önceden bilinen çevresel koşulların ve özelliklerin haritalar yardımıyla yapılması veya bu haritaların istatistiksel olarak görev esnasında oluşturulması esasına dayanmaktadır. Özellikle optik algılayıcılardan kamera görüntülerinden alınan verilerin işlenmesi ile gerçekleştirilen jeofiziksel seyrüsefer, bütün yöntemler içerisinde en yüksek hassasiyeti sağlıyor olmasına rağmen, algoritmalarının karmaşıklığı, optik sensörlerin maliyeti, bu sensörlerin derinlerde başarılı olabilmesi için yüksek aydınlatma zorunluluğu ve dolayısıyla enerji sarfıyatı, pahalı maliyet gibi nedenlerden dolayı halen çok kritik askeri uygulamaların dışında yaygın bir yöntem değildir, fakat hızla gelişmektedir. Optik kameralar dışında aktif tarama sonarları ile batimetrik haritalama yöntemiyle su altı navigasyonu yapılmaktadır. Batimetrik haritalama, deniz tabanının derinliklerinin ölçülmesi ve haritalanmasıdır. Bu haritalar, su altı topografyasının 3D modellemesini sağlar ve derinlik, dalga hareketi, akıntılar ve diğer su altı özelliklerini gösterir. Batimetrik haritalama, gemi trafiğini güvence altına almak, limanların planlanması, denizaltı keşifleri ve kaynak araştırmaları gibi birçok uygulamada önemlidir. Batimetrik haritalama için kullanılan sonarlar, genellikle çoklu işaretli sesli frekans (multibeam) sonarları olarak adlandırılan sistemlerdir. Bu sistemler, birçok darbelerden oluşan bir dizi ses dalgası yayar ve yansımalarını alır. Bu yansımaların analizi, derinlik ölçümleri ve su altındaki nesnelerin topografik haritalarının oluşturulması için kullanılır.

3. SINIFLANDIRMA VE KÖŞE ÇIKARMA ALGORİTMALARI

Köşe çıkarma algoritmaları, bir resim veya görüntü üzerinde köşeleri veya belirgin noktaları tespit etmeye odaklanan algoritmaları ifade eder. Bu tür algoritmalar genellikle görüntü işleme, bilgisayarlı görüş ve robotik uygulamalarda kullanılır. Köşe çıkarma, nesnelerin konumlarını, dönme açılarını ve ölçek faktörlerini belirlemede yardımcı olabilir. Harris Köşe Algılama, Shi-Tomasi Köşe Algılama ve FAST (Features from Accelerated Segment Test) gibi köşe çıkarma algoritmaları, yaygın olarak kullanılan örneklerdir. Bu algoritmalar, teknolojinin birçok alanında geniş bir uygulama yelpazesi bulmuştur. Örneğin, sınıflandırma algoritmaları, spam filtreleme, tıbbi tanı, otomatik sürüş sistemleri ve daha birçok alanda kullanılarak karmaşık veri setlerini analiz etme, gruplandırma ve verileri anlam kazandırma gibi katkıları vardır. Köşe çıkarma algoritmaları, nesne tanıma, robot navigasyonu ve görüntü odaklı uygulamalarda kullanılarak önemli bilgi çıkarma işlemlerine katkıda bulunur. Bu algoritmaların etkili bir şekilde kullanılması, veri analizi ve bilgisayarlı görüş alanındaki teknolojik ilerlemelere ivme kazandırmaktadır.

3.1 Harris-Stephens Köşe Çıkarma Algoritması

Bir görüntüde köşeler görüntü parlaklığında ani değişiklikleri ile belirlenir. Harris-Stephens geliştirdikleri algoritma ile görüntüdeki her pikseli birbiri ilişkilendirerek karşılaştırma yapar. Bunu bir fonksiyon olarak belirtir. Otokorelasyon fonksiyonu olarak adlandırılır. Bu fonksiyon görüntünün küçük miktarlarda farklı yöne kaydırılmış değişkenlerini ölçer. Denklem ifadesi;

$$c(x, y) = \sum_w [I(x_i, y_i) - I(x_i + \Delta x, y_i + \Delta y)]^2 \quad (3.1)$$

Şeklinde. $I(x_i, y_i)$ ifadesi görüntünün matematiksel değerini temsil eder. x ve y merkezli W (Gaussian) penceresindeki noktalar olarak ifade edilir. Bu ifade Taylor serisi şeklinde bir yaklaşım ile aşağıdaki gibi gösterilir. I_x ve I_y ifadeleri x ve y 'nin kısmi türevlerini gösterir.

$$I(x_i, y_i) - I(x_i + \Delta x, y_i + \Delta y) \approx I \left(I(x_i, y_i) + [I_x(x_i, y_i)I_y(x_i, y_i)] \begin{bmatrix} \Delta x \\ \Delta y \end{bmatrix} \right) \quad (3.2)$$

Eşitlikler yerine koyularak hesaplamalar yapılırsa $c(x, y)$ ifadesinin son hali aşağıdaki gibidir.

$$c(x, y) = [\Delta x \ \Delta y] C(x, y) \begin{bmatrix} \Delta x \\ \Delta y \end{bmatrix} \quad (3.3)$$

$$C(x, y) = \sum_w \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} = \begin{bmatrix} m_{11} & m_{12} \\ m_{21} & m_{22} \end{bmatrix} \quad (3.4)$$

$$\lambda_{min} \approx \lambda_1 \lambda_2 / (\lambda_1 + \lambda_2) = \frac{\det(C)}{\text{tr}(C)} \quad (3.5)$$

$$\text{tr}(C) = m_{11} + m_{22} \quad (3.6)$$

$$R = \det(C) - k. (\text{tr}(C))^2 \quad (3.7)$$

$C(x, y)$ matrisi, karşılaştırılan matrisleri birbirine olan yakınlığını ifade eder. Bu matrisin λ_1, λ_2 iki öz değeri bulunur. Öz Değerler döndürme açısından bir açıklama sağlar. Üç duruma göre değerlendirme yapılır.

Birinci durum: Hesaplanan iki öz değerde küçükse, λ_1, λ_2 küçükse ($\lambda_1 \approx 0$, $\lambda_2 \approx 0$) C 'nin otokorelasyon fonksiyonu düz ya da küçük bir eğimli yapıdadır. Bu ifade görüntüde kenar ve köşe olmadığının göstergesidir.

İkinci durum: Eğer λ_1 büyük , λ_2 küçükse ($\lambda_2 \approx 0$) C 'nin otokorelasyon fonksiyonu yarım daire şeklindedir. Bu görüntüde bir kenar olduğunun ve bu kenar boyunca yoğunluktaki değişikliklerin önemli olduğu anlamına gelmektedir.

Üçüncü Durum: Her iki öz değer büyük olduğu durumdur. Bu durumda C 'nin otokorelasyon fonksiyonu sivri bir tepeye sahiptir. Bu görüntüde bir köşenin var olduğu anlamına gelmektedir.

$$R = \lambda_1 \lambda_2 - k(\lambda_1 + \lambda_2) = \det(C) - k. (\text{tr}(C))^2 \quad (3.8)$$


R eşitliği köşe olasılık fonksiyonu olarak adlandırılmaktadır. “k” sabit bir sayıdır ve 0.04-0.06 arasında değer alabilir. Öz değerlerin bulunup değerlendirildiği gibi bu eşitlikte değerlendirilebilir. Sınıflandırma işlemi pencere, kenar, köşe veya herhangi bir adlandırma ile yapılır. Bu işlem de hesaplanan R değeri ile alakalıdır. Değerin yüksek çıkması görüntüde köşelerin var olduğunu göstergesidir. (λ_1 ve λ_2 en üstte, nokta köşedir), R negatif bir değer hesaplanıyorsa bir kenar olduğunu gösterir (λ_1 en üstte ve λ_2 en altta) (Kadhim, H. A., & Araheemah, W. A. , 2019) (Derpanis, K. G. 2004) (Harris, C., & Stephens, M. ,1988, August).

3.2 Shi-Tomasi Köşe Çıkarma Algoritması

Görüntü işlemede bir resmin köşe noktalarını belirlemeye, filtrelemeye yarayan bir diğer algoritmadır Shi ve ark. 1994 yılında geliştirmiştir. Shi-Tomasi Köşe çıkarma algoritması Harris-Stephens algoritmasına dayalı bir algoritmadır. Harris algoritmasından farklı olarak, tüm pikseller için bir hesaplama yapar ve daha sonra belli bir eşik değerleri ile karşılaştırarak hesaplamaları değerlendirir. Harris ve ark. Köşe hesaplamasını köşe olasılık fonksiyonu (R), bir matrisin öz değerleri ile ilişkilendirilen denklem ifadesi önermişti. Shi ve ark. ise köşe bulucusu bu fonksiyonun atılması gerektiğini önermiştir. Sadece öz değerler ile piksellerin ilişkili olup olmadığı test edilmesi gerektiğini savunmuştur. Verimli sonuçlara ulaşmak için, yapısal verilerin öz değerlerinin mutlak değerlerinin minimumunu hesaplayarak Harris köşe bulma yönteminde küçük bir iyileştirme yapmışlardır.

$$R = \text{Minimum}(\lambda_1 \lambda_2) \quad (3.9)$$

Shi ve ark., bu hesaplama kriterinin çok daha iyi olduğunu deneysel olarak kanıtlamıştır. Köşeler, R'nin yerel maksimumlarıdır. R değeri belirli bir değerle karşılaştırılarak, eğer bu değerden büyükse, köşe olarak işaretlenebilir.



Şekil 3.1: Shi-Tomasi ile Harris-Stephen dedektörü (Gandhi 2018).

3.3 Förstner Köşe Tespiti

Förstner köşe tespiti, köşeleri tespit etmek için görüntüdeki yoğunluk ve gradient değişikliklerini kullanır. Algoritma, her pikselin bir köşe adayı olup olmadığını belirlemek için çeşitli özellikler kullanır ve bu adayları doğrulukla sınıflandırır. Algoritma, köşenin ideal bir durumda, teğet çizgilerinin hepsinin tek bir noktada kesiştiği gerçeğine dayanmaktadır. Uygulamada bu pek mümkün değildir optimum teğet çizgileri belirlenmeye çalışılır. Köşe olarak belirlenen bir pikselin x' noktasında teğet çizgisinin denklem ifadesi;

$$T_{x'}(x) = \nabla I(x')^T (x - x') = 0 \quad (3.10)$$

Şeklindedir. $\nabla I(x') = [I_x \ I_y]^T$ I'nin x' noktasındaki gradyan vektörünü temsil etmektedir. Köşenin bulunduğu nokta, tüm teğet çizgilerine en yakın nokta x_0 aşağıdaki şekilde hesaplanır:

$$x_0 = \operatorname{argmin} \int T_{x'}(x)^2 dx' \quad x \in R^{2*1} \quad x' \in N \quad (3.11)$$

Güçlü gradyanlara sahip piksellerden geçen teğetlere filtrelendir. x_0 ifadesinin çözümü de aşağıda verilmiştir.

$$x_0 = \operatorname{argmin} \int (\nabla I(x')^T (x - x'))^2 dx' \quad (3.12)$$

$$x_0 = \operatorname{argmin} \int (x - x')^T \nabla I(x') \nabla I(x')^T (x - x') dx' \quad (3.13)$$

$$x_0 = \operatorname{argmin} (x^T A x - 2x^T b + c) \quad (3.14)$$

$$A \in R^{2 \times 2}, b \in R^{2 \times 1} \quad c \in R \quad (3.15)$$

x_0 ifadesini doğrusal denklem ifadesine eşitlemek için (minimize) x e göre türev alıp sıfıra eşitlenir.

$$Ax = b \quad (3.16)$$

$$2Ax - 2b = 0 \quad (3.17)$$

Burada $A \in R^{2 \times 2}$ yapı tensorü anlamına gelmektedir, Bir fonksiyonun gradyanından elde edilen bir matris ifadesidir. A matrisinin tersi alınabilir olduğu durumlarda denklem ifadesinin bir çözümü mevcuttur. Denklem ifadesinin bir çözümü mevcut olabilmesi için A matrisi tam sıralı(rank) olması gerekir. Yani bu matris lineer bağımsız olması gerekir. Bunun sonucunda çözüm mümkün olur.

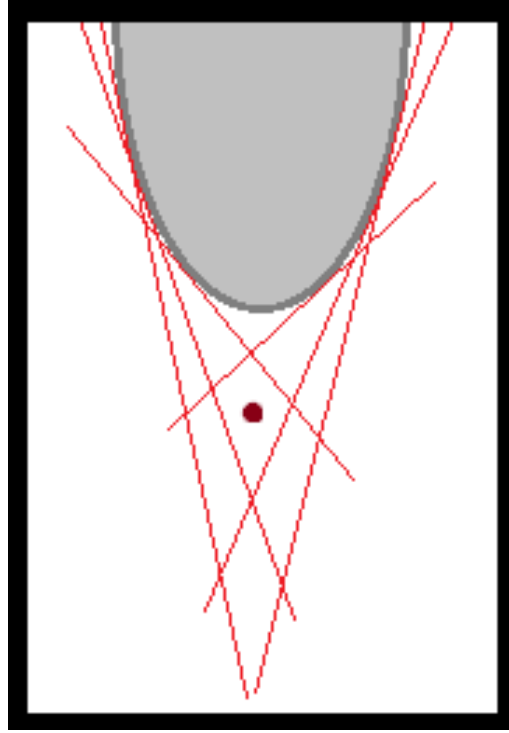
$$x_0 = A^{-1}b \quad (3.18)$$

Bu köşe yerleştirme yöntemi için otomatik ölçek seçimi yapma metodolojisi, Lindeberg (1994). tarafından sunulmuştur. Bu metodoloji, normalize edilmiş bir hata terimini minimize ederek ölçekleri otomatik olarak ayarlar:

$$\tilde{d}_{min} = \frac{c - b^T A^{-1} b}{\operatorname{trace}(A)} \quad (3.19)$$

Bu sayede yöntem, görüntü verilerindeki gürültü seviyesine göre gradyanların hesaplanmasında daha kalın ölçek seviyelerini seçerek gürültülü görüntü verileri için

daha kalın ölçek seviyelerini ve köşeye benzeyen yapılar için daha ince ölçek seviyelerini otomatik olarak seçme yeteneğine sahiptir.



Şekil 3.2: Förstner Köşe Tespiti (Wikipedia 2012).

