

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİKLİ GEMİLERİN ŞARJ PROSESİ İÇİN YAPAY ZEKÂ
TABANLI YENİ BİR OTONOM KONTROL SİSTEMİ

DOKTORA TEZİ

Emin GÜNEY

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

EYLÜL 2025

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİKLİ GEMİLERİN ŞARJ PROSESİ İÇİN YAPAY ZEKÂ
TABANLI YENİ BİR OTONOM KONTROL SİSTEMİ**

DOKTORA TEZİ

Emin GÜNEY

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Cüneyt BAYILMIŞ

EYLÜL 2025

Emin Güney tarafından hazırlanan “Elektrikli Gemilerin Şarj Prosesi için Yapay Zekâ Tabanlı Yeni Bir Otonom Kontrol Sistemi” adlı tez çalışması 29.08.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

- Jüri Başkanı :** **Prof. Dr. Ahmet ZENGİN**
Sakarya Üniversitesi
- Jüri Üyesi :** **Prof. Dr. Cüneyt BAYILMIŞ**
Sakarya Üniversitesi
- Jüri Üyesi :** **Prof. Dr. Devrim AKGÜN**
Sakarya Üniversitesi
- Jüri Üyesi :** **Prof. Dr. Sezgin KAÇAR**
Sakarya Uygulamalı Bilimler Üniversitesi
- Jüri Üyesi :** **Doç. Dr. Selman HIZAL**
Sakarya Uygulamalı Bilimler Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “ELEKTRİKLİ GEMİLERİN ŞARJ PROSESİ İÇİN YAPAY ZEKÂ TABANLI YENİ BİR OTONOM KONTROL SİSTEMİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

29/08/2025

Emin Güney





Eşime ve kızım Zeynep Sare'ye



TEŞEKKÜR

Tez çalışması boyunca kıymetli bilgi ve tecrübeleriyle her aşamada beni yönlendiren, destekleyen ve yol gösterici katkılarını hiçbir zaman esirgemeyen değerli danışmanım Prof. Dr. Cüneyt BAYILMIŞ'a en içten teşekkürlerimi sunarım.

Bu süreçte Arizona State University (ASU) Active Perception Group (APG) ekibiyle çalışma fırsatı sunan, yeni fikirler ve araştırma alanları önererek çalışmalarına katkı sağlayan Doç. Dr. Yezhou YANG'a teşekkür ederim.

Çalışmanın gerçek hayata aktarılması ve saha uygulamalarının gerçekleştirilmesinde değerli katkıları bulunan ELKON ve REGBES firmalarından Dr. Erdeniz EROL, Dr. Özhan ATMACA, Dr. Mert DOĞANLI, Batuhan ÇAKAN ve İsmail Hakkı ŞAHİN'e teşekkür ederim.

Ayrıca, TÜBİTAK Başkanlığı'na, 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında sağladığı destek ile 2214-A Yurt Dışı Doktora Sırası Araştırma Burs Programı aracılığıyla ABD'de, ASU bünyesinde bir yıl süreyle araştırma yapma imkânı tanıdığı için teşekkür ederim. Bu çalışmanın saha uygulamaları, Robotik Elektrikli Gemi Batarya Besleme Sistemi (REGBES) adlı TEYDEB projesi kapsamında gerçekleştirilmiştir.

APG'deki araştırma faaliyetlerim sırasında akademik katkıları ve yapıcı görüşleriyle bana yol gösteren Dr. Duo LU'ya ayrıca teşekkür ederim. Yoğun araştırma dönemlerinde samimi arkadaşlıkları ve içten destekleriyle yanımda olan Aayush Atul VERMA, Chi-Yao HUANG, Sangmin JUNG, Kaustav CHANDA ve Shamanthak HEGDE'ye de minnettarım.

Her zaman yanımda olan, sevgisi ve desteğiyle bana güç veren çok değerli anne ve babama teşekkür ederim. Verdikleri emek, sabır ve anlayış, bu süreci tamamlamamda önemli bir rol oynamıştır. Her zaman sabır, anlayış ve desteğiyle yanımda olan değerli eşime teşekkür ederim. Bu süreçte aramıza katılan kızım Zeynep Sare, çalışmamı tamamlamamda moral ve motivasyon kaynağı olmuştur.

Emin Güney



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR.....	ix
İÇİNDEKİLER	xi
KISALTMALAR.....	xiii
TABLO LİSTESİ	xiv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1. Literatür Taraması	2
1.2. Tezin Amacı ve Literatüre Katkıları	8
1.3. Tezin Organizasyonu.....	9
2. DERİN ÖĞRENME TABANLI NESNE TESPİT VE TAKİP YÖNTEMLERİ	13
2.1. Derin Sinir Ağları (DNN).....	13
2.2. Evrişimsel Sinir Ağları (CNN).....	14
2.3. Nesne Tespiti ve Tespit Algoritmaları	15
2.3.1. İki aşamalı nesne tespit algoritmaları	16
2.3.1.1. Feature pyramid network (FPN)	16
2.3.1.2. Faster R-CNN	17
2.3.2. Tek aşamalı nesne tespit algoritmaları.....	18
2.3.2.1. Single shot multibox detector (SSD)	18
2.3.2.2. You only look once (YOLO)	19
2.3.2.3. YOLOv5.....	20
2.3.2.4. YOLOv8.....	21
2.3.3. Transformer tabanlı yöntemler	22
2.3.3.1. Vision transformers (ViT)	22
2.3.3.2. Detection transformer (DETR)	23
2.3.3.3. Real-time detection transformer (RT-DETR)	24
2.3.3.4. Roboflow detection transformer (RF-DETR)	24
2.4. Nesne Takibi ve Takip Algoritmaları.....	25
2.4.1. DeepSORT	26
2.4.2. Multiple object tracking (MOT)	27
2.4.3. FairMOT	27
2.4.4. ByteTrack.....	28
2.4.5. StrongSORT.....	28
2.4.6. BoT-SORT	29
2.4.7. OC-SORT	29
3. GELİŞTİRİLEN OTONOM KONTROLLÜ ROBOTİK KIYI ŞARJ SİSTEMİ	31
3.1. Donanım Altyapısı	32