3.4 K-means Algoritması

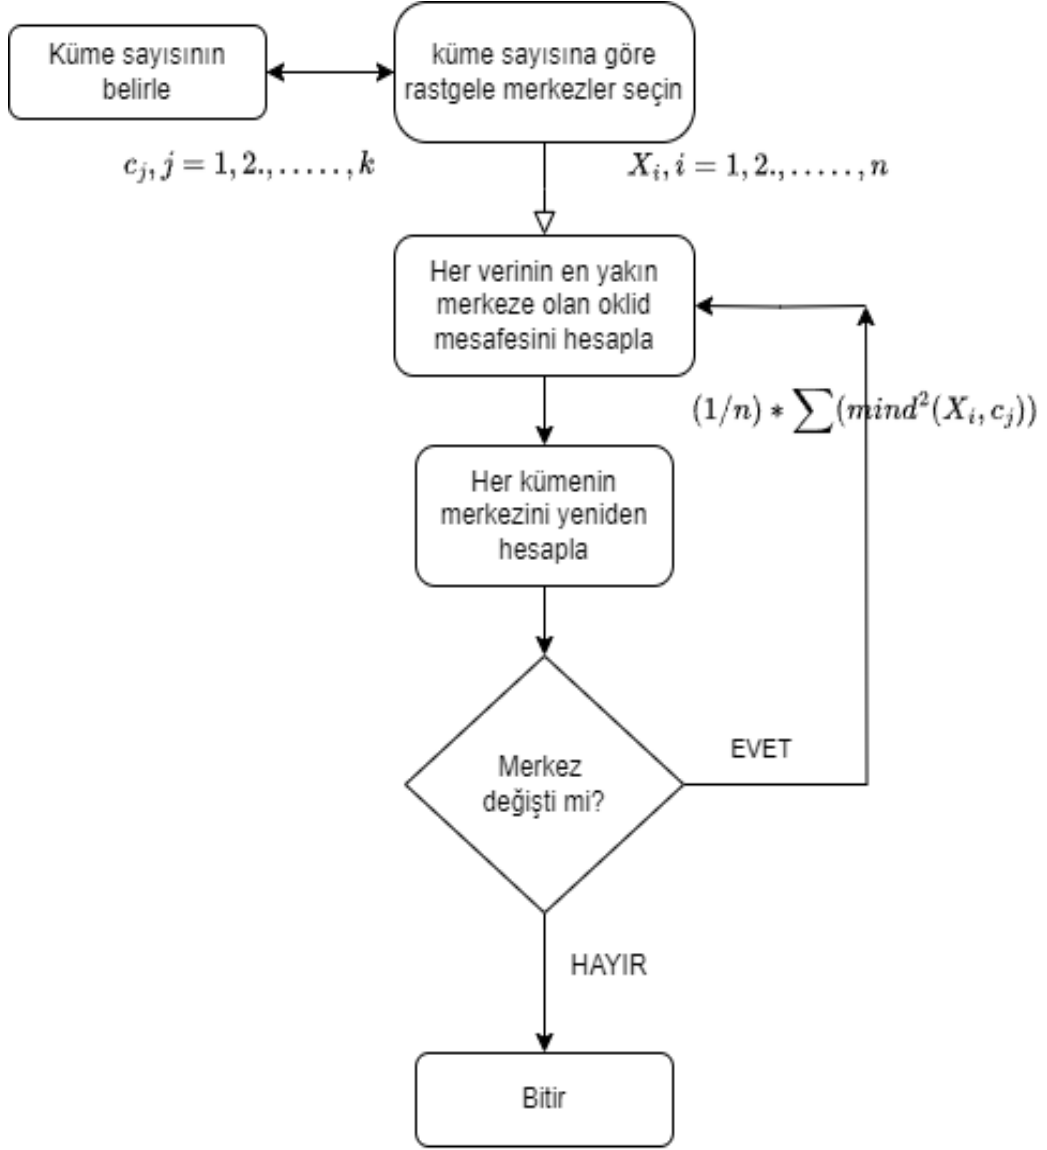
Bir veri setini işlemek, verinin analizi ve kümeleme işlemleri oldukça önemlidir. K-means algoritması, bu verileri kümelerine ayırarak anlamlı ve kullanışlı hale getirmek için sıklıkla kullanılan bir tekniktir. Algoritma, verileri küme merkezlerine olan benzerliklerine göre gruplandırır. Bu benzerlik, veri noktalarının belirli bir merkeze ne kadar yakın olduğu ile belirlenir. Denklem ifadesi aşağıda verilmiştir.

$$\mu_i = \frac{1}{|S_j|} \sum_{x_i \in S_j} x_i \quad (3.20)$$

$$\arg \min_s \sum_{j=1}^K \sum_{x_i \in S_j} \|x_i - \mu_j\|^2 \quad (3.21)$$

x , $i = 1, 2, \dots, N$ tane gerçek vektörden oluşan bir veri kümesini ifade eder. Algoritma bu verileri K tane $S = \{S_1, S_2, \dots, K\}$ kümeye bölmeyi hedefler. Bu bölümlenme işlemi, her bir veri noktasını K küme merkezi ile en yakın olan kümeye atayarak gerçekleştirilir. Aynı zamanda, bu işlem sırasında toplam kare hatayı (mesafe) minimize etmeye çalışır. Yani, her veri noktasının ait olduğu küme merkezine olan mesafesi toplamı mümkün olduğunca düşük olacak şekilde kümeleri oluşturur. Bu, verilerin daha iyi anlaşılmasına ve gruplandırılmasına yardımcı olur.

K-means algoritması birçok farklı alanda başarıyla kullanılır. Pazarlama alanında müşterileri farklı gruplara ayırmak ve pazarlama yöntemini optimize etmek için kullanılabilir. Görüntü işleme uygulamalarında benzer nesnelere veya renkleri algılamak için kullanılabilir. Haberler ve makaleleri birbirleri ilişkilendirilen konuları bir grup haline getirmek için K-means yöntemi kullanılabilir. K-means sınıflandırma yönteminin algoritma akış şeması Şekil 3.3'te verilmiştir.

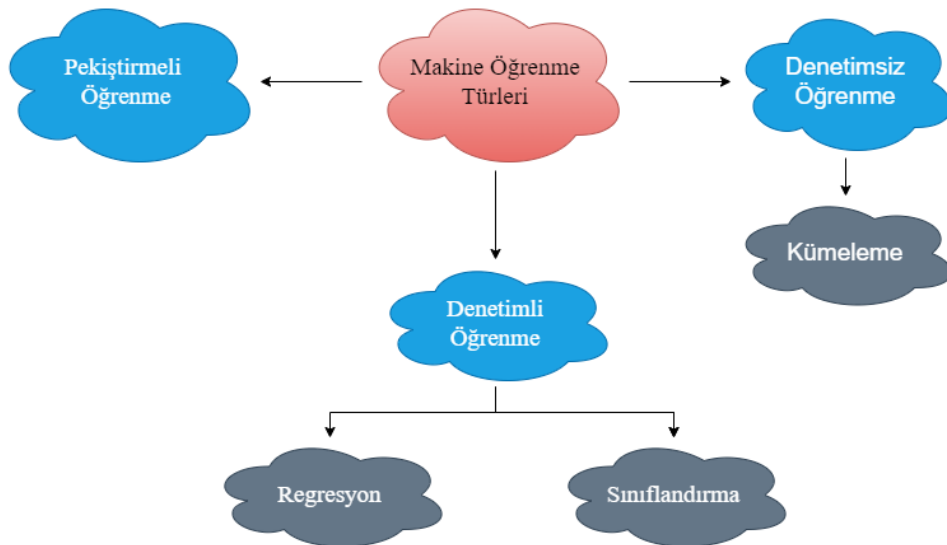


Şekil 3.3: K-means algoritma akış diyagramı.

4. ÖĞRENME ALGORİTMALARI

İnsanların öğrenme yetisini bilgisayar sistemlerine aktarmayı amaçlayan makine öğrenme, yapay zekâ alanının önemli bir alt dalıdır. Makine öğrenme, yapay zekâ alanında büyük bir devrim yaratmış ve bilgisayar sistemlerini kendi başlarına öğrenme ve verileri analiz etme yetisi kazandırmıştır. Bu alandaki geliştirilen algoritmalar, bilgisayarların deneyimlerinden öğrenmelerini ve verileri analiz karmaşık görevleri gerçekleştirmesini sağlar. Makine öğrenme modellerinin ana hedefi, bu verilerdeki gizli desenleri ortaya çıkarmak ve bunları tahminlerde veya sınıflandırmalarda kullanılabilir hale getirmektir.

Makine öğrenme algoritmaları, eğitim verilerine dayalı olarak belirli parametreleri kullanır ve bu verilere dayanarak sonuçlar üretir. Eğitim verileri, algoritmaların dünyayı daha iyi anlamalarına ve karmaşık veri setlerini işlemelerine yardımcı olur. Bu verilerin çeşitliliği ve zenginliği arttıkça, makine öğrenme algoritmaları daha kesin sonuçlar üretebilirler. Makine öğrenme algoritmaları, denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olmak üzere 3 başlık altında türleri mevcuttur. Bu algoritmaların yaygın olarak kullanıldığı uygulama alanları arasında veri madenciliği, otomasyon, yapay zekâ tabanlı öneri sistemleri ve daha fazlası bulunmaktadır. Makine öğrenme, veri işleme ve karar verme süreçlerini geliştirmek ve optimize etmek için güçlü bir araçtır (Boyacı 2022).



Şekil 4.1: Makine Öğrenimi Çeşitleri.

4.1 Denetimsiz Öğrenme

Denetimsiz öğrenme, etiketlenmemiş verilerle çalışır ve veri kümesindeki gizli yapıları keşfetmeyi amaçlar. Bu tür algoritmalar, veri içindeki örüntüleri veya yapıları belirlemeye çalışır. Örneğin, kümeleme algoritmaları benzer veri noktalarını gruplandırmak için kullanılırken, boyut azaltma algoritmaları veri setlerini daha az karmaşık bir şekilde temsil etmek için kullanılır. Denetimsiz öğrenme, veri sıkıştırma ve veri görselleştirmesi gibi birçok uygulamada kullanılır.

4.2 Takviyeli Öğrenme

Takviyeli öğrenme, bir ajanın belirli bir çevre içinde belirli bir hedefe ulaşmak için nasıl hareket etmesi gerektiğini öğrenmeyi amaçlar. Bu algoritmalar, ajanın çevresiyle etkileşime girdiği durumlar üzerinden öğrenme sağlar. Örneğin, otonom araçlar, oyun oynayan yapay zekâ ajanları ve robotlar, takviyeli öğrenme kullanarak karmaşık görevleri gerçekleştirmeyi öğrenebilirler. Bu algoritmalar, oyun stratejileri oluşturmak, robot kontrolü ve otomasyon sistemleri gibi uygulamalarda önemli bir rol oynar.

4.3 Denetimli Öğrenme


Denetimli makine öğrenme, adından da anlaşılacağı gibi "denetim" altında gerçekleşir. Bu, eğitim sürecinin bir öğretmen veya uzman tarafından yönlendirildiği ve etiketli verilerin kullanıldığı anlamına gelir. Denetimli öğrenme, bir sistem veya modelin girdi verilerini analiz ederek doğru çıktıları üretmesini sağlamayı amaçlar.

Denetimli makine öğrenme süreci, doğru sonuçları öğrenmek için kullanılan etiketlenmiş verilere dayanır. Bu veriler, genellikle eğitim verileri olarak adlandırılır ve her bir girdiye karşılık gelen doğru çıktılarıyla işaretlenmiştir. Model eğitimi, denetimli makine öğrenme sürecinin temel adımıdır. Bu adımda, veriler modele sunulur ve model, bu verilere dayalı olarak çıktıları tahmin etmeyi öğrenir. Algoritma, veriler arasındaki desenleri ve ilişkileri tanımak için eğitilir. Bu, doğru tahminler yapabilmek için gereken içsel parametrelerin ayarlanmasını içerir. Eğitim sonrasında,

modelin performansını deęerlendirmek için test ve doęrulama ařamaları gelir. Bu ařamada, öğrenme sürecinin bir parçası olarak kullanılmayan veriler kullanılır. Modelin, bu yeni verilere dayalı olarak ne kadar iyi tahminler yapabildięi deęerlendirilir. Bu adım, modelin aşırı uydurmadan kaçınmasını ve genelleme yeteneęini deęerlendirmeyi amaçlar. Eęitilmiş model, gerçek dünya verilerine dayalı tahminlerde bulunmak veya sınıflandırmalar yapmak için kullanılabilir.

Makine öğrenme, temel olarak sınıflandırma ve tahmin problemlerini çözmek için kullanılan iki ana kategoriye ayrılır. Sınıflandırma algoritmaları, test verilerinde belirli farklılıkları tespit ederek bu verileri farklı kategorilere ayırmak için tercih edilir. Önde gelen sınıflandırma algoritmaları arasında Destek Vektör Makineleri (SVM), Doğrusal Sınıflandırıcılar, K-En Yakın Komşu (K-Nearest Neighbors / KNN), Rastgele Orman (RO) ve Karar Ağaçları (KA) bulunur. Regresyon algoritmaları ise bağımsız ve bağımlı deęişkenler arasındaki ilişkiyi anlamak ve tahmin etmek için kullanılır. Önde gelen regresyon algoritmaları arasında Doğrusal Regresyon (DR), Karar Ağaçları (KA), K-En Yakın Komşu (KNN), ve Rastgele Orman (RO) algoritmaları yer alır.

4.3.1 Doğrusal Regresyon Algoritması



Şekil 4.2: Doğrusal Regresyon Modeli Çıktısı (Şener 2020).

Makine öğrenme alanında yaygın olarak kullanılan bir istatistiksel regresyon tekniğidir. Veri setinde bulunun herhangi bir değişiklikte etkilenmeyen değerlerin bağımlı değişkenlere etkilerini analiz etmek amacıyla kullanılır.