3.1.1. PLC tabanlı kontrol altyapısı	33
3.1.2. Algılama ve görüntü işleme donanımı	34
3.2. Yazılım Altyapısı.....	34
3.2.1. Görüntüden karara: yazılım iş akışı	35
3.2.2. Nesne tespiti ve konum bilgisi üretimi	35
3.2.3. YOLO modelinde sınırlayıcı kutu tahminleri ve konum hesaplaması....	37
3.2.4. PLC ile haberleşme ve hareket komutu oluşturma	38
3.3. Özgün Veri Seti ve Performans Metrikleri.....	38
3.3.1. Özgün elektrikli gemi şarj soketi veri seti	39
3.3.2. Singapore maritime dataset (SMD).....	41
4. DENEYSEL ÇALIŞMALAR VE PERFORMANS ANALİZLERİ	43
4.1. Değerlendirme Metrikleri	43
4.1.1. Tespit metrikleri.....	43
4.1.2. Takip metrikleri.....	45
4.1.3. Kayıp fonksiyonları.....	46
4.2. YOLO Tabanlı Şarj Soketi Tespit Çalışmaları.....	47
4.2.1. YOLOv5 üzerinde kayıp fonksiyonu optimizasyonu	50
4.3. Transformer Tabanlı Şarj Soketi Tespit Çalışmaları	52
4.3.1. RT-DETR performansının çok aşamalı veri artırma ile iyileştirilmesi....	54
4.4. Çoklu Nesne Takip Algoritmalarının Performans Sonuçları	55
5. SAHA UYGULAMALARI VE GERÇEK ZAMANLI TESTLER	59
5.1. Uygulama Arayüzleri	59
5.2. Deneysel Uygulama ve Gerçekleme.....	61
6. SONUÇLAR, DEĞERLENDİRME VE ÖNERİLER	67
6.1. Sonuçlar ve Değerlendirme	67
6.2. Öneriler.....	69
KAYNAKLAR.....	71
ÖZGEÇMİŞ.....	77

KISALTMALAR

AUV	: Otonom sualtı aracı
CBAM	: Evrişimsel blok dikkat modülü
CCS	: Birleşik şarj sistemi
CNN	: Evrişimsel sinir ağı
CSP	: Aşama geçişli kısmi katman
CTMA	: Küme şablon eşleştirme algoritması
DNN	: Derin sinir ağı
DPM	: Bükülebilir parçalar modeli
DETR	: Tespit dönüştürücü
FLANN	: Yaklaşık en yakın komşular için hızlı kütüphane
FPN	: Özellik piramidi ağı
FPS	: Saniyedeki kare sayısı
GIoU	: Genelleştirilmiş birleşim üzerinden kesişim
HSV	: Ton doygunluk değeri
IDSW	: Kimlik değişimi
IMO	: Uluslararası denizcilik örgütü
IoU	: Birleşim üzerinden kesişim
MOT	: Çoklu nesne takibi
mAP	: Ortalama hassasiyetin ortalaması
NMS	: Maksimum olmayan bastırma
Re-ID	: Yeniden tanımlama
RNN	: Tekrarlayan sinir ağı
RPN	: Bölge öneri ağı
SIFT	: Ölçekten bağımsız özellik dönüşümü
SMD	: Singapur denizcilik veri seti
SSD	: Tek atış çoklu kutu tespitçisi
STS	: Kıyıdan-gemiye
ViT	: Görsel dönüştürücü
YOLO	: Yalnızca bir kez bakarsın



TABLO LİSTESİ

Sayfa

Tablo 1.1. Tez çalışmasının kapsamı ve en yakın olan çalışmalar.	6
Tablo 1.2. Tez çalışmasına en yakın olan literatürdeki çalışmalar ile gerçekleştirilen sistemin genel özelliklerinin karşılaştırılması.	7
Tablo 2.1. DETR ve türevlerinin mimari özellik karşılaştırması.	23
Tablo 4.1. YOLO sürümlerinin performans metriklerinin karşılaştırması.	49
Tablo 4.2. Farklı kayıp fonksiyonlarının (Focal, SIoU, BAL) şarj soketi tespit performansına etkileri (%).	51



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Denizcilik sektörü için 2018-2050 dönemi öngörülen yakıt dağılımı (IMO hedef senaryosu, DNV'nin izniyle yayınlanmıştır) [11].	2
Şekil 2.1. Nesne tespiti sürecinin genel işlem adımları.	15
Şekil 2.2. FPN yapısında çok ölçekli özellik haritalarından tahmin üretimi [59].	17
Şekil 2.3. Faster R-CNN mimarisinin çalışma prensibi [60].	18
Şekil 2.4. SSD modelinin genel mimarisi [55].	19
Şekil 2.5. YOLO modelinin genel mimarisi [53].	19
Şekil 2.6. YOLO algoritmalarının gelişim süreci ve sürüm zaman çizelgesi [63]. ...	20
Şekil 2.7. YOLOv5 modelinin genel mimarisi [33]. Omurga, boyun ve baş katmanları ayrı bölümler halinde gösterilmektedir.	21
Şekil 2.8. YOLOv8 modelinin genel mimarisi [69].	22
Şekil 2.9. ViT mimarisi ve kodlayıcı yapısı. Görüntü yamalarının doğrusal gömme, pozisyon kodlama ve dikkat mekanizması ile işlenmesi gösterilmektedir [78].	23
Şekil 2.10. DETR mimarisi [57]. Omurgadan elde edilen öznitelikler kodlayıcı-çözücü katmanında işlenerek sorgular üzerinden sınıf ve konum tahminleri yapılır.	24
Şekil 2.11. DeepSORT modelinin genel mimarisi [82].	26
Şekil 2.12. FairMOT modelinin genel mimarisi. Kodlayıcı-çözücü ağı öznitelikleri çıkarır, ardından nesne tespiti yapar, Re-ID ile kimlik bilgileri korur [70].	27
Şekil 2.13. ByteTrack algoritmasının pseudo kod gösterimi [74].	28
Şekil 2.14. OC-SORT algoritmasının işlem hattı (pipeline) gösterimi [77].	30
Şekil 3.1. Geliştirilen otonom kontrollü STS şarj sistemi ile gemi bataryası arasındaki enerji aktarım süreci.	32
Şekil 3.2. PLC tabanlı kontrol ve tahrik sistemi blok diyagramı.	33
Şekil 3.3. Şarj sürecine ait görüntü işleme ve PLC tabanlı akış diyagramı.	35
Şekil 3.4. YOLO tabanlı geliştirilen soket tespit modelinin eğitim ve tespit aşamalarına ait akış diyagramı.	36
Şekil 3.5. YOLO modelinde tahmin edilen sınırlayıcı kutunun hesaplanması.	38
Şekil 3.6. Robotik şarj sistemine ait erkek ve dişi soket arayüzleri (sol: erkek, sağ: dişi).	39
Şekil 3.7. Çeşitli açılardan ve ışık koşullarında çekilmiş şarj soketi görüntüleri.	40
Şekil 3.8. Veri setindeki görüntülerin ortam ve ışık koşullarına göre sayısal dağılımı.	40
Şekil 3.9. Veri artırma uygulamaları: orijinal ve dönüştürülmüş görüntüler.	41
Şekil 3.10. Veri artırma örnekleri: (a) orijinal, (b) dikey çevirme, (c) yatay çevirme.	41
Şekil 3.11. SMD veri setinden farklı gemi türlerini içeren örnek sahneler.	42
Şekil 4.1. YOLOv5 modelinin eğitim sürecinde (a) mAP@0.5, (b) mAP@0.5:0.95, (c) precision ve (d) recall metriklerinin adım bazında değişimi.	49