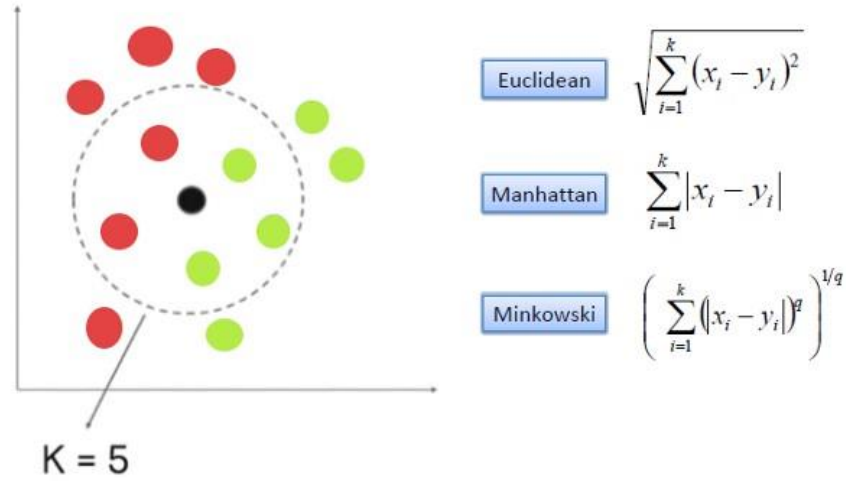
Doğrusal regresyonun temel amacı, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini tanımlamaktır. Bu, değişkenler arasındaki ilişkiyi anlamak ve gelecekteki değerleri tahmin etmek için kullanılır. Basit regresyon ve çoklu regresyon olmak üzere iki türde incelenir. Basit regresyon, yalnızca bir bağımsız değişkenin bağımlı değişken üzerindeki etkisini modellemek için kullanılırken, çoklu regresyon birden fazla bağımsız değişkenin etkisini aynı anda incelemek için kullanılır. Doğrusal regresyon, bağımsız değişkenlerin bağımlı değişken üzerinde doğrusal bir ilişkiye sahip olduğunu varsayar. Bu, bir bağımsız değişkenin artışıyla bağımlı değişkenin tahmin edilen artışı arasında doğrusal bir ilişki olduğu anlamına gelir. Bir doğrusal katsayılar, bağımsız değişkenlerin etkilerini temsil eder. Model, bu katsayıları veri üzerinden tahmin eder. Doğrusal regresyon modellerinin performansı, genellikle belirli bir hedefi ne kadar iyi tahmin edebildiklerini değerlendirmek için kullanılan metriklerle ölçülür. Bu metrikler arasında R-kare (R-squared), ortalama kare hata (MSE), ve belirli uygulamaya bağlı olarak diğerleri bulunur.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n + \epsilon \quad (4.1)$$

Bu modelde y çıkışı temsil eder. Bağımsız giriş değişkenleri x_n olarak gösterilmiştir. β değerleri doğrusal denklem ifadesinin kat sayı değerlerini ve regresyon sabiti de ϵ olarak ifade edilir. Burada β katsayılarını en doğru şekilde belirleyerek bağımlı değişken y çıkışı hesaplanır

4.3.2 K-NN Algoritması

K-En Yakın Komşu (KNN), veri madenciliği ve makine öğrenme alanında sıkça kullanılan bir sınıflandırma ve regresyon algoritmasıdır. Bu algoritma, veri noktaları arasındaki benzerlik ölçütlerini kullanarak belirli bir veri noktasını sınıflandırma veya tahmin etme görevlerinde oldukça etkilidir.



Şekil 4.3: KNN yapısı (Tafralı 2022).

Basit bir ilkeye dayanır: "Bir nokta, komşularının çoğunluğuna benzer." Yani, bir veri noktasının sınıflandırılması veya tahmin edilmesi için, bu noktanın en yakın komşularının sınıf etiketleri veya değerleri dikkate alınır. KNN, veri noktaları arasındaki benzerlikleri ölçmek için farklı metrikler kullanabilir. Şekil 4.3'te gösterilen Euclidean mesafe, Manhattan mesafe veya kosinüs benzerliği gibi metrikler yaygın olarak kullanılır. KNN algoritması, herhangi bir veri noktasının sınıflandırılması veya tahmin edilmesi için kullanılacak komşu sayısını belirlemek için bir K değeri gerektirir. K, çoğunluk sınıfını veya ortalamayı belirlemek için kullanılır. Küçük K değerleri (örneğin K = 1) modeli daha hassas hale getirirken, büyük K değerleri (örneğin K = 10) modelin daha genel olmasını sağlar. KNN modeli eğitim aşamasında veri noktalarını ve sınıf etiketlerini veya değerleri öğrenir. Tahmin aşamasında, yeni bir veri noktası verildiğinde, bu noktanın K en yakın komşusunu belirler ve bu komşuların çoğunluğuna dayanarak sınıflandırma veya tahmin yapar.

KNN, önceden ayarlanmış karmaşık parametreleri içermez. Bu, başlangıçta anlaması ve uygulaması kolay hale getirir. Ayrıca, sonuçlar açık ve yorumlanabilir olduğu için özellikle regresyon problemlerinde tercih edilir. KNN, sınıflandırma ve regresyon problemlerinin yanı sıra veri madenciliği, öneri sistemleri, tıp (örneğin, hastalık teşhisi), görüntü işleme ve metin sınıflandırma gibi birçok farklı uygulama alanında kullanılır.

$$y = \frac{1}{k} \sum_{n=1}^N b_n \quad (4.2)$$

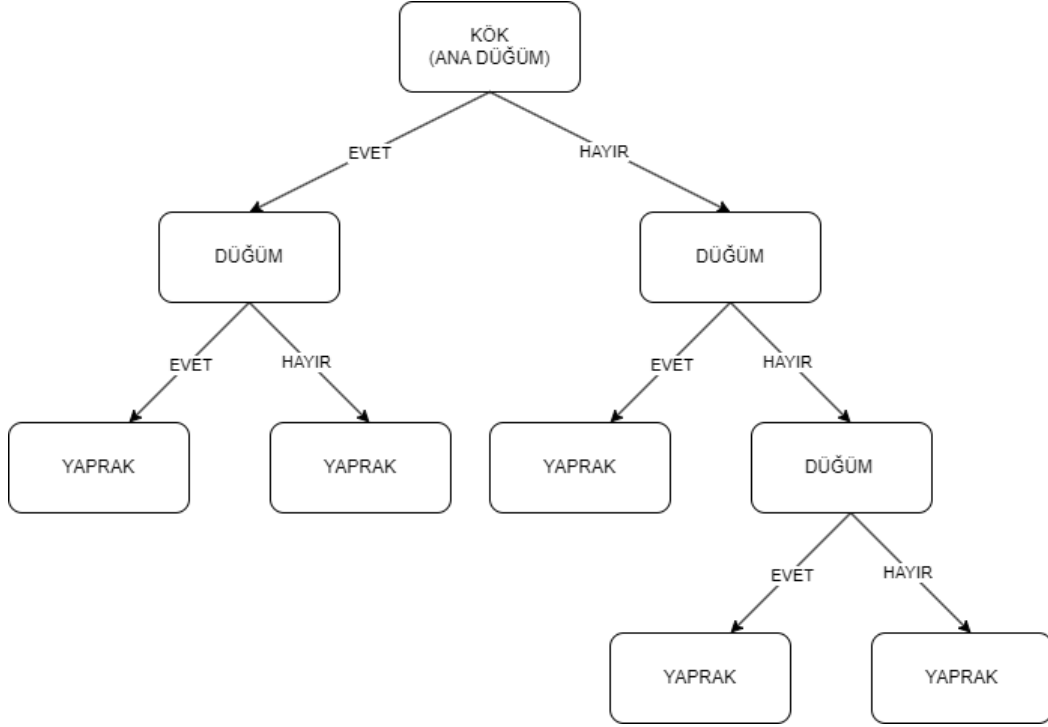
Komşu sayısı k , uzaklık ifadesi b_n olarak ifade edilir. Algoritma girdi bilgilerine göre en yakın k tane komşuları belirler ve ortalamasını alır. Algoritma, basit ve etkilidir, ancak büyük veri setlerinde hesaplama maliyeti yüksek olabilir. k değerini iyi seçmek ve veri özelliklerini dikkate almak, KNN'nin başarısını büyük ölçüde etkileyebilir. Bu nedenle, KNN'nin avantajları ve sınırlamaları iyi anlaşılmalı ve uygulama bağlamında dikkate alınmalıdır.

4.3.3 Karar Ağacı Algoritması

Karar Ağacı, veri madenciliği ve makine öğrenme alanında yaygın olarak kullanılan bir sınıflandırma ve regresyon algoritmasıdır. Bu algoritma, veri setlerini analiz ederek karar ağaçları oluşturur ve bu ağaçlar üzerinden veri sınıflandırma veya tahmin etme görevlerini gerçekleştirir.

Algoritmanın çalışma prensibi "Eğer-sonra" (if-then) kurallarını kullanarak veri sınıflandırma ve tahmin yapmasıdır. Bu kurallar, bir ağaç yapısında öğrenilir ve bu yapı, verileri ağaç dallarında kararlar alarak sınıflandırır. Karar Ağacı, kök düğüm (root node) olarak başlar ve ardışık karar düğümleri (decision nodes) ve yaprak düğümleri (leaf nodes) eklenerek büyür. Karar düğümleri, belirli özelliklerin değerlerine göre veri kümesini bölerken, yaprak düğümleri sonuç sınıflarını veya tahminleri içerir. Karar Ağacı, hangi özelliklerin verileri bölmek ve sınıflandırmak için kullanılacağını belirler. Özellik seçimi, verilerin sahip olduğu değerlere ve veri setinin yapısına göre yapılır. Özelliklerin sıralanması, hangi özelliğin kök düğümde kullanılacağını belirler. Kök düğümden başlayarak veri kümesini böler ve kararlar alır. Her düğüm, bir eşik değeri belirler ve bu eşik değeriyle verileri iki veya daha fazla alt küme halinde böler. Bu işlem, veri noktalarının sınıflandırılmasını sağlar. Verilerin daha fazla alt kümelere bölünmesi ve her alt kümenin sınıflandırılmasıyla büyür. Bu işlem, karar ağacının daha derin dallara sahip olmasını sağlar ve daha fazla kural oluşturur. Karar Ağacı algoritması, ağacın büyüklüğünü kontrol etmek için parametreler içerir. Dallanma kriterleri, ağacın hangi düğümlerde bölüneceğini

belirler. Örneğin, bilgi kazancı (information gain) ölçülüp en yüksek olan ağacın en üstüne atanır. Doğruluk, hassasiyet ve diğer performans metrikleri kullanılarak değerlendirilir. Ayrıca, aşırı uyum (overfitting) problemlerini önlemek için ağacın derinliği sınırlanabilir.



Şekil 4.4: Karar Ağacı Yapısı.

$$H(x) = \sum p(x) \log_2 p(x) \quad (4.3)$$

$$Gain(S, x) = H(S) - \sum P(x) H(x) \quad (4.4)$$

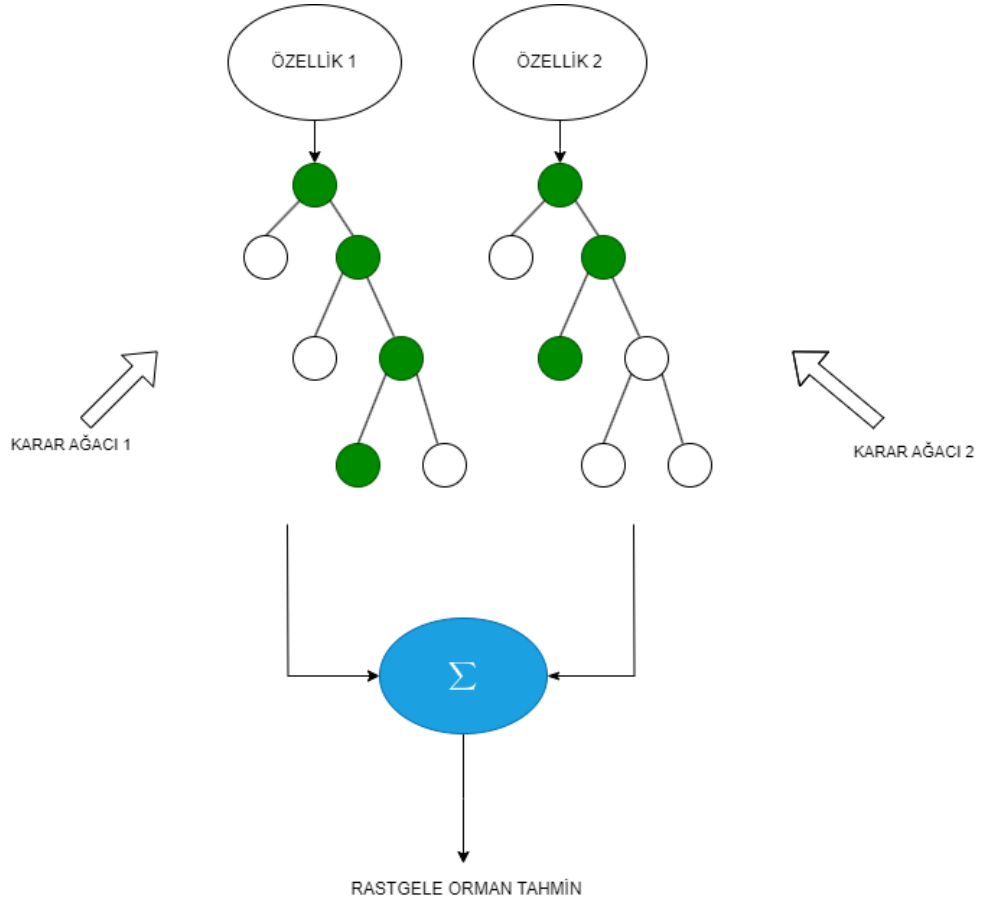
Entropi, bir veri kümesinin düzensizliğini veya belirsizliğini ölçen bir terimdir. Veri kümesi içindeki farklı sınıfların dağılımı ne kadar dengesizse, entropi o kadar yüksektir. $H(x)$, bir belirli bir veri kümesi x için entropiyi ifade eder. $p(x)$, veri kümesindeki belirli bir sınıfın olasılığını temsil eder. Her farklı sınıf için bu terim hesaplanır ve toplanır. Entropi, 0 ile 1 arasında bir değer alır, 0 tamamen düzenli (tüm veriler aynı sınıfa aittir), 1 ise tamamen düzensiz bir veri kümesini (veriler rastgele dağılmış) temsil eder. $Gain(S, x)$ (Bilgi Kazancı), bir veri kümesini belirli bir özellik (x) kullanarak bölmenin ne kadar bilgi kazandıracığını hesaplayan bir terimdir. S ,

orijinal veri kümesini temsil eder. Bilgi kazancı, orijinal entropi ($H(S)$) ile belirli bir özelliği (x) kullanarak veriyi böldüğünüzde elde edilen yeni entropi ($H(S)$) arasındaki farkı ifade eder. $P_{(x)}$, veri kümesindeki belirli bir özelliği (x) kullanarak veriyi bölerken ortaya çıkan alt küme olasılığını temsil eder. $Gain(S, x)$ değeri, bir özelliği kullanarak veriyi böldüğümüzde kazandığımız bilgi miktarını ölçer. Daha yüksek bilgi kazancı, daha iyi bir özellik bölümü anlamına gelir.

4.3.4 Rastgele Orman Algoritması

Rastgele Orman (Random Forest), makine öğrenme alanında popüler ve güçlü bir sınıflandırma ve regresyon algoritmasıdır. Bu algoritma, birçok karar ağacının bir araya getirilmesiyle oluşturulan bir ansambl (ensemble) yöntemidir.

Veri örnekleri ve özellikler rastgele olarak seçilir. Bu, her bir karar ağacının farklı bir alt kümeyle eğitilmesini sağlar. Aynı zamanda, her düğümde rastgele bir alt küme özellikleri kullanılır. Bu rastgele dağılım, ağaçların çeşitlenmesini ve aşırı uyumun (overfitting) önlenmesini sağlar. Rastgele Orman'da bir veri noktasının sınıflandırılması veya bir değer tahmin edilmesi için tüm karar ağaçlarının sonuçları toplanır (sınıflandırma için oylama, regresyon için ortalama). Sonuçlar, çoğunluk kararı veya ortalama sonuç olarak kabul edilir. Rastgele dağılım sayesinde, ağaçların varyasyonu artırılır ve bu da daha güçlü bir model oluşturur. Ayrıca, rastgele ormanlar, aşırı uyumun etkilerini azaltır ve genelleme yeteneğini artırır. Rastgele Orman, her özelliğin sınıflandırmadaki veya regresyondaki önemini değerlendirmek için kullanılabilir. Özellik önemi, her bir özelliğin bilgi kazancına göre hesaplanır ve hangi özelliklerin daha fazla katkı sağladığını gösterir.