Şekil 4.2. YOLOv5 modeline ait (a) Precision-Confidence eğrisi, (b) Recall-Confidence eğrisi, (c) Precision-Recall eğrisi ve (d) F1-Confidence eğrisi.	49
Şekil 4.3. YOLOv5 tabanlı şarj soketi tespit modülünün gerçek ortam görüntüleri üzerindeki tespit sonuçları.	50
Şekil 4.4. Focal, SloU ve BAL kayıp fonksiyonlarının şarj soketi tespitinde kutu (box), nesne (obj) ve sınıf (cls) kayıplarındaki göreceli iyileşme oranları (%). .	51
Şekil 4.5. Farklı kayıp fonksiyonlarının eğitim sürecinde precision, recall ve mAP değişim eğrileri.	52
Şekil 4.6. DETR, RF-DETR ve RT-DETR modellerine ait karşılaştırmalı başarımların ısı haritası (heatmap) biçiminde gösterimi.	53
Şekil 4.7. DETR, RF-DETR ve RT-DETR modellerinin başarı değerlerinin dağılımını gösteren kutu grafiği.	54
Şekil 4.8. RT-DETR modelinde çok aşamalı adaptif veri artırma tekniklerinin mAP skoruna etkisi.	55
Şekil 4.9. Çoklu nesne takip algoritmalarının FPS (hız) ve MOTA (izleme doğruluğu) değerlerine göre karşılaştırılması.	56
Şekil 5.1. Elektrikli gemiler için şarj soketi tespit uygulamasının ana arayüzü.	60
Şekil 5.2. YOLOv5 tabanlı uygulama arayüzü üzerinden gerçek zamanlı şarj soketi tespiti ve konum-mesafe bilgilerinin gösterimi.	61
Şekil 5.3. Gerçek zamanlı şarj soketi tespit sistemi ve uygulama arayüzü.	62
Şekil 5.4. Robotik STS şarj sisteminin donanım bileşenleri: gömülü platform, PLC tabanlı kontrol panosu, kamera ve erkek şarj soketi.	63
Şekil 5.5. Robotik STS şarj sistemi erkek-dişi soket hizalama süreci: (a) park pozisyonu, (b) hizalanmış konum, (c) kenetlenme durumu.	64
Şekil 5.6. Geliştirilen robotik STS şarj sistemi üzerinde erkek ve dişi şarj soketlerinin konumlandırılması ve uygulama arayüzü görünümü.	65

ELEKTRİKLİ GEMİLERİN ŞARJ PROSESİ İÇİN YAPAY ZEKÂ TABANLI YENİ BİR OTONOM KONTROL SİSTEMİ

ÖZET

Denizyolu taşımacılığı, küresel ticaretin omurgasını oluşturarak ekonomik ve stratejik açıdan önem taşımaktadır. Ancak fosil yakıt kullanımına bağlı olarak ortaya çıkan yüksek sera gazı emisyonları, sektörü sürdürülebilir ve düşük emisyonlu teknolojilere yönlendirmektedir. Bu doğrultuda, elektrikli ve hibrit gemilerin yaygınlaşmasıyla birlikte, limanlarda güvenli, hızlı ve otonom şarj sistemlerine duyulan ihtiyaç artmaktadır.

Bu tez kapsamında, elektrikli gemilerin limanlarda kıyıda gemiye (Shore-to-Ship, STS) şarj sürecini gerçekleştirebilecek robotik şarj istasyonu için yapay zekâ tabanlı yeni bir otonom kontrol sistemi geliştirilmiştir. Farklı çevresel koşullarda (gündüz/gece, bulutlu/güneşli) elde edilen görüntülerden özgün bir şarj soketi veri seti oluşturulmuş; nesne tespiti için YOLOv3, YOLOv5 ve YOLOv8 mimarileri karşılaştırılmıştır. YOLOv5 üzerinde Focal, SIOU ve Boundary-Aware kayıp fonksiyonları kullanılarak performans iyileştirmeleri sağlanmıştır. Ayrıca DETR, RT-DETR ve RF-DETR mimarileri analiz edilmiş; RT-DETR üzerinde çok aşamalı adaptif veri artırma stratejisi geliştirilerek değişen senaryolarda genelleme başarımı belirgin şekilde artırılmıştır.

Nesne tespitinden sonra limana yaklaşan gemilerin takibini sağlamak için DeepSORT, ByteTrack, OC-SORT, SORT, BoT-SORT ve StrongSORT algoritmaları sırasıyla test edilmiş ve performans analizleri yapılmıştır. Takip algoritmalarının değerlendirilmesinde; (1) Çoklu Nesne Takibi (MOT) algoritmalarının performansını ölçmek ve (2) hareketli sahnelerde limana yaklaşan gemilerin çoklu hedef senaryolarını analiz etmek amacıyla, literatürde yaygın olarak kullanılan Singapore Maritime Dataset (SMD) tercih edilmiştir. Tüm modeller, NVIDIA A100 GPU üzerinde eğitilmiş; ayrıca Jetson Nano ve Jetson Xavier Nx platformlarında gerçek zamanlı test edilmiştir. RGB kamera ve lazer sensör verileri, veri füzyonu yöntemiyle birleştirilmiş; soketin konumuna göre elde edilen bilgiler Modbus protokolü üzerinden PLC'ye aktarılmıştır. Bu süreç soketler arasındaki mesafe 60 cm'ye ulaşınca kadar devam ettirilmiş, belirlenen mesafeden sonra ise daha hassas hizalama için lazer sensör tabanlı sistem devreye alınmıştır. Lazer destekli hizalamanın ardından erkek ve dişi soket kenetlenmiş, fiziksel bağlantı sağlanarak enerji aktarımı mümkün kılınmıştır. Gömülü donanım entegrasyonu sayesinde gerçek zamanlı karar verme ile hareket kontrolü gerçekleştirilmiş; Jetson Nano üzerinde optimize edilen algoritmalar PyQt tabanlı arayüz ile desteklenmiştir. Ayrıca Snap7 kütüphanesi kullanılarak PLC ile doğrudan iletişim kurulmuş, Modbus tabanlı haberleşmeye ek olarak daha esnek ve güvenilir bir kontrol imkânı sağlanmıştır. Saha testlerinde bağlantı süresinin 30 saniyenin altına düşürülmesiyle güvenli, hızlı ve hassas enerji aktarımı doğrulanmıştır.

Sonuç olarak, geliştirilen sistem, laboratuvar ortamında prototip testleri ve saha denemeleriyle doğrulanarak güvenilirlik, hız ve hassasiyet açısından etkinliğini kanıtlamıştır. Bu tez, yapay zekâ tabanlı robotik otonom şarj sistemlerinin denizcilik sektörüne entegrasyonu konusunda uygulanabilir bir çözüm modeli sunmaktadır.



A NOVEL AI-BASED AUTONOMOUS CONTROL SYSTEM FOR THE CHARGING PROCESS OF ELECTRIC SHIPS

SUMMARY

Maritime transportation constitutes the backbone of global trade, providing indispensable economic and strategic connectivity between nations. With more than 80% of global goods transported by sea, the shipping industry serves as both a key economic driver and a fundamental component of the global supply chain. However, the sector's dependence on fossil fuels has led to significant greenhouse gas emissions, making it one of the major contributors to climate change. This reality has accelerated the search for sustainable and low-emission technological alternatives. In line with this transformation, the International Maritime Organization (IMO) has introduced strict decarbonization targets, including a 50% absolute emission reduction and a 70% carbon intensity reduction by 2050 compared to 2008 levels. The growing adoption of electric and hybrid vessels is a direct response to these global objectives, yet it brings with it a set of operational challenges, among which the development of safe, fast, and fully autonomous charging systems at ports is of critical importance.

This doctoral research addresses these challenges by proposing and validating a robotic autonomous control system capable of performing the shore-to-ship (STS) charging process without human intervention. The proposed system combines artificial intelligence, computer vision, and embedded control techniques to execute the detection, localization, tracking, and precise alignment of a ship's charging inlet with the shore-based connector. The primary objectives of the system design are to improve operational safety, reduce connection time, increase alignment precision, and ensure adaptability in diverse environmental conditions.

A major contribution of this work lies in the creation of an original charging socket image dataset specifically designed for maritime conditions. The images were captured using an RGB camera mounted on the robotic manipulator under a wide variety of environmental settings, including day and night operations, different weather conditions such as sunny or cloudy skies, and varying illumination intensities. This diversity was deliberately introduced to enhance the robustness of the detection models and to ensure their ability to generalize to real-world port environments where lighting, reflections, and partial occlusions are common. The dataset also incorporates background variations to simulate potential distractors, thereby providing a comprehensive resource for both this project and future research in maritime automation.

For the object detection stage, three widely used YOLO architectures: YOLOv3, YOLOv5, and YOLOv8—were implemented and evaluated using standard performance metrics such as precision, recall, mean Average Precision (mAP) at different Intersection over Union (IoU) thresholds, and inference time. The comparative analysis demonstrated that YOLOv5 achieved the optimal balance between detection accuracy and computational efficiency, making it the most suitable choice for real-time embedded deployment in this system. Following the model

selection, further performance optimization was conducted by integrating advanced loss functions. Focal Loss was applied to address class imbalance and to prioritize difficult samples during training, Siou Loss was incorporated to enhance bounding box regression accuracy by accounting for vector-based spatial relationships, and Boundary-Aware Loss (BAL) was used to improve edge precision, especially in high-glare maritime scenes where socket boundaries are less distinct. Experimental results demonstrated that these loss-function-based optimizations improved localization precision and robustness against background clutter.

In addition to convolutional network-based models, transformer-based detection architectures such as DETR, RT-DETR, and RF-DETR were also examined. While DETR demonstrated strong capabilities in global feature modeling, RT-DETR was selected for further optimization due to its superior balance between accuracy and inference speed. A novel multi-stage adaptive data augmentation strategy was designed for RT-DETR, which included contrast enhancement using CLAHE to improve performance in low-light environments, shadow manipulation to replicate real maritime lighting variations, mosaic augmentation to increase scene diversity, MixUp and CutMix methods to improve class generalization, and test-time augmentation (TTA) to enhance prediction stability. This adaptive strategy significantly improved model generalization, with mAP scores increasing by more than ten percentage points under challenging lighting and background conditions.

After object detection, the system incorporated multi-object tracking to maintain continuous identification of the charging socket and reference points throughout the alignment process. Six state-of-the-art multi-object tracking algorithms—DeepSORT, ByteTrack, OC-SORT, SORT, BoT-SORT, and StrongSORT—were tested and compared. The evaluation used widely accepted metrics such as Multiple Object Tracking Accuracy (MOTA), Identity F1 Score (IDF1), and the number of ID switches. The Singapore Maritime Dataset (SMD) was selected as the benchmark due to its realistic maritime traffic scenes, variety of vessel types, and challenging environmental conditions. ByteTrack and BoT-SORT were found to offer the best combination of accuracy and stability, particularly in scenes with frequent partial occlusions.