Şekil 4.5: Rastgele Orman yapısı.

4.4 Öğrenme Algoritmalarında Değerlendirme Kriterleri

Günümüzde, makine öğrenmesi alanındaki hızlı gelişmeler, çeşitli öğrenme algoritmalarının keşfedilmesine ve uygulanmasına olanak sağlamıştır. Bu algoritmalar, geniş bir uygulama yelpazesi içinde kullanılmakta olup, performanslarını değerlendirmek için belirli kriterlere ihtiyaç duyarlar. Öğrenme algoritmalarının etkili bir şekilde değerlendirilmesi, algoritmaların güvenilirliği, doğruluğu ve genel performanslarının anlaşılmasına katkıda bulunur.

Değerlendirme kriterleri, bir öğrenme algoritmasının başarı ölçütlerini belirlemede kullanılan ölçümler ve metrikleri içerir. Değerlendirme ölçütleri olarak Ortalama Kare Hatası (MSE), Kök Ortalama Kare Hatası (RMSE), Ortak Mutlak Hata (MAE), R^2 Determinasyon Katsayısı ölçütleri üzerinde durulmuştur.

4.4.1 Ortalama Kare Hatası (MSE)

MSE, tahminlerin gerçek değerlerden ne kadar sapma gösterdiğini ölçen bir metrik olarak işlev görür. Bir modelin tüm tahminlerinin hatalarının karelerinin ortalamasını hesaplar. Hataların kareleri alındığı için negatif değerler ortay MSE, regresyon modellerinin performansını değerlendirmek ve farklı modelleri karşılaştırmak için sıkça kullanılır. Daha düşük MSE, daha iyi bir model performansını gösterir. Ayrıca, MSE'nin biriminin karesi, orijinal veri birimlerinin karesidir.

$$MSE = \frac{1}{N} \sum_i^N (y_i - y'_i)^2 \quad (4.5)$$

MSE, regresyon problemlerinde yaygın olarak kullanılan bir metrik olmasına rağmen, tek başına model performansını değerlendirmek için yetersiz olabilir. Diğer metrikler ve modelin bağlamı da dikkate alınmalıdır. MSE, modelin tahminlerinin ne kadar yakın olduğunu ve ne kadar hata yaptığını değerlendirmek için önemli bir araçtır.

4.4.2 Kök Ortalama Kare Hatası (RMSE)

RMSE, modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini değerlendirmek için kullanılır. Bir modelin tahminlerinin ne kadar iyi olduğunu değerlendirir. Daha düşük bir RMSE, daha iyi bir model performansını gösterir. Bu nedenle, bir regresyon modelinin başarısını değerlendirmek için kullanılan bir ölçüttür. Temelde, hata karelerinin ortalamasının karekökü olarak ifade edilir ve aşağıdaki şekilde hesaplanır.

$$RMSE = \sqrt{\frac{1}{N \sum_i^N (y_i - y'_i)^2}} \quad (4.6)$$

4.4.3 Ortak Mutlak Hata (MAE)

MAE, bir modelin tüm tahminlerinin gerçek değerlerden sapma miktarlarının mutlak değerlerini alır. MAE, veri seti içindeki hataların mutlak büyüklüğünü hesapladığı için bazen model performansını daha iyi bir şekilde yorumlamak için kullanılır. Ancak, her ölçüm metriği gibi, MAE'nin de sınırlamaları vardır ve modelin bağlamı ve uygulama gereksinimleri de göz önünde bulundurulmalıdır. Her hata negatif veya pozitif olsa da hataların büyüklüğü aynıdır. Bu, bazen modelin performansını daha yavaş bir şekilde değerlendirmesine neden olabilir. Özellikle bazı uygulamalarda, büyük hataların küçük hatalara göre daha fazla etkisi olması gerekebilir. Bu tür durumlarda, Ortalama Kare Hata (MSE) veya diğer hata metrikleri daha uygun olabilir.

$$MAE = \frac{1}{N} \sum_i^N |y_i - y'_i| \quad (4.7)$$

4.4.4 R^2 Determinasyon Katsayısı

Regresyon analizlerinde kullanılan bir istatistiksel ölçüdür. Bir regresyon modelinin bağımsız değişkenlerin bağımlı değişkeni ne kadar iyi açıkladığını ölçer. Genellikle "varyansın açıklanma yüzdesi" olarak yorumlanır. İlk olarak ortalama farkların toplamı hesaplanır. Daha sonra gerçek değer ile tahmin edilen değerler çıkarılarak hataların karelerin toplamı hesaplanır.

$$OFT = \sum_i^N (y_i - y_{ort})^2 \quad (4.8)$$

$$HKT = \sum_i^N (y_i - y'_i)^2 \quad (4.9)$$

Bağımlı değişkenin (genellikle hedef değişken) varyansı ile regresyon modelinin tahmin ettiği varyans arasındaki oran olarak hesaplanır. Aşağıdaki formülle ifade edilir.

$$R^2 = 1 - \frac{HKT}{OFT} \quad (4.10)$$

R^2 değeri 0 ile 1 arasında değişir. Eğer 0'a yakınsa, bu, bağımsız değişkenlerin bağımlı değişkeni açıklamada hiçbir katkısı olmadığı anlamına gelir. 1'e yakınsa, bu, bağımsız değişkenlerin bağımlı değişkeni mükemmel bir şekilde açıkladığı anlamına gelir. R^2 bir regresyon modelinin açıklama gücünü ölçer. Yani, modelin tahminleri gerçek değerleri ne kadar iyi açıklıyor? Örneğin, R^2 değeri 0.75 ise, bağımsız değişkenler bağımlı değişkenin varyansının %75'ini açıklar. R^2 , farklı modelleri veya değişkenleri karşılaştırmak için kullanışlıdır. Ancak, tek başına bir modelin başarısını belirlemek için yetersizdir. Modelin diğer faktörlerini, hata dağılımını ve uygulama bağlamını dikkate almak önemlidir.

5. YÖNTEM

Su altında gerçekleştirilen haritalama ve konumlandırma işlemleri açık denizlerde akustik sistemlerin birbirleri arasında kurulan iletişimler sayesinde olmaktadır. Keşif ya da görev yapılacak alanın önceden belirlenip bu alanda su altı aracı üzerinde bulunan bir akustik sensörün o alanda yerleştirilen diğer sensörlerden aldığı ses sinyallerine göre bir konumlandırma yapılmaktadır. Uygulanacak olan yöntem kapalı bir alanda bir su altı aracının konumunu tahmin etmek için geliştirilmiştir. Yöntem belirlenirken bir veri setinin sınıflandırmasında verileri belirli gruplara ayırıp analiz etmede sıklıkla kullanılan bazı yöntemler mevcuttur. K-means yöntemi de bu tekniklerden birisidir.

Bu çalışma 2 adımı içermektedir. İlk adım Bir su altı aracı suya bırakıldığında üstünde bulunan tarama sonarı sayesinde etrafın haritasını çıkarır. Bu haritadan kapalı alanın köşeleri tahmin edilir ve bu köşelere göre aracın konumu belirlenir. Bu tahmin K-means kümeleme algoritması kullanılarak yapılır. 2. adımda ise aracın hareketi öğrenme algoritmaları ile tahmin yapılarak ne kadar yol aldığı hesaplanmaktadır. Burada Knn, Rastgele Orman, Karar Ağaçları algoritmalarıyla oluşturulan model ve karşılaştırmaları denenmiştir. Aracın üstünde bulunan mesafe sensörlerinden alınan veriler ile model eğitilmiştir.

Tablo 5.1: Köşe Tespiti Algoritması Akış Diyagramı.

ALGORİTMA: Sınıflandırma ve Köşe Tespiti

1: Su altı aracı düz bir şekilde ortama bırakılır. IMU sensöründen dönme açısı verisi istenir

2: 360 derecelik Sonar taraması başlatılır.

3: 400*1200 lük veriler Kartezyen koordinat sisteminden kutupsal koordinat sistemine dönüştürülür.

4: IMU sensöründeki dönme miktarına göre tarama sonucunun düzeltilir.

5: Tarama sonucunda görüntüdeki gürültüleri azaltmak için “normalizasyon” işlemi yapılır.

6: Matris verilerini sonar ile yapılan tarama mesafesine oranlama işlemi yapılır

7: Oranlanmış verileri k-means kümeleme yöntemi ile gruplara ayır.K-means merkezleri hesaplanır.

8: Su altı üzerinde bulunan sonarın araç çevresi kadar etrafındaki verileri temizleme işlemi yapılır.

9: Aracın merkezi koordinat sisteminin başlangıç noktası olarak (0,0) alınır.Her bir merkez noktasının başlangıç noktasına olan açıları hesaplanır ve bu açılara göre merkezleri (0-360°) sıralanır.

10: K-means ile kümelenen merkezleri anlamlı hale getirilir. Her bir merkez noktası sol_kenar, ön_kenar, sağ_kenar, arka_kenar olarak gruplandırılır. Bu gruplandırma hesaplanan açılar ile yapılır.

11: Bulunan kenarların keşişim noktalarını araştır. Keşişen noktalar varsa bu noktaları köşe olarak belirle.

12: Eğer keşişen noktalar her kenar öncelikle kendi içinde değerlendirme yapılır ve birbirine benzer olan noktalar dışındakiler atılır. Bu değer de bir eşik değeri ile belirlenir. Daha sonra filtrelenen kenarlardan köşe noktalarının değerlerin ortalaması alınarak köşe belirlenir.

Tablo 5.2: Tahmin Algoritması Akış Diyagramı.

ALGORİTMA: Model Eğitimi ve Tahmin

1: Öğrenme Problemi belirlenir

2: Gereken veriler toplanır ve bir veri seti oluşturulur.

3: Veriler giriş ve istenilen çıkışlar olarak gruplanır

4: Eğitmek için kullanılacak algoritma seçilir.

5: Eğitim başlar. Verilerin bir kısmı öğrenimin test edilmesi için ayrılır ve değerlendirme yapılır.

6: Öğrenme gerçekleştiği kontrol edilir. Başarısız bir öğrenme gerçekleşmişse parametreler yeniden ayarlanır ve 5 tekrar çalıştırılır.

7: Öğrenme başarılı ise çıkış tahmini yazdırılır.

6. UYGULAMA VE ÇIKTILAR

6.1 Tez Çalışmasında Kullanılan Malzemeler

Yapılan tez çalışmasında Pamukkale Üniversitesi Teknofest ekiplerinden PUSAT takımı tarafından üretilen ve geliştirilen su altı aracı kullanılmıştır. Bu araç üzerine çalışma kapsamında kullanılacak sensörler entegre edilmiştir.

6.1.1 Tarama Sonarı

Ping360, konumlandırma ve görüntüleme için mekanik bir tarama sonarıdır. 50 metre (165 fit) menzile, 300 metre (984 fit) derinlik derecesine ve onu ROV konumlandırma ve su altı akustik görüntüleme için yetenekli bir araç haline getiren açık kaynaklı bir yazılım ara yüzüne sahiptir.



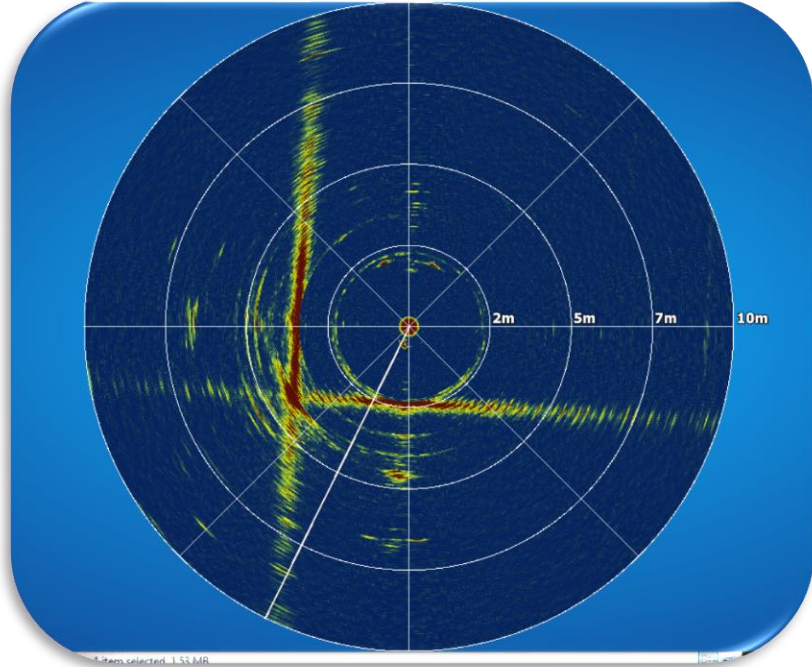
Şekil 6.1: PİNG360 Tarama Sonarı.

Sound Navigation And Ranging (SONAR) sistemleri, su altındaki nesnelere tespit etmek için ses darbelerini ileterek ve bu darbelerin yansımalarını kaydederek çalışan bir aktif sonar türüdür. Tarama sonarları, geniş dikey bir huzmeye ve dar bir yatay huzmeye sahip "fan" şeklinde bir akustik huzme oluşturarak çevresel akustik özelliklerini belirler. Daha sonra, bu bilgileri bir izleyici üzerinde tek bir görüntü olarak göstererek detaylı bir kesitte görselleştirir. Sesin su içindeki hızını dikkate

olarak, sonar, taramadan geri dönen sesin zamanı ve sesin kat ettiği mesafeyi hesaplamak için aşağıdaki denklemi kullanmaktadır.

$$meafe = sesin\ sudaki\ hızı * (yankı\ için\ ölçülen\ süre) \quad (6.1)$$

Ses hızındaki büyük farklılıklar, hedeflere olan doğru mesafeleri etkileyebilir. Denizde sesin hızı yaklaşık olarak 1500m/s. Bu hız denizin tuzluluk oranına, suyun sıcaklığına ve sonarın basınç altındaki hassasiyetine göre değişebilmektedir. Bu sonarlar sesin hızını otomatik olarak hesaplama özellikleri yoktur. Sonarın taraması için kullanılan ara yüz programından veya python yazılımından bu ayarları yaparak doğru hassasiyetle bir sonuç alınabilir.



Şekil 6.2: Havuz ortamında örnek bir tarama çıktısı.

Şekil 6.2’de verilen örnek bir taramayı içermektedir. Bu tarama Blue Robotics firmasının geliştirdiği PingViever uygulaması ile kaydedilmiştir. Bilgisayar ile haberleşme bağlantısı rs-485 USB dönüştürücü kullanılarak gerçekleştirilmiştir. Bu tarama çıktısının alınabilmesi için ayarlar Şekil 6.3’de verilmiştir.