To further enhance alignment accuracy, a sensor fusion approach was implemented by combining visual data from the RGB camera with distance measurements from a laser rangefinder. After socket detection, the real-time position was transmitted to the programmable logic controller (PLC) via the Modbus protocol, enabling the male and female connectors to be aligned until the distance reached approximately 60 cm. Beyond this point, the laser-based subsystem was activated for fine alignment. Closed-loop feedback control ensured smooth and accurate connector engagement even under environmental disturbances such as vessel movement caused by waves. The entire system was deployed on an NVIDIA Jetson Nano platform, chosen for its low power consumption and high computational efficiency in running CUDA-accelerated deep learning models. Additional optimizations, including model quantization and TensorRT acceleration, were applied to meet the strict real-time inference requirement of under 30 milliseconds per frame.

A PyQt-based graphical user interface (GUI) was developed to provide real-time visualization of the detection and tracking outputs, alignment progress, and system diagnostics. The interface included options for manual override to allow human

intervention in case of anomalies, as well as logging functions to record operational data for performance analysis and system improvement.

Extensive prototype trials were conducted in a laboratory environment simulating port conditions. The trials demonstrated that the alignment and secure connection process could be completed in less than thirty seconds, significantly reducing vessel turnaround times. Detection accuracy remained above 95% mAP at IoU 0.5 in both daytime and nighttime conditions, and tracking stability was maintained despite wave-induced vessel motion and the presence of other moving objects. No safety incidents occurred during the fully autonomous operation cycles.

In conclusion, the developed robotic autonomous control system provides a practical and deployable solution for integrating AI-powered shore-to-ship charging into the maritime industry. By combining high reliability, rapid operation, and precise alignment, the system meets industrial performance requirements while contributing to the IMO's greenhouse gas reduction targets. The research offers both academic novelty and direct industrial applicability, representing a significant step towards smart and sustainable port infrastructures that support the widespread adoption of electric vessels.




1. GİRİŞ

Günümüzde denizyolu taşımacılığı, küresel ticaretin %90'ından fazlasını oluşturarak; tedarik zincirlerinin sürekliliği, yolcu taşımacılığının güvenliği ve lojistik operasyonların verimliliği açısından merkezî bir rol üstlenmektedir. Bu stratejik öneme rağmen, denizcilik sektörü fosil yakıt kullanımı nedeniyle küresel sera gazı emisyonlarının yaklaşık %3 ila %5'inden sorumludur [1, 2]. Fosil yakıtların yanması sonucunda ortaya çıkan karbondioksit (CO₂), kükürt oksitler (SO_x), azot oksitler (NO_x) ve siyah karbon gibi zararlı emisyonlar; sektörün iklim değişikliği üzerindeki olumsuz etkisini ciddi biçimde artırmaktadır. Mevcut eğilimlerin devam etmesi ve etkin iklim politikalarının hayata geçirilmemesi durumunda, bu oranın 2050 yılı itibarıyla %17-%18 seviyelerine ulaşacağı öngörülmektedir. Bu durum, sektörün uzun vadeli sürdürülebilirlik hedeflerine ulaşabilmesi için kapsamlı ve kararlı adımların atılmasını zorunlu kılmaktadır [3]. Uluslararası Denizcilik Örgütü (International Maritime Organization, IMO), Avrupa Yeşil Mutabakatı doğrultusunda [4, 5], 2050 yılına kadar denizcilik kaynaklı emisyonları %50 azaltmayı hedeflemekte ve net sıfır emisyon senaryolarına geçiş çağrısı yapmaktadır (Şekil 1.1). Bu küresel hedeflere ulaşabilmek için yalnızca gemi teknolojileri değil, liman altyapılarında da sürdürülebilir çözümlerin yaygınlaştırılması önem kazanmaktadır. Özellikle elektrikli ve hibrit gemiler, denizcilikte fosil yakıt bağımlılığını azaltma potansiyeliyle öne çıkmakta; bu gemilerin operasyonel verimliliğini artırmak için otonom şarj sistemlerinin geliştirilmesi kritik bir ihtiyaç haline gelmektedir [6].

Son yıllarda, özellikle robotik tabanlı kıyıdan gemiye (Shore-to-Ship, STS) şarj çözümleri akıllı liman teknolojileri kapsamında ön plana çıkmaktadır. Bu sistemler, kara araçlarındaki şarj teknolojilerine benzer şekilde çalışmakla birlikte, denizcilik sektörüne özgü yüksek güç gereksinimleri ve kısa süreli bağlantı ihtiyaçlarına yanıt verecek şekilde özelleştirilmektedir. Bu sayede STS çözümleri, yalnızca gemi emisyonlarını azaltmakla kalmayıp, liman operasyonlarının çevresel etkilerini de azaltarak sürdürülebilirlik hedeflerine önemli ölçüde katkıda bulunmaktadır [7-9]. STS sistemlerinin artan önemi, şarj sürecinin otonom şekilde yönetilmesi gerekliliğini de beraberinde getirmiştir. Bu kapsamda geliştirilen sistemler, robotik donanımın

yazılım tabanlı kontrol mekanizmalarıyla entegre edilmesiyle çalışmakta; çevresel koşullara uyum sağlayarak liman ve gemi altyapısı arasındaki etkileşimi gerçek zamanlı yönetebilmektedir. Böylece operasyonel güvenlik artırılmakta, insan müdahalesi azaltılmakta ve enerji kayıpları en aza indirilmektedir [10].



Şekil 1.1. Denizcilik sektörü için 2018-2050 dönemi öngörülen yakıt dağılımı [11] (IMO hedef senaryosu, DNV'nin izniyle yayınlanmıştır).

Bu teknolojik dönüşümün arka planında, literatürde robotik şarj kollarına yönelik hareket kontrolü, hedef konum tespiti ve hassas hizalama algoritmalarının yanı sıra farklı otonom kontrol yaklaşımları yer almaktadır. Bu çalışmalar, enerji verimliliğini artırmak ve operasyonel güvenliği sağlamak amacıyla geliştirilmiştir. Özellikle elektrikli gemi teknolojilerinin hızla yaygınlaşması, STS sistemlerinin tam otomasyonla çalışma gerekliliğini daha da ön plana çıkarmıştır [12, 13].

1.1. Literatür Taraması

Bu tez çalışması kapsamında, elektrikli gemi kıyı robotik şarj sistemleri için: farklı çevresel koşullarda oluşturulan özgün şarj soketi veri seti ile eğitilmiş; şarj soketi konumunun ve mesafesinin yüksek doğrulukla belirlenmesinde yapay zekâ tabanlı çeşitli şarj soketi tespit ve gemi takip uygulamalarını içeren; PLC ve gömülü sistem tabanlı; RGB kamera ve lazer sensörleri verilerinin veri füzyonu ile entegre edildiği; PyQt tabanlı gerçek zamanlı arayüz içeren; gerçek zamanlı saha koşullarında test

edilecek olan; maliyet-etkin (bağlantı süresi ve bellek kullanımı az olan), güvenli, hassas ve bütüncül yeni bir otonom kontrol sistemi geliştirilmesi hedeflendiğinden, bu bağlamda kapsamlı bir literatür taraması yapılmıştır.

Literatürde incelenen birinci kısım çalışmalarda, elektrikli araç şarj teknolojileriyle ilgili çeşitli çalışma ve araştırmalar yer almaktadır. Fakat bu çalışmalarda görüntü işleme ve/veya yapay zekâ tabanlı sistemlerin kullanılmadığı görülmektedir: Bu çalışmalar arasında Walzel vd. [14], elektrikli araçlar için önerdikleri şarj istasyonu prototipinde otomatik şarj teknolojilerindeki gelişmeleri incelemişlerdir. Çalışmalarında, robotik kollar aracılığıyla şarj konektörünün araç soketine tamamen otonom biçimde bağlanabilmesini sağlayan sensör teknolojileri ve kontrol algoritmalarının tasarımına odaklanmışlardır. Guidi vd. [15], robotik şarj uygulamalarının kullanım kolaylığı ve güvenlik açısından önemli avantajlar sunduklarını belirtmişlerdir. Ayrıca bu tür sistemlerin denizcilikte operasyonel verimliliği artırma ve sürdürülebilirliğe katkı sağlama potansiyellerine vurgu yapmışlardır. Kumar vd. [16], şarj bataryalarının daha kolay şarj edilebilmesi amacıyla şarj istasyonlarını incelemişler; bu sistemlerin pratik uygulanabilirliklerini ve teknik zorluklarını tartışmışlardır. Karimi vd. [12], güç sistemi mimarileri, şarj altyapısı ve şarj yönetimi kontrol sistemlerini kapsayan mevcut ve gelecekteki trendlere genel bir bakış sunmuşlardır. Guo vd. [17], STS sistemlerinin liman elektrifikasyonu ve karbon emisyonlarının azaltılması açısından kritik rolünü detaylı biçimde incelemişler; hem kablolu hem de kablosuz çözümleri, enerji yönetim stratejilerini ve standardizasyon çabalarını kapsamlı şekilde ele almışlardır. Mutarraf vd. [18], tam elektrikli gemi operasyonları bağlamında şarj altyapısı gereksinimlerine, enerji talebi yönetimine ve entegre sistem planlamasına odaklanarak, STS sistemlerinin tümleşik elektrikli gemi yönetimindeki temel rollerini vurgulamışlardır. Zhang vd. [34], Amsterdam kanal ağında elektrikli gemiler için mobil enerji dağıtımına yönelik RoboCharger sistemini önermişlerdir. Bu sistem, şarj altyapısının esnekliğini artırmayı ve operasyonel verimliliği geliştirmeyi hedeflemiştir. Bucher vd. [19], elektrikli araçlar için Serbestlik Derecesi (Degrees of Freedom, DoF) ve Kombine Şarj Sistemi (Combined Charging System, CCS) konektörüne bağlı, düşük maliyetli bir kamera içeren yenilikçi bir şarj robotu tanıtmışlardır. Behl vd. [20], park halindeki elektrikli araçların otonom şarjı için engellerden kaçınarak haritalayan bir robot mekanizması ve yeni bir robotik sistem önermişlerdir.

Bu tez çalışması ise literatürdeki bu eksikliği gidermeye yönelik olarak görüntü işleme ve yapay zekâ tabanlı çözüme odaklanmıştır.

Literatürde incelenen ikinci kısım çalışmalarda, elektrikli araçlardaki şarj soketleri, nesne algılama ve/veya nesne takibi ile ilgili yapılan görüntü işleme tabanlı çalışmaları içermektedir. Fakat bu çalışmaların yapay zekâ tabanlı olmadığı ve nesne takibi içeren çok az sayıda çalışma olduğu görülmektedir: Bazı araştırmacılar, şarj soketi pozisyonunu hızlı bir şekilde algılamak amacıyla robot kontrollü yaklaşımlar geliştirmiştir [21]. Bazı çalışmalarda, eşik bölütleme ve stereo kamera tabanlı 3D görüntüleme tekniklerinden yararlanılarak robot tabanlı şarj istasyonu sistemleri önerilmiştir [22]. Elektrikli araç tipi tespiti, sınıflandırma ve şarj noktası lokalizasyonu için 2D kameralar [24] ile şekil tabanlı 3D eşleme yöntemlerinin kullanıldığı örnekler de mevcuttur [25]. Quan vd. [26], elektrikli araç şarj portlarının tespiti için Hough çemberi, Canny operatörü, QCS ve PNP algoritmalarını temel alan bir yöntem kullanırken; diğer bir çalışmalarında ise [27] Küme Şablonu Eşleştirme Algoritması (Cluster Template Matching Algorithm, CTMA) ve feature circle algoritmasından yararlanmışlardır. Ayrıca, nesne konumunu otomatik olarak çıkarmak amacıyla Ton Doygunluk Değer (Hue Saturation Value, HSV) tabanlı yöntemler [28], HSV ve Kalman filtresine dayalı yöntemler [29], HSV renk modeli ve Canny operatörüne dayalı yöntemler [30], Ölçekten Etkilenmeyen Özellik Dönüşümü (Scale Invariant Feature Transform, SIFT) algoritması ile Yaklaşık En Yakın Komşular için Hızlı Kütüphane (Fast Library for Approximate Nearest Neighbors, FLANN) eşleştirme algoritmasına dayalı yöntemler [31] önerilmiştir. Güney vd. [32] gemi üzerindeki şarj soketini tespit etmek amacıyla HSV renk uzayı tabanlı görüntü işleme ve morfolojik işlem adımlarını kullanan bir yöntem geliştirmiştir. Bu yaklaşım, özellikle tek sınıflı tespit senaryolarında hızlı ve düşük maliyetli bir çözüm sunarken, değişken ışık koşullarında renk tabanlı yöntemlerin hassasiyetinin sınırlı kalabileceği belirtilmiştir. Çalışmada, soket bölgesinin segmentasyonu sağlanmış ve ardından geometrik filtreleme ile yanlış pozitifler azaltılarak daha kararlı sonuçlar elde edilmiştir.