Şekil 6.3: Tarama verileri ayarları.

6.1.2 Ping Sonar Altimeter and Echosounder




Şekil 6.4: Su altı mesafe sonarı.

Ping denizaltı ses radarı, Denizaltı araştırma ve keşif araçları (ROV ve AUV) için bir derinlik ölçer olarak, Deniz yüzeyi aracı üzerinde batimetri çalışmaları için, engelden kaçınma radarı olarak ve diğer su altı mesafe ölçüm uygulamaları için kullanılabilir. 300 metre derinlikte basınca dayanabilen, ölçüm yapabilen, açık

kaynaklı bir kullanıcı ara yüzü ve Arduino, C++, ve Python geliştirme kütüphaneleri ile kullanılabilir.

Su altı mesafe sensörü olarak adlandırılır. Su altı ses dinleme sensörü, piezoelektrik dönüştürücü yardımıyla su altında ses darbeleri üretir. Daha sonra ses darbelerin geri dönüşünü dinlenir. Bu sensör ile deniz tabanına göre aracın mesafesini ve su altı aracı önüne çıkan engelleri tespit edebilir. Ping, girişimden kaçınmak için çoğu tekne ses dinleme cihazlarında kullanılanlardan farklı olan 115 kHz dönüştürücü frekansını kullanır. 100 metre ölçüm aralığına ve 25 derece ölçüm açısına sahiptir, bu da sallanan bir tekne veya engelden kaçınma uygulamaları için mükemmeldir.



Şekil 6.5: Örnek bir mesafe ölçümü.

Tablo 6.1: Ping Sonar teknik özellikleri.

Çalışma Gerilimi	4.5-5.5V
Çalışma Akımı	100mA(nominal) 900mA(anlık)
Haberleşme Protokolü	UART 115200bps
Mesaj Protokolü	Ping Protokol
Bağlantı	Kırmızı:Vgiriş Siyah:Toprak Beyaz:TX Yeşil:RX
Frekans	115Khz
Tarama Genişliği	25°
Mesafe çözünürlüğü	Tarama mesafesinin %0.5 i

6.1.3 Basınç Sensörü



Şekil 6.6: Su altı basınç(derinlik) sensörü.

Türetilmiş bir büyüklük olan basınç, basınç sensörleri ile ölçülür. Üzerine düşen basıncı ölçerek analog sinyale dönüştürerek kullanılır. Bu sinyaller arduino, stm gibi mikro denetleyiciler yardımıyla anlamlı verilere dönüştürülür. Basınç, birim yüzey alanına etki eden kuvvet olarak tanımlanır. Su havaya göre çok daha yoğun bir maddedir. Dolayısıyla, bir santimetrekarelik alana 1kg ağırlık uygulayan suyun yüksekliği sadece 10 metredir. Öyleyse, 10 metre derinlikteki suyun basıncı 1 Bar (1 atm) olacaktır.

Tablo 6.2: Basınç(derinlik) sensörü teknik özellikleri

Haberleşme	I^2C
Ölçüm Aralığı	0-30bar
Paket	Seramik metal
Çalışma Sıcaklığı	$-20\sim 85^{\circ}C$
Çözünürlük	0.2mbar
Çalışma Voltajı	1.5-3.6V

6.1.4 Pixhawk

Pixhawk uçuş kontrolörü, hızla gelişen ve rafine edilmiş ardupilot mega veya 3DR robotikten açık kaynaklı bir proje olan "APM" ye dayanmaktadır. Bir su altı aracının motor kontrollerinin yapılabildiği cihazdır. Motorları farklı seçeneklerle sürebilmektedir. Sabit denge kontrol yazılımını ile içinde bulundurduğu IMU sensörü sayesinde hızı ve yönünü belirleyebilir. Kendi içinde PID kontrol yazılımı mevcuttur. IMU'nun görevi cihazın hızını, dönme açısını ve dönüklük miktarlarını belirlemektedir Jiroskop, yön belirleme amaçlı kullanılan cihazdır. İvmeölçer üzerlerine düşen yerçekimi veya dinamik (aniden hızlanma veya durma) ivmeyi ölçmektedirler. Jiroskop ve ivmeölçer sadece kendi içinde doğru sonuçlar veremezler. Bu nedenle IMU sensörü kullanılmaktadır IMU sensörü bu iki sensörler referans alınarak hız, pozisyon gibi veriler tek çatı altında toplanmaktadır. Cihaza harici olarak bağlana basınç sensörü sayesinde sabit derinlik seçeneği ile aracın istenilen derinliğe indiğinde burada sabit kalmasını sağlamaktadır.




Şekil 6.7: Pixhawk hareket kontrol kartı.

Tablo 6.3: Pixhawk Teknik Özellikleri.

Ana işlemci	STM32F427VIT6
Yardımcı İşlemci	STM32F100C8T6
Jiroskop	MPU6000
Pusula	QMC5883L
Haberleşme protokolü	Mavlink UART
Çalışma sıcaklığı	-40~85°C
Çalışma gerilimi	5V
Pwm çıkış	8 adet
SPI portu	1adet
I ² C portu	1adet
CAN portu	1 adet
Aux çıkış	6 adet PWM çıkış(ayarlanabilir)
GPS uart	1 adet
ADC portu	1 adet 3.3V, 1 adet 6.6V
Bağlantı	xh soket
Serial portu	1 adet

6.1.5 Arduino Mega Pro



Şekil 6.8: Arduino mega pro mikrodnetleyici.

Su altı aracında bulunan 3 tane Ping mesafe sonarının araç içi bilgisayarı ile iletişimini ve sensör verilerini aktarmak için arduino mikrodenetleyicisi kullanılmıştır. Bu çip te bulunan 3 adet seri bağlantı noktası sayesinde sensörlerin iletişimi kolaylıkla sağlanmaktadır.

Tablo 6.4: Mikrodenetleyici teknik özellikleri

İşlemci	Atmega2560
Haberleşme	USB-TTL CH340
Güç Tüketimi	5V 220mA
Saat Frekansı	16Mhz
Çalışma Sıcaklığı	-40~85°C
Serial Bağlantı	Harici 3 adet vardır(Tx-Rx)

6.1.6 NVIDIA Jetson Nano 4gb

NVIDIA Jetson Nano Developer Kit, görüntü sınıflandırma, nesne algılama, segmentasyon ve konuşma işleme gibi uygulamalar için paralel olarak birden fazla sinir ağını çalıştırmanıza izin veren küçük ve güçlü bir (Model B01) bilgisayardır. Hepsi, 5 watt'a kadar çalışan, kullanımı kolay bir platformda. Modern AI algoritmalarını hızlı bir şekilde çalıştırmak için 4 çekirdekli 64-bit ARM CPU, 128 çekirdekli bir entegre NVIDIA GPU ve 4 GB LPDDR4 bellek ile 472 GFLOPS sunar. Görüntü işleme ve makine öğrenmesi çalışmaları için oldukça kullanışlı bir yapay zeka bilgisayarıdır. Jetson Nano, derin öğrenme, bilgisayarla görme, GPU hesaplama, multimedya işleme ve daha fazlası için bir tahta destek paketi (BSP), CUDA, cuDNN ve TensorRT yazılım kitaplıklarını içeren NVIDIA JetPack tarafından da desteklenmektedir.




Şekil 6.9: NVIDIA Jetson Nano 4gb developer kit.

Tablo 6.5: NVIDIA Jetson Nano teknik özellikleri

GPU	128 çekirdekli Maxwell™ GPU
CPU	dört çekirdekli ARM® Cortex®-A57 CPU
Bellek	4GB 64 bit LPDDR4
Depolama	Micro SD kart yuvası (harici minimum 16G TF kart gerektirir)
Ara Birimler	Ethernet: 10/100 / 1000BASE-T otomatik anlaşma Fotoğraf Makinesi: 12-ch (3x4 VEYA 4x2) MIPI CSI-2 DPHY 1.1 (1.5 Gbps) Ekran: HDMI 2.0, DP (DisplayPort) USB: 4x USB 3.0, USB 2.0 (Mikro USB) Diğerleri: GPIO, I2C, I2S, SPI, UART
Güç	Mikro USB (5V 2A) DC jakı (5V 4A)
Boyutlar	Çekirdek modül: 69,6 mm x 45 mm Bütün takım: 100mm × 80mm × 29m

6.1.7 Pusat Su Altı Aracı

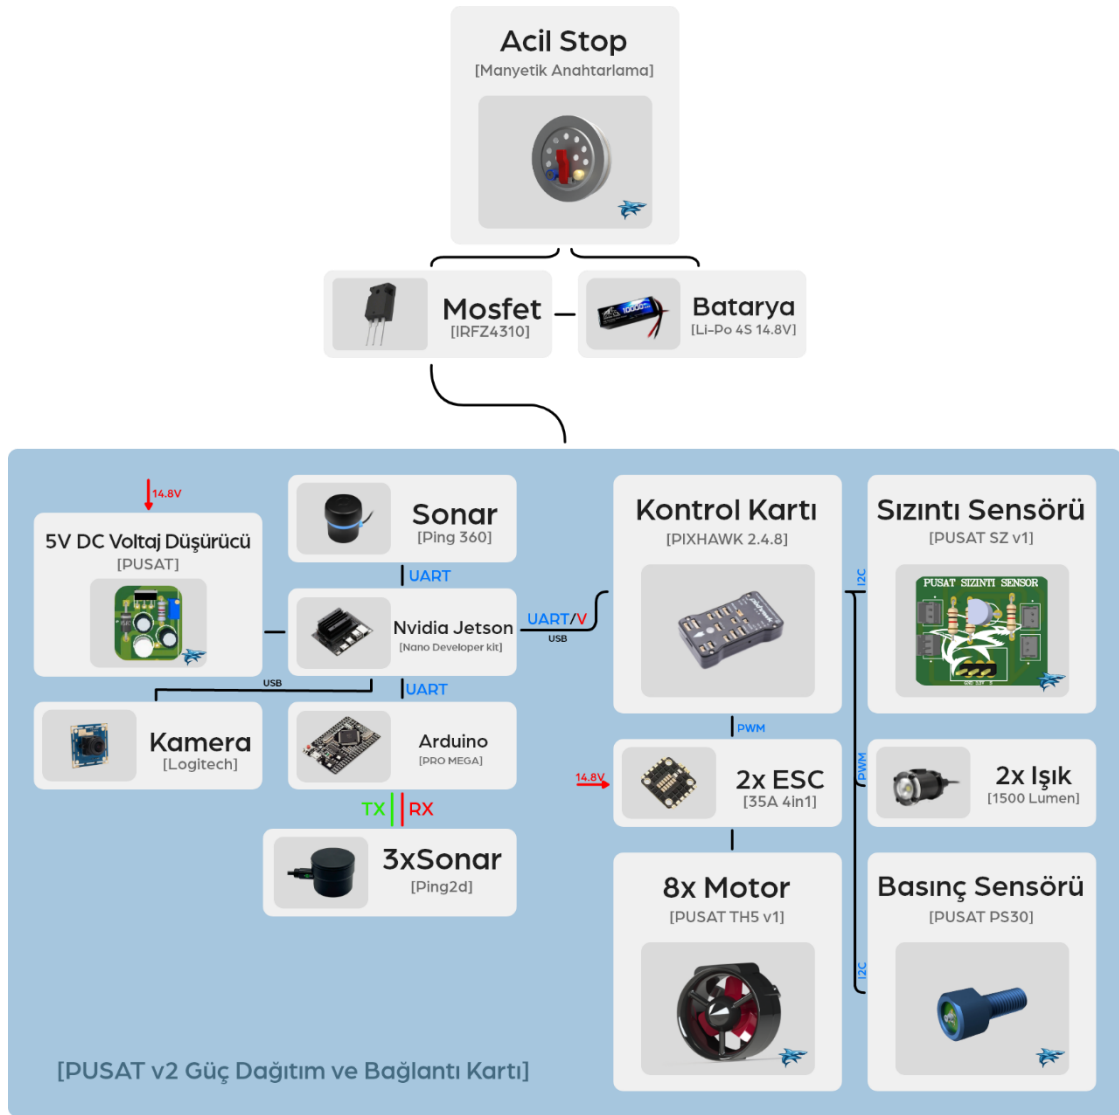


Şekil 6.10: PUSAT takımı su altı test aracı.

Teknofest insansız su altı sistemleri kategorisinde PUSAT takımı tarafından yarışmaya hazırlanan aracın tasarımı. Su altı konumlandırma, haritalama ve otonom sürüş testleri için kullanılacak ve birçok algoritmanın geliştirilip test edilmesine olanak sağlamaktadır. 8 motorlu tasarlanan araç 6 eksen de hareket kabiliyetine sahiptir. Su altı aracı otonom hareket etmektedir. Besleme gerilimi için Lityum Polimer (Li-Po) batarya tercih edilmiştir. Diğer batarya türleri ile karşılaştırıldığında deşarj oranının ve sağladığı akım miktarının daha yüksek olduğu ayrıca daha hafif olduğu gözlemlenmiştir. Büyüklük olarak 10000mAh 50C Li-Po batarya tercih edilmiştir. Sekiz motorlu olarak tasarlanan aracın motor kontrolleri 4'ü 1 arada elektronik hız kontrol (ESC) kartları ile sağlanmaktadır. Motorlar yüksek hassasiyet ve verimlilikte, 35A akım değerine kadar kontrol edilebilmektedir. 4 motoru tek kontrol kartı ile sürebilmekte ve çift yönlü çalışma imkânı sunmaktadır. Yapılan motor itki testlerine göre bir motorun tam güçte yaklaşık 6.1A çektiği gözlemlenmiştir. 35A'e kadar dayanabilen ESC kartları, bahsedilen bu özelliklerden dolayı tercih edilmiştir.

6.2 Tez Çalışması Uygulaması

Su altı aracın kontrolü ve sensör bağlantısı aşağıdaki şekilde gösterilmektedir. Araç içinde bulunan yapay zekâ bilgisayarı üzerinde tüm işlemler kontrol edilmektedir. Su altı konumlandırma için kullanılan tarama sonarı NVIDIA yapay zekâ bilgisayarına UART üzerinden haberleşme yapmaktadır. Aracın etrafında bulunan 3 adet ping sonardaki mesafe verileri arduino mikro denetleyicisi ile okunup anlamlı hale geldikten sonra yapay zekâ bilgisayarına iletilmektedir.




Şekil 6.11: Kontrol Sistemi Şematik Yapısı.