Bu tez çalışması ise, görüntü işlemenin yanında nesne algılama, nesne takibi ve yapay zekâ tabanlı teknolojilerin, farklı kaynaklardan elde edilen verilerin veri füzyonu yaklaşımıyla birlikte kullanılmasını önermektedir.

Literatürde incelenen üçüncü kısım çalışmalarda, elektrikli araç şarj istasyonları ve otonom şarj için çeşitli nesne algılama ve/veya nesne takip ile ilgili yapılan yapay zekâ

tabanlı çalışmalar yer almaktadır. Fakat bu çalışmalar, görüntü işleme teknikleri, özgün veri seti, takip algoritmaları kullanımı, gerçek zamanlı arayüz, farklı ortam koşullarına uyum, saha testi ile doğrulama ve gömülü platform kavramlarının tamamını içermediği, bir veya birkaçını içerdiği görülmektedir: Rashmi vd. [33], zorlu hava koşullarında nesne tespiti için YOLOv5 tabanlı, hafifletilmiş SD-YOLO-AWDNet modelini geliştirerek C3Ghost, GhostConv, DSDC ve CA modülleri ile Focal-Distribution kayıp fonksiyonlarının entegrasyonu sayesinde performans artışı sağlamışlardır. Radovic vd. [35], nesne tanımayı geliştirmek amacıyla çeşitli hava görüntülerinden yararlanan bir Evrişimsel Sinir Ağı (Convolutional Neural Network, CNN) modeli önermişler ve deneylerinde hem nesne algılama hem de sınıflandırma görevlerinde yüksek doğruluk elde etmişlerdir. Zhu vd. [36], gelişmiş bir YOLOv4 ağ mimarisi kullanarak geniş kapsamlı tanıma yeteneklerine ve farklı araç modellerindeki şarj bağlantı noktalarını tanımlama kapasitesine sahip bir otomatik şarj sistemi tanıtmışlardır. Güney vd. [37], elektrikli gemilerin şarj soketini tespit etmek ve hizalamak amacıyla bilgisayarlı görme, YOLOv5 ve görüntü işleme tabanlı bütüncül bir otonom robotik şarj sistemi geliştirmişlerdir. Bir diğer çalışmada [38], şarj portu konumunu elde etmek ve otomatik şarj bağlantısını gerçekleştirmek üzere yüksek çözünürlüklü bir video kamera ve CNN tabanlı bir yöntem önerilmiştir. Mahaadevan vd. [39], elektrikli araç şarj altyapısının otomatikleştirilmesi amacıyla geliştirdikleri EVS-YOLO modeli ile görüntü işleme ve derin öğrenme tabanlı soket tanımlama yaklaşımı sunmuşlardır. Quan vd. [40], farklı araç tiplerine ait şarj noktalarının tanımlanmasını sağlamak amacıyla CBAM (Convolutional Block Attention Module) ve YOLOv7 yöntemlerini birleştiren bir otomasyon yaklaşımı önermişlerdir. Yu vd. [23] ise monoküler görüş, kırılma yasası ve derin öğrenme tabanlı hedef konum belirleme yöntemini birleştirerek insansız su altı araçlarının şarj platformuna yüksek hassasiyetle hizalanmasını sağlamışlardır.

Bu tez çalışması ise görüntü işleme teknikleri, özgün veri seti, takip algoritmaları kullanımı, gerçek zamanlı arayüz, farklı ortam koşullarına uyum, saha testi ile doğrulama ve gömülü platform kavramlarının tamamını içermektedir (Tablo 1.1).

Tablo 1.1. Tez çalışmasının kapsamı ve en yakın olan çalışmalar.

Kriterler \ Çalışmalar	Bu tez çalışması	Rashmi vd. [33]	Quan vd. [26]	Yu vd. [23]	Zhang vd. [34]
Otonom şarj sistemi	✓	X	✓	✓	✓
Görüntü işleme tabanlı kontrol	✓	✓	✓	✓	X
Derin öğrenme tabanlı tespit	✓	✓	X	✓	X
Transformer model analizi	✓	X	X	X	X
Takip algoritmaları kullanımı	✓	X	X	X	X
Gömülü platform uygulaması	✓	X	✓	✓	X
Gerçek zamanlı arayüz	✓	X	✓	✓	✓
Sensör füzyonu (RGB+lazer vb.)	✓	✓	X	X	X
Farklı ortam koşullarına uyum	✓	✓	✓	✓	✓
Saha testi / simülasyon ile doğrulama	✓	✓	✓	✓	✓
Çok aşamalı adaptif veri artırma	✓	X	X	X	X
Kayıp fonksiyonu tabanlı performans iyileştirme	✓	X	X	X	X
Düşük maliyetli donanım	✓	✓	✓	✓	X

Tablo 1.2’de bu tez çalışmasına en yakın olan literatürdeki çalışmalar ile tez kapsamında gerçekleştirilen sistemin genel özelliklerinin karşılaştırılması verilmiştir.

Tablo 1.2. Tez çalışmasına en yakın olan literatürdeki çalışmalar ile gerçekleştirilen sistemin genel özelliklerinin karşılaştırılması.