6.2.1 Köşe Bulma ve Konumlandırma İşlemi

İlk olarak Su altı aracı üzerinde bulunan 1'er gradyan olacak şekilde 400 gradyanda etrafını tarayabilen ping360 tarama sonarından veriler alınmaktadır. Bu veriler her gradyanda 1200 veri içermektedir. İlk veri sensöre olan en yakın mesafe 1200. veri sensöre olan en uzak mesafeyi temsil eder. Bu veriler sensörün tarama mesafesine göre oranlanır. Tarama mesafesi 30 metre ise 1200. Veri 30. metrede bulunan tarama ifadesini temsil etmektedir. Her gradyandaki verilerin her biri 0-255 arasında değer vermektedir. Bu o tarama ses darbesinin geriye yansıma oranına göre belirlenir ve orada bir kenar bir engel olup olmadığı anlaşılır.


$$Veriler = [0,255,255,150,30, \dots, 255]_{1 \times 1200} \quad (6.2)$$

Tüm tarama sonucunda elde 400*1200 boyutunda bir matris veri seti oluşmaktadır. Elde edilen bu veriler Kartezyen koordinat sisteminde ifade edilmektedir. Örnek bir tarama sonucunda ortaya çıkan değerlerin python programı ile resim formatında gösterme işlemi aşağıda verilmiştir. (Deney, 25*50 metre boyunda olimpiik yüzme havuzunda ping360 tarama sonarının 20m mesafeli taraması sonucu elde edilmiştir.)



Şekil 6.12: Ping360 tarama sonucu kartezyen koordinat sisteminde gösterimi.

Bu veri setini dairesel koordinat sistemine dönüştürmek gerekmektedir. Dönüşüm sonucunda 400*400 boyutunda python programında dairesel koordinat sistemine göre görselleştirme yapılmıştır. Sensörün tarama sırasında oluşan gürültüleri azaltmak için bir filtreleme işlemi yapılmaktadır. Bu filtreleme işlemi OpenCV kütüphanelerinden normalizasyon işlemi yardımıyla yapılmaktadır. Her bir taramada 0-255 arasında verilen değerleri 220-255 arasındaki veriler dışındakiler temizlenmektedir. Bu sonuç deneysel çalışmalar sonucunda ortaya çıkmıştır.



(a)

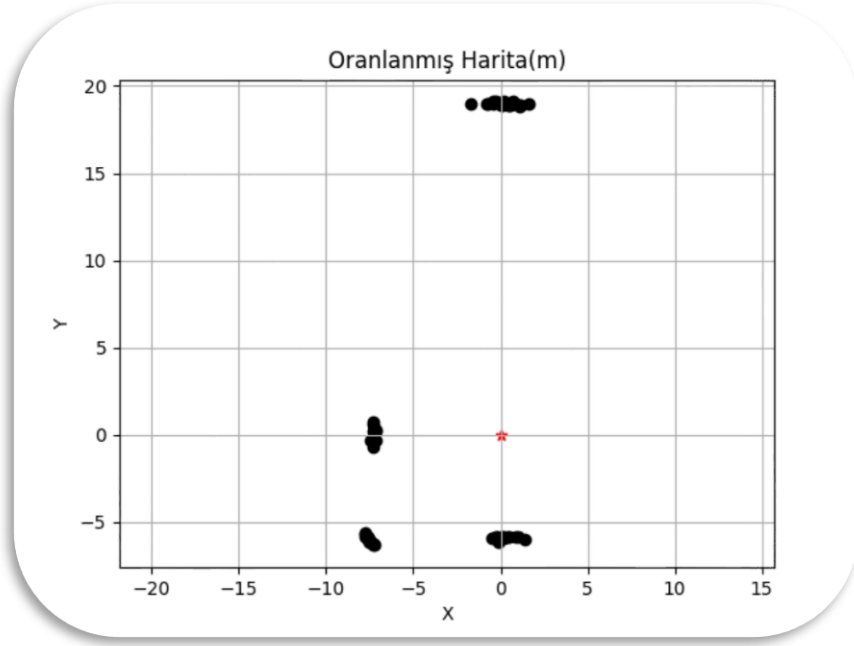
(b)

Şekil 6.13: a) Kutupsal Kordinat Sistemine Dönüştürülmüş tarama verileri b)Normalizasyon işlemi sonrası.

Temizlenmiş 400*400 boyutunda matris verilerini sensörün tarama mesafesine göre metre cinsinden oranlama işlemi yapılmıştır. Burada koordinat sisteminin merkezini (200,200) noktası referans alınmıştır ve her nokta bu merkeze göre mesafeleri sonarın tarama mesafesine oranlanmıştır. Bu işlemi gerçekleştiren eşitlikler denklem 6.3 ve denklem 6.4'te verilmiştir. Bu verilerin mesafe verilerine dönüştürülmüş hali Şekil 6.4'te gösterilmiştir.

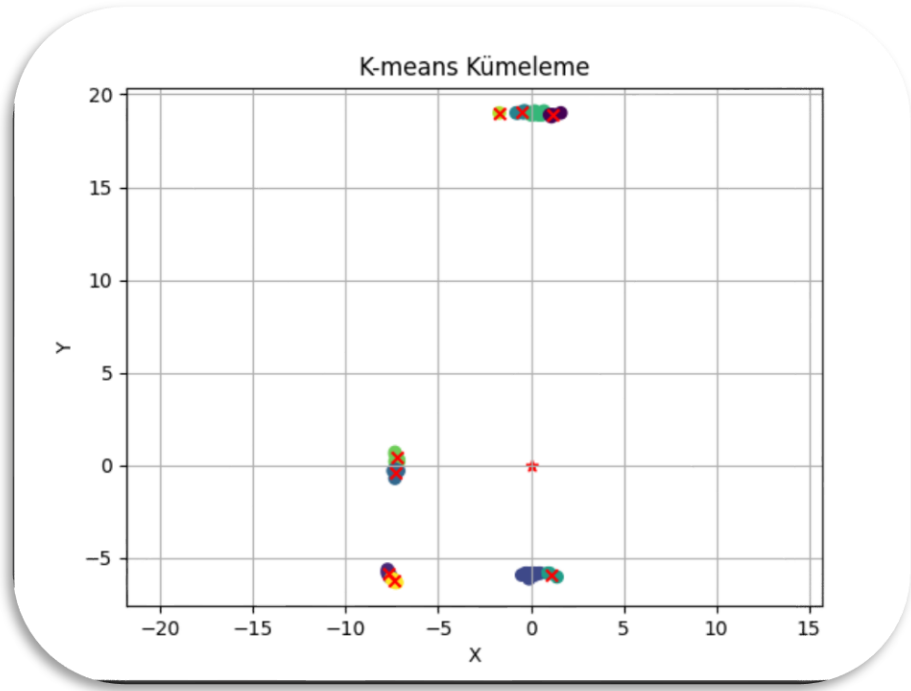
$$x_{uzaklik} = \left| \left(Tarama_{mesafe} * \frac{199 - j}{199} \right) \right| \quad j = 0,1, \dots, 399 \quad (6.3)$$

$$y_{uzaklik} = \left| \left(Tarama_{mesafe} * \frac{199 - i}{199} \right) \right| \quad i = 0,1, \dots, 399 \quad (6.4)$$



Şekil 6.14: Tarama mesafesine göre oranlanmış veriler.

Bu verilere K-means kümeleme algoritması uygulanmıştır. K-means Kümeleme İlk olarak, verilen noktaların listesini K-means kümeleme yöntemi kullanarak k adet küme olarak gruplar. Bu işlem sonucunda her nokta, en yakın kümenin etiketi ile etiketlenir ve küme merkezleri hesaplanır. Kümeleme işlemi için $k=8$ seçilmiştir. Bu seçim deneysel çalışmalara göre belirlenmiştir. Tarama sonucunda Şekil 6.14'te verildiği gibi az miktarda nokta kümesi içinden köşeyi tahmin edilmek istenirse k küme sayısının çok olması noktaların çok fazla ayrıştırılmasına sebep vermektedir. Eğer k sayısı 5'den az seçilirse köşeleri doğru tahmin olasılığı düşmektedir. Şekil 6.15 te 8 adet küme merkezi için K-means kümeleme işlemi sonucu gösterilmektedir.



Şekil 6.15: K-means kümeleme ve merkezlerin belirlenmesi.

Küme merkezlerinin bir listesi oluşturulur. Oluşturulan liste daha sonra bir filtreleme işleminden geçirilmiştir. Merkezlerin koordinatları incelenmiş ve her birinin mutlak değeri belirli eşik değerlerin ötesindeyse (x ve y koordinatlarının mutlak değeri sırasıyla 0.45 ve 0.35'ten büyükse), bu merkezler yeni bir liste oluşturmaktadır. Bu işlem, aracın tarama sonucunda kendi çevresindeki gürültüyü temizlemek için kullanılır.

Elde edilen k adet küme merkezleri bir koordinat sisteminde gösterilir ve her bir noktanın aracın merkezine göre (0,0) açıları denklem 6.5 ile hesaplanmaktadır.

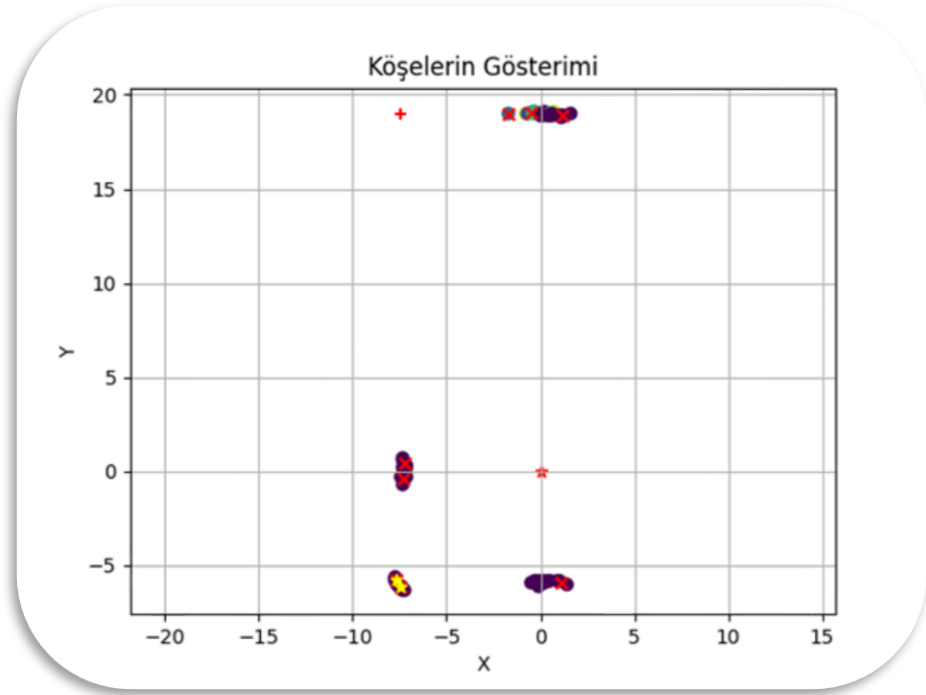
$$\theta_k = \arctan2(y, x) * \frac{180}{\pi} \quad (6.5)$$

K-means ile rastgele kümelenen noktaları bir koordinat sisteminin bölgelerine göre ayırma işlemi yapılmıştır. Burada küme isimleri (araca göre) ön_kenar, sol_kenar, arka_kenar, sağ_kenar olarak gruplandırılmıştır. K-means kümeleme sonucu merkez noktaları (MN) ve x bu noktaların aracın merkezine göre açı ifadesini temsil etsin. Kümeleme sonucunda k adet merkez belirlenmiştir.

$$MN_i \{i = 1, 2 \dots k\}$$

$$\begin{cases} MN_i = \text{ön_kenar}, & 35^\circ \leq \theta_k \leq 145^\circ \\ MN_i = \text{sol_kenar}, & 125^\circ \leq \theta_k \leq 235^\circ \\ MN_i = \text{arka_kenar}, & 215^\circ \leq \theta_k \leq 325^\circ \\ MN_i = \text{sağ_kenar}, & 0^\circ \leq \theta_k \leq 55^\circ \text{ veya } 305^\circ \leq \theta_k \leq 359^\circ \end{cases} \quad (6.6)$$


Belirlenen kenarları birbirleri ile karşılaştırarak kesişen noktaları köşe olarak belirlenmiştir. Bu noktaların koordinat sistemine göre konumları da hangi köşe olduğunu göstermektedir. Eğer bu kenarlarda bir kesişme yoksa her kenar öncelikle kendi içinde değerlendirme yapılır ve birbirine benzer olan noktalar dışındakiler atılır. Bu değer de bir eşik değeri ile belirlenir. Daha sonra filtrelenen kenarlardan köşe noktalarının değerlerin ortalaması alınarak köşe belirlenir. Örneğin sol kenar için verilen noktaların x değerleri öncelikle kendi içinde değerlendirilir ve dışarda kalan (benzer olmayan) noktalar atılır. Daha sonra bu noktaların ortalamasının mutlak değeri hesaplanır. Sol arka veya sol ön köşenin x noktası belirlenir. Aynı işlemler ön kenar için yapılırsa sol ön veya sağ ön kenarın y değeri belirlenmiş olur. Bu iki noktayı kullanarak sol ön köşe belirlenmiş olur. Şekil 6.16'da köşe bulma işleminin son adımı gösterilmektedir. Sol alt köşe noktaları bir önceki adımda belirlenen kenarların kesişen noktalarından elde edilmiştir. Sol ön olarak adlandırabileceğimiz '+' ifadesi kesişim noktası olmadığı durumda köşe tahminini ifade etmektedir.



Şekil 6.16: Bulunan Köşelerin Gösterimi.

Çıktı sonuçlarına göre algoritma, araca göre sol ön= (-7.4518.96) ve sol arkada 2 adet sol arka=(-7.66,-5.8) , (-7.38,-6.24) noktaları olarak köşeleri tespit etmiştir. Su altı aracının koyulduğu yere bakıldığında bu köşelerin y noktaları toplandığında 24.78m ve 25.2m gibi değerler ortaya çıkmaktadır. Havuzun kısa kenarının 25m olduğu bilindiğine göre hazırlanan köşe bulma algoritmasının büyük oranda çalıştığı söylenebilir.

Şekil 6.15 ile sonuçlanan köşe bulma işlemlerinin deney çalışması Pamukkale Üniversitesi Spor Kompleksi kapalı yüzme havuzunda gerçekleştirilmiştir. Yapılan köşe bulma işlemi 25m -50 metre olan havuzda, tarama sensörünün 20 metre çevresini tarama yapabilecek şekilde ayarlanmıştır.




Şekil 6.17: Büyük Havuz Test Ortamı Tarama.

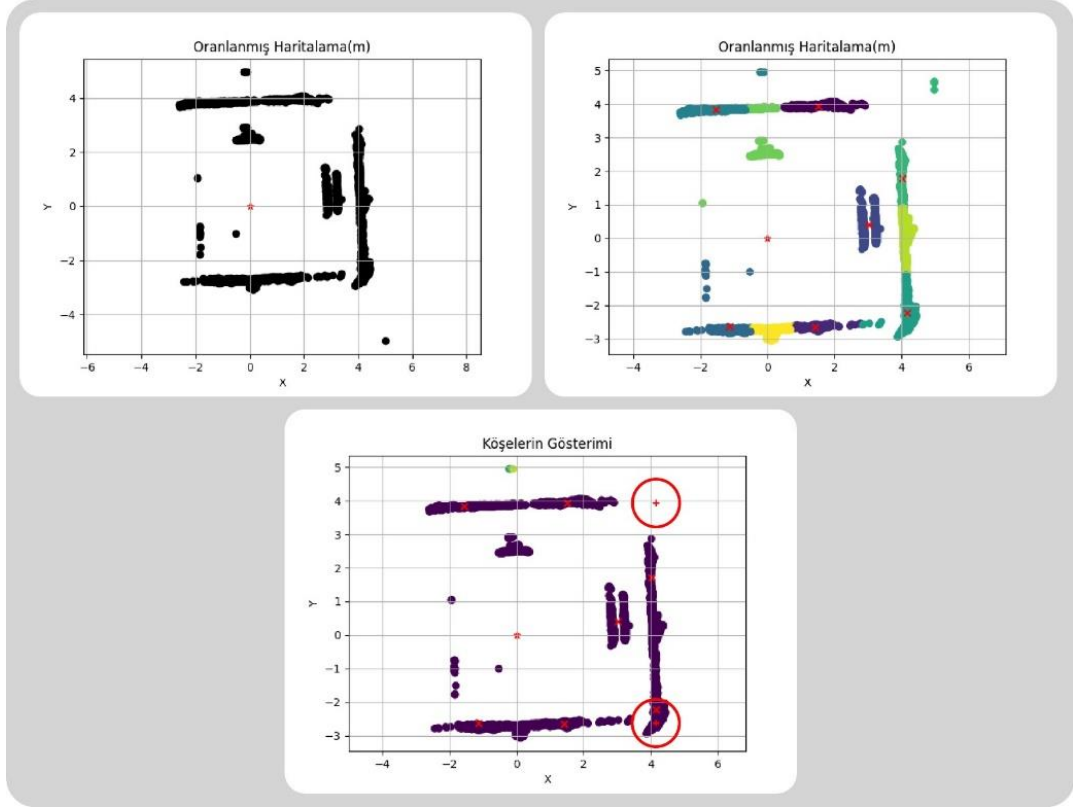


Şekil 6.18: Büyük Havuz Test Ortamı İlerleme.

Bir başka örnek tarama uygulaması aşağıda verilmiştir. Bu taramada tarama sonarının 5m yarı çapında bir daire tarama alanı olacak şekilde ayarlanmıştır. Küçük havuzda yüksek tarama aralığı kullanıldığı takdirde çok fazla yankı meydana gelmektedir.



Şekil 6.19: Köşe Bulma Uygulaması 1. Kısım.



Şekil 6.20: Köşe Bulma Uygulaması 2. Kısım

Algoritma sonucunda 2 adet köşe belirlenmiştir. Görüldüğü gibi net bir şekilde kesişen noktalar olmasa dahi en az 1 veya 2 nokta havuz köşesi olarak belirlenmektedir.

6.2.2 Yol Tahmin Çalışması


Su altı aracın köşeleri belirlendikten sonra çalışmanın 2.kısmı yol tahmin kısmıdır. Bu kısımda yöntem başlığı altında verilen algoritma akış şeması işlemleri gerçekleştirilir (bkz. Tablo 2).

6.2.2.1 Veri Setinin Belirlenmesi

Modelin başarısı doğrudan eğitim veri setinin kalitesine bağlıdır. Veri seti, modelin öğrenme sürecini yönlendirir ve modelin gelecekteki tahminlerinde ne kadar başarılı olacağını belirleyen temel bilgileri sağlar. Lura su altı aracının yol tahmin çalışması için eğitilecek veriler; su altı aracı kontrol istasyonundan motorlara uygulanacak pwm değerleri, araca bağlanacak yükler, aracın yön bilgisi ve, ping mesafe sonarlarından alınan uzaklık bilgileridir.


Tablo 6.6: Tahmin Modeli İçin Giriş ve Çıkış Değerleri.

Giriş/çıkış verileri	Değer aralığı
Araç yönü	İleri, geri, sağ, sol
Motorlara verilen hız değerleri	1250 μ s-1750 μ s
Aracın yük durumu	0kg -3 kg
İki ölçüm arasında, aracın yol aldığı mesafe	0m - 25m



Şekil 6.21: Aracın Kontrol Yönleri.

Aracın 2 ekseninde hareketinin modellenmesi (ileri-geri ve araç yönü değişmeden sağa ve sola hareket) yapılmıştır. Veri setinde aracın ilk önce kendi ağırlığı ile (12 kg) daha sonra çeşitli ağırlıklar takarak belirlenen araç yönlerinde belirli bir süre boyunca hareket verileri modellenmiştir. Pamukkale Üniversitesi Spor Kompleksinde bulunan boyutları 6.5m 20m olan havuz ortamında test yapılmıştır. Su altı aracına ileri yönde motorlara 1600µs pwm vererek ölçüm süresi boyunca ping mesafe sensörü verileri kaydedilmiştir. Daha sonra aynı işlem sırasıyla 1650µs, 1700µs, 1750µs pwm değerleri verilerek değerler kaydedilmiştir. Bu işlemler tüm yönlerde tekrar etmiştir. Aracın üzerine yük bu yapılanlar tekrarlanmıştır ve veri seti oluşturulmuştur.



Şekil 6.22: Havuz Test Ortamı.

6.2.2.2 Veri Setlerinin Sınıflandırılması

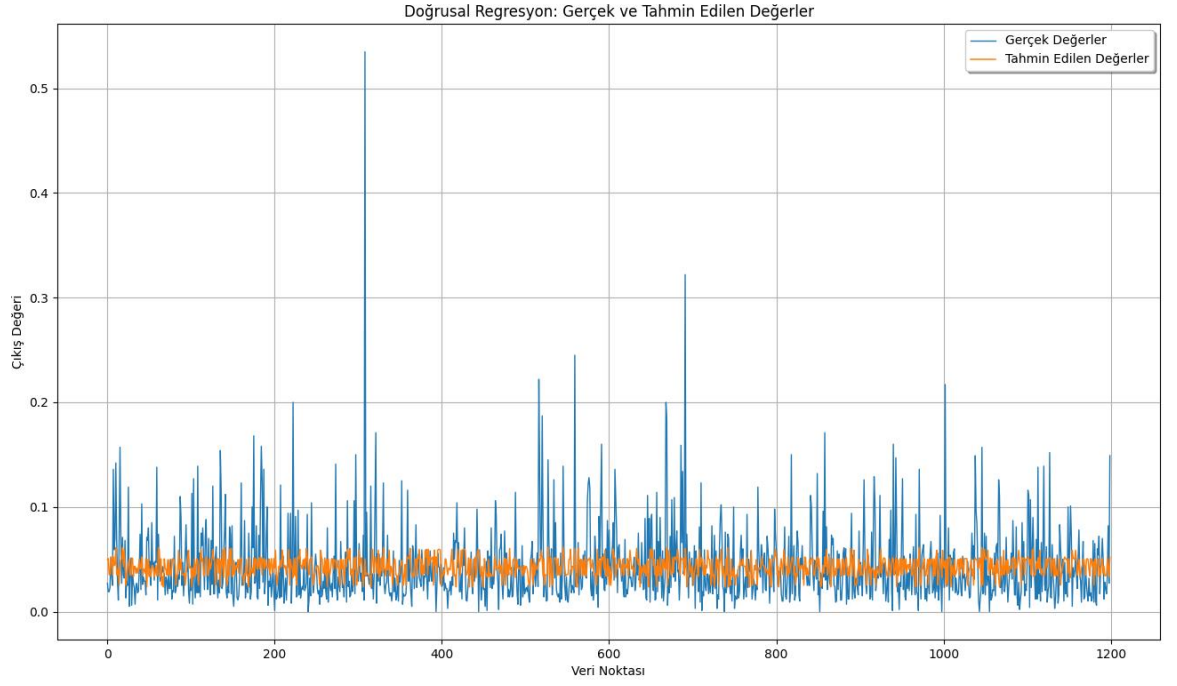
Veri seti belirlendikten sonra bu verilerin %70'i eğitim verisi olarak kullanılırken %30'u modelin test edilmesi için kullanılmıştır.

6.2.2.3 Model Çıktıları Ve Sonuçların Değerlendirilmesi

Eğitim sonuçları, Ortalama Kare Hatası (MSE), Kök Ortalama Kare Hatası (RMSE), Ortak Mutlak Hata (MAE), R^2 Determinasyon Katsayısı ölçüm değerlendirme kriterleri tarafından değerlendirilmiştir.

6.2.2.3.1 Doğrusal Regresyon Algoritması Sonuçları

Doğrusal regresyon algoritmasında, tahmin edilecek model ve gerçek değerler arasında doğrusal bir bağlantı olduğunda iyi sonuçlar verebilir. Aşağıdaki resimde görüldüğü gibi su altı ortamında alınan veriler doğrusal olmadığı için gerçek veriler ile tahmin verileri arasında farklar meydana gelmektedir



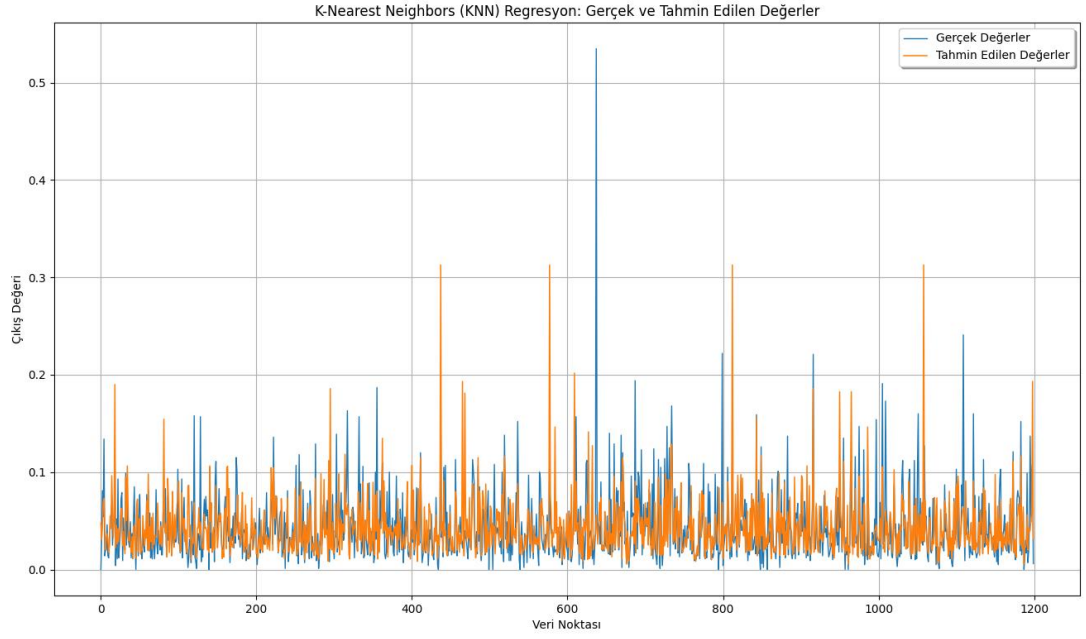
Şekil 6.23: Doğrusal Regresyon Algoritması Eğitim Modeli Sonuçları.

Tablo 6.7: Doğrusal Regresyon Modeli Değerlendirmesi.

Ölçüm Bilgisi	Sonuç
R^2	0.05
MSE	0.0
RMSE	0.04
MAE	0.03

6.2.2.3.2 KNN Algoritması Sonuçları

Bu algoritma, her bir giriş parametresinin, diğer veri noktalarına olan mesafesini hesaplar. Ardından, belirlenen bir k değeri için en yakın k komşuyu seçer ve bu komşuların çıktı değerlerinin ortalamasını alarak tahminde bulunur. k değeri 5 olarak seçilmiş ve sonuçları aşağıda verilmiştir.




Şekil 6.24: KNN Algoritması Eğitim Modeli Sonuçları.

Tablo 6.8: KNN Modeli Değerlendirmesi.

Ölçüm Bilgisi	Sonuç
R^2	0.15
MSE	0.0
RMSE	0.03
MAE	0.02

6.2.2.3.3 Karar Ağaçları Algoritması Sonuçları

Veri setlerinde herhangi bir şekilde belirgin doğrusal bir ilişki olmadığı zaman karar ağaçları algoritması ile modelleme daha çok tercih edilmektedir. Algoritma sonuçları ve değerlendirme sonuçları aşağıda verilmiştir.




Şekil 6.25: Karar Ağacı Algoritması Eğitim Modeli Sonuçları.

Tablo 6.9: Karar Ağacı Modeli Değerlendirmesi.

Ölçüm Bilgisi	Sonuç
R^2	0.47
MSE	0.00
RMSE	0.03
MAE	0.02

6.2.2.3.4 Rastgele Orman Algoritması Sonuçları

Bu algoritma, karar ağaçlarını birleştirerek bir makine öğrenimi modeli oluşturur. Rastgele Orman, birden çok karar ağacının bir araya getirilmesiyle oluşturulan bir toplu öğrenme yöntemidir. Algoritma çıktı sonuçları aşağıda verilmektedir.



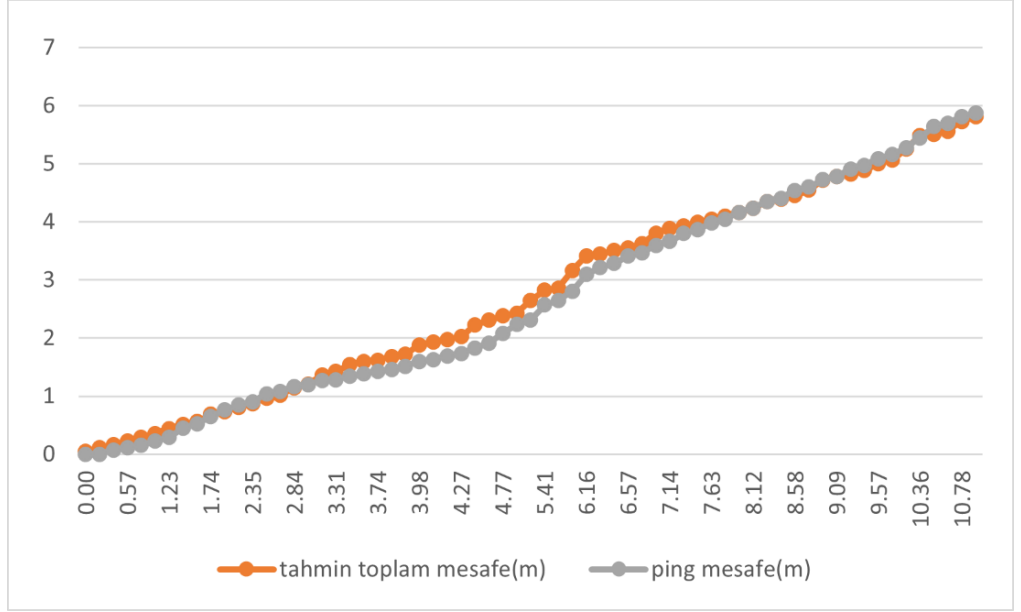
Şekil 6.26: Rastgele Orman Algoritması Eğitim Modeli Sonuçları.

Tablo 6.10: Rastgele Orman Modeli Değerlendirmesi.

Ölçüm Bilgisi	Sonuç
R^2	0.58
MSE	0.00
RMSE	0.03
MAE	0.02

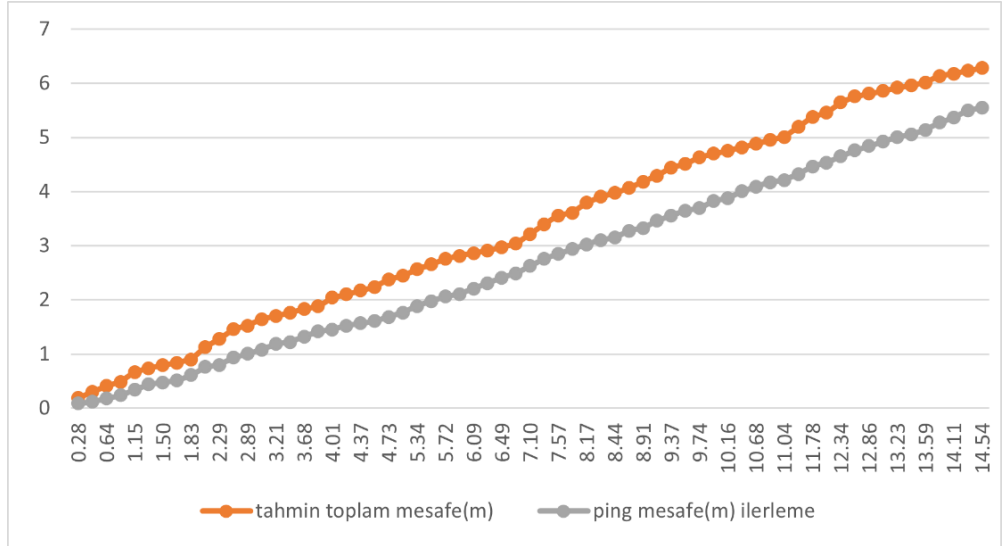
6.2.2.4 Algoritma Tahmin Deneş Çalışması

Eğitim modeli olarak uygulanan yapay zeka modellerinden Karar Ağaçları ve Rastgele Orman Algoritmaları daha doğru sonuçlar verdiği gözlenmiştir. Eğitilen model sonrasında uygulama olarak havuzda yapılan bir çalışma sonucu aşağıda verilmiştir. Burada Araç belirli süre boyunca sağa giderken mesafe sensöründen alınan veriler ve algoritmanın tahmin verileri karşılaştırılmıştır. Su altı aracı motorlarına denge ayarında 1700µs sağa doğru hareket verilmiştir ve belirli bir t süresi boyunca ölçümleri yapılmıştır.



Şekil 6.27: Aracın Hareketinin Karşılaştırılması Uygulama Sonucu:1.

Bir başka deneyde aracın üzerine 1.5 kg yük bağlayıp 1700µs pwm değeri uygulayarak ileri yönde hareketinin tahmin ve mesafe sensöründen alınan sonuçları aşağıda vermiştir.



Şekil 6.28: Aracın Hareketinin Karşılaştırılması Uygulama Sonucu:2.

7. SONUÇLAR VE ÖNERİLER

Su altı çalışmalarında konumlandırma, özellikle denizaltı arařtırmaları, su altı keřifleri ve denizaltı robotlarının navigasyonu gibi alanlarda kritik bir öneme sahiptir. Ancak, su altında konumlandırma ile ilgili bir dizi zorlukla karřılařılmaktadır. En büyük zorluklardan biri su altında, geleneksel GPS sinyalleri etkisiz hale gelmesidir. Bu nedenle, su altı arařtırmalarında konumlandırma için GPS kullanmak mümkün deęildir. Alternatif olarak, su altında kullanılabilen bařka konumlandırma teknolojileri kullanılmaktadır. Ataletsel navigasyon, akustik navigasyon ve optik navigasyon gibi sistem çözümleri mevcuttur.

Açık denizlerde yapılan akustik konumlandırma sistemlerinde deniz tabanına bir dizi alıcı ve verici sistemler yerleřtirilmektedir. Bu sistemler yüzeydeki istasyon ile iletişim halindedir veya su altı aracı bu alıcı vericiler ile kendi arasında kapalı alan bir konumlandırma sistemi üretirler. Kapalı bir ortamda bu tip sistemlerin kullanılması yüksek maliyet gerektirmektedir. Bu tez çalışmasında yüksek maliyetli sistemler yerine daha uygun çözümler üzerinde durulmuřtur. Kapalı alanda aracın kendi konumunu 360 derece tarama alanı olan bir sonar ile tarama verileri python programı yardımıyla elde edilmiřtir. Daha sonra bu veriler görüntü iřleme yöntemleri ile fotoğraf halini alınmıř ve çeřitli filtrelerden geçirilmiřtir. Sınıflandırma algoritmalarından K-means algoritması kullanılarak bu veriler anlamı bir yapı halini almıřtır. Aracın durumuna göre bu verilerden ortam köřeleri belirlenmiřtir. Daha sonra aracın etrafına yerleřtirilmiř su altı mesafe sensörlerinden alınan veriler yapay zekâ algoritmalarıyla modellenmiřtir. Karar Aęaçları ve Rastgele Orman algoritmaları doğrusal olmayan sistemlerin modellenmesi için oldukça kullanıřlı olduęu sonucuna varılmıřtır. Bu model ile aslında mesafe sensörlerini ortadan kaldırarak aracın su altında hareket ettięinde ne kadar yol alabileceęi tahmin edilmiřtir.

Yapılan çalışmada giriş verileri olarak sadece mesafe, motorlara uygulanan kontrol girdisi, aracın yükü ve yönelim seçilmiřtir. Araç 6 ekseninde hareket edebilme yeteneęine sahiptir. Bu çalışmada 2 ekseninde hareketi modellenmiř ve algoritma bařarılı sonuçlar vermiřtir.

Sonraki çalışmalarda algoritmayı geliřtirmek ve tahmin doğruluęunu arttırmak için girdi verilerini arttırılabilir. Algoritmanın açık denizlerde de kullanılabilmesi için

farklı sensörlerden geri dönüşler alınarak kapalı döngü bir sistem yapılabilir. Örneğin denizde dalgaların yönüne ve şiddetini ölçerek, motorlara uygulanan torku hesaplayarak, suyun yoğunluğunu gibi parametreleri de hesaplayarak aracın kendi referansını başlangıç noktası olarak kabul edilirse ne kadar yol aldığı hesaplanabilir. Sensörlerden kaynaklanan ölçüm hatalarını da en aza indirmek için kapalı döngü sistemine Kalman filtreleri de ekleyerek aracın konum hatası en aza indirilebilir.

8. KAYNAKLAR

- Canlı, G. A., Kurtođlu, İ., Canlı, M. O., & Tuna, Ö. S. “Dünyada Ve Ülkemizde İnsansız Sualtı Araçları İsa-a-uv & Rov Tasarım Ve Uygulamaları”, *Gidb Dergi*, (04), 43-75,(2015).
- Leblebiciođlu, K. M., Ege, E., Ulusoy, İ., Yiđitler, H., Koç, S. S., Karadeniz, S., ... & Aytakin, Ö., “Çok Maksatlı Ulusal İnsansız Sualtı Aracı Projesi (ULİSAR)”,(2009).
- Loebis, D., Sutton, R., Chudley, J., & Naeem, W., “Adaptive tuning of a Kalman filter via fuzzy logic for an intelligent AUV navigation system”, *Control engineering practice*, 12(12), 1531-1539, (2004).
- Lee, P. M., & Jun, B. H., “Pseudo long base line navigation algorithm for underwater vehicles with inertial sensors and two acoustic range measurements”, *Ocean Engineering*, 34(3-4), 416-425, (2007).
- Mallios, A., Ridao, P., Ribas, D., Maurelli, F., & Petillot, Y., “EKF-SLAM for AUV navigation under probabilistic sonar scan-matching”, *IEEE/RSJ International Conference on Intelligent Robots and Systems* (pp. 4404-4411). IEEE, (2010).
- Barkby, S., Williams, S. B., Pizarro, O., & Jakuba, M. V., “A featureless approach to efficient bathymetric SLAM using distributed particle mapping”, *Journal of Field Robotics*, 28(1), 19-39, (2011).
- Fallon, M. F., Folkesson, J., McClelland, H., & Leonard, J. J., “Relocating underwater features autonomously using sonar-based SLAM”, *IEEE Journal of Oceanic Engineering*, 38(3), 500-513, (2013).
- Leblebiciođlu, M. K., Akar, G., Halıcı, U., Kartal, S. K., Saç, H., & Shabanı, R., “İnsansız sualtı araçları için yol planlama ve sualtı optik görüntülerin akustik görüntüleme desteđi ile iyileştirilmesi”, (2015).
- Vallicrosa, G., Bosch, J., Palomeras, N., Ridao, P., Carreras, M., & Gracias, N., “Autonomous homing and docking for AUVs using range-only localization and light beacons”, *IFAC-papersonline*, 49(23), 54-60, (2016).
- R. Cui, Y. Li and W. Yan, “Mutual Information-Based Multi-AUV Path Planning for Scalar Field Sampling Using Multidimensional RRT*”, in *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 46, no. 7, pp. 993-1004, doi: 10.1109/TSMC.2015.2500027, (2016).
- Berna, E. R. O. L., Cantekin, R., Kartal, S., Hacıođlu, R., Görmüş, K. S., Kutođlu, Ş. H., & Leblebiciođlu, K., “İnsansız Sualtı Aracı Hareketinin Kalman Filtre İle Kestirimi ve Makine Öğrenmesi ile

İyileştirilmesi”, *International Journal of Advances in Engineering and Pure Sciences*, 33, 67-77,(2021).

Partovibakhsh, M., Liu, G. “An adaptive unscented Kalman filtering approach for online estimation of model parameters and state-of-charge of lithium-ion batteries for autonomous mobile robots”, *IEEE Transactions on Control Systems Technology*, 23(1), 357-363, (2014).

Wan, E. A., Van Der Merwe, R., “The unscented Kalman filter for nonlinear estimation”, In *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium, Cat. No. 00EX373*, pp. 153-158, (2000).

İlvan, A., Bostancı, B. “İnsansız Hava Araçları İçin Düşük Bütçeli INS/GNSS Sistemi Entegrasyonunda Genişletilmiş Kalman Filtresi (EKF) ve Kokusuz Kalman Filtresi (UKF) Yöntemlerinin Karşılaştırılması”, *Türkiye Harita Bilimsel ve Teknik Kurultayı*, (2021).

Harris, C., & Stephens, M., “A combined corner and edge detector”, In *Alvey vision conference*, Vol 15, No. 50, pp. 10-5244, (1988).

Derpanis, K. G., “The harris corner detector” , *York University*, 2, 1-2,(2004).

Kadhim, H. A., & Araheemah, W. A., “A comparative between corner-detectors (Harris, Shi-Tomasi & FAST) in images noisy using non-local means filter”, *J. Al-Qadisiyah Comput. Sci. Math*, 11(3), 86-93, (2019).

Shi, J., “Good features to track” In *1994 Proceedings of IEEE conference on computer vision and pattern recognition*, pp. 593-600, (1994).

Lindeberg, T., “Junction detection with automatic selection of detection scales and localization scales”, In *Proceedings of 1st international conference on image processing*, IEEE, Vol. 1, pp. 924-928, (1994).

Acet, A., “SVM, NB, KNN, ADABOOST ve Random Forest sınıflandırma algoritmaları kullanılarak meme kanserinin tahmini”, Yüksek lisans tezi, *İnönü Üniversitesi Fen Bilimleri Enstitüsü*, Malatya, (2022).

Kotsiantis, S. B., “Supervised machine learning: A review of classification techniques”, *Informatica*, 31 (3), 249–268, (2007).

Kartal, E., “Sınıflandırmaya dayalı makine öğrenmesi teknikleri ve kardiyolojik risk değerlendirmesine ilişkin bir uygulama”, Doktora tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, (2015).

Boyacı, Ö., “Elektrikli araçlar için yapay zeka tabanlı rejeneratif enerji denetimi.” , Doktora tezi, *Pamukkale Üniversitesi Fen Bilimleri Enstitüsü*, Denizli, (2022).

Muñoz, F., Cervantes-Rojas, J. S., Valdovinos, J. M., Sandre-Hernández, O., Salazar, S., & Romero, H., “Dynamic neural network-based adaptive tracking control for an autonomous underwater vehicle subject to modeling and parametric uncertainties”, *Applied Sciences*, 11(6), 2797, (2021).

Fossen, T. I. *Handbook of marine craft hydrodynamics and motion control*, Trondheim, Norway :John Wiley & Sons Ltd.,(2011).

Wu, C. J., “6-dof modelling and control of a remotely operated vehicle , Doctoral dissertation, *Flinders University, College of Science and Engineering*, (2018).

Jehangir,R., “What is an Underwater ROV?[online]”,(10 Ekim 2023),<https://bluerobotics.com/learn/what-is-an-rov/>.

Robotics,B., “Underwater Operations: Using a ROV DVL (Doppler Velocity Log[online]”,(15 Ekim 2023), <https://www.boxfish.nz/products/boxfish-rov/accessories/dvl/>.

Gode, T., “Long Baseline Ranging Acoustic Positioning System[online]”, (17 Ekim 2023), <https://www.semanticscholar.org/paper/Long-Baseline-Ranging-Acoustic-Positioning-System-Gode/bab1f0ad0365530bfb14fdace6ba25f4550396de/figure/4> ,(2015).

Ardusub, “ Underwater Positioning and GPS[online]” ,(17 Ekim 2023), <https://www.ardusub.com/images/hardware/USBL-CS.png> .

Gandhi, N., “Harris Corner Detection and Shi-Tomasi Corner Detection[online]”, (1 Kasım 2023), <https://medium.com/pixel-wise/detect-those-corners-aba0f034078b> ,(2018).

Wikipedia, “The Förstner Corner Detection[online]”,(3 Kasım 2023) https://en.wikipedia.org/wiki/Corner_detection#/media/File:Corner_detection_using_Foerstner_Algorithm.png ,(2012).

Şener, E., “Lineer Regresyon Modellemesi ile Pazarlama Kampanyaları Bütçe Estimasyonu[online]”, (4 Kasım 2023), <https://semtr.com/blog/lineer-regresyon-modellemesi-ile-pazarlama-kampanyalari-butce-estimasyonu/>, (2020).

Tafralı, S., “K-en yakın komşu algoritması nasıl çalışır? [online]”, (5 Kasım 2023), <https://miuul.com/image/article/62b0b8edb12bd.jpg> , (2022).