Kriterler \ Çalışmalar	Bu tez çalışması	Rashmi vd. [33]	Quan vd. [26]	Yu vd. [23]	Zhang vd. [34]
Uygulama Alanı	Elektrikli gemilerin otonom kontrollü, yapay zekâ tabanlı şarj prosesi	Otonom araçlarda zorlu hava koşulları altında nesne tespiti	Elektrikli araçlarda otomatik şarj portu bağlantı ve tanımlama	Su altı araçlar için şarj platformu hizalama ve otomatik bağlantı	Elektrikli gemiler için mobil şarj botlarının görev planlaması
Araştırmanın Amacı	Zorlu koşullarda daha hızlı, hassas ve otonom enerji aktarımı sağlamak	Değişken sahnelerde hızlı, güvenilir ve hafif nesne tespiti	Karmaşık sahnelerde şarj portu tanıma ve robotik bağlantı	Monoküler kamera ile hassas hizalama ve otonom şarj sağlamak	Gemilerin kesintisiz çalışması için MED planlaması
Kullanılan Yöntemler	YOLO (v3, v5, v8), DETR (Temel, RT, RF), MOT algoritmaları, veri artırma, optimizasyon	YOLOv5 + C3Ghost, GhostConv, CA, DSDC, Focal distribution loss	Hough dönüşümü, Canny kenar tespiti, QCS kontur uyumu ve PNP yöntemleri	Monoküler görüntü işleme, derin öğrenme tabanlı hedef tespiti ve ArUco kod tanıma	MinHash tabanlı trafik tahmini, MOEA/D, CSP optimizasyonu
Donanım Entegrasyonu	PLC, gömülü platform, RGB kamera, lazer sensörleri veri füzyonu	Yalnızca kamera tabanlı (gömülü donanım detayı yok)	Endüstriyel kamera, kontrol sistemi, AUBO 6-DOF robot	Monoküler kamera, kayar tabla ve şarj çubuğu entegrasyonu	Fiziksel donanım yok, simülasyon tabanlı
Veri Setleri ve Katkılar	Özgün şarj soketi, SMD. Çok aşamalı adaptif veri artırma, otonom-kontrol, kayıp fonksiyonu optim.	BDD100k, KITTI, CAD. YOLOv5'in hafifletilmesi, daha hızlı nesne tespiti	Gerçek sahnede çoklu ışık koşulu verileri. Feature-free ile şarj portu konumlama	Sualtı deney verileri, ArUco. Monoküler görme tabanlı hizalama yöntemi	MarineTraffic, Amsterdam verileri. Adaptif dinamik görev planlama

1.2. Tezin Amacı ve Literatüre Katkıları

Bu tez çalışmasının temel amacı, elektrikli robotik şarj sistemleri için yapay zekâ tabanlı yeni bir otonom kontrol sistemi geliştirerek, elektrikli gemilerin daha güvenli, hızlı ve hassas bir şekilde şarj edilmesini sağlamaktır. Geliştirilen sistem ile gemilerin operasyonel programları dikkate alınarak bağlantı sürelerinin azaltılması ve insan müdahalesinin en aza indirilerek tam otomasyonla çalışan bir yapı ortaya konulması hedeflenmiştir.

Bu kapsamda geliştirilen sistemin özgün yönleri ve literatüre katkıları aşağıda maddeler hâlinde özetlenmiştir:

- Elektrikli deniz araçlarının hızlı, güvenli, hassas ve otonom şarj prosesine yönelik maliyet-etkin ve uygulanabilir bir robotik sistem tasarlanmıştır. PLC, gömülü sistem, RGB kamera ve lazer sensörlerinin entegre edildiği donanımsal, bütüncül bir yapı oluşturulmuş ve yapay zekâ tabanlı kontrol algoritmaları geliştirilerek gerçek zamanlı karar alma kabiliyeti sağlanmıştır.
- Farklı çevresel koşullarda, iç mekan (gündüz/gece) ve dış mekan (bulutlu/güneşli), şarj soketi görüntüleri içeren özgün bir veri seti oluşturularak literatüre sunulmuştur.
- Şarj soketi konum ve mesafesinin yüksek hassasiyetle tespit edilmesi için YOLOv3, YOLOv5 ve YOLOv8 mimarileri temel alınarak doğruluk oranları test edilmiş; YOLOv5 mimarisi üzerinde kayıp fonksiyonları tabanlı performans iyileştirme gerçekleştirilmiştir. Bu kapsamda Focal, SIOU ve Boundary-Aware fonksiyonları optimize edilmiş, farklı kayıp kombinasyonları kullanılarak modelin doğruluk oranlarında anlamlı artış elde edilmiştir.
- DETR, RT-DETR ve RF-DETR transformer tabanlı mimariler analiz edilmiş; bu modeller tespit sürecinde doğruluk, hız ve sistem entegrasyonu açısından değerlendirilmiştir. RT-DETR mimarisi üzerinde çok aşamalı adaptif veri artırma stratejisi geliştirilmiş ve farklı senaryo koşullarında modelin genelleme başarımını artıracak şekilde veri çeşitliliği dinamik olarak optimize edilmiştir.
- Nesne tespitine ek olarak limana yaklaşan gemilerin takibini sağlamak amacıyla Singapore Maritime Dataset (SMD) üzerinde MOT tabanlı

DeepSORT, ByteTrack, OC-SORT, SORT, BoT-SORT ve StrongSORT takip algoritmaları entegre edilerek izleme başarımları test edilmiştir.

- RGB kamera ve lazer sensörlerinden elde edilen veriler, optimize edilerek geliştirilen algoritmalar aracılığıyla veri füzyonu yöntemiyle birleştirilmiş; bu sayede şarj soketinin doğru tespiti, hassas hizalanması ve güvenli enerji aktarımı sağlanmıştır. Sistem, hem masaüstü ortamda hem de Jetson Nano gömülü platformunda gerçekleştirilmiştir.
- Geliştirilen otonom kontrol sistemi, bağlantı süresini 30 sn.'nin altına indirerek operasyonel verimliliği artırmakta ve enerji aktarım sürecini hızlandırmaktadır. Bununla birlikte, sistem için tasarlanan PyQt tabanlı arayüz, sistem durumu, soket koordinatları ve mesafe verilerinin gerçek zamanlı olarak izlenmesini sağlamaktadır.
- Geliştirilen sistemin performansı saha koşullarında test edilerek doğrulanmış ve üniversite-sanayi işbirliği çerçevesinde uygulamaya hazır bir çözüm olarak ortaya konmuştur.

Bu tez nesne algılama, nesne takip ve veri füzyonu bileşenlerini sahada doğrulayan bir yapıda bütünleştirerek özgün katkılar sunmakta; yapay zekâ destekli robotik şarj sistemlerinin denizcilik sektörüne entegrasyonu konusunda literatürdeki eksikliğin giderilmesine katkı sağlamaktadır. Geliştirilen otonom kontrol sisteminin, yalnızca elektrikli gemilerde değil, aynı zamanda elektrikli araç sektöründe de yaygınlaştırılmasıyla birlikte; hem elektrikli deniz taşıtlarının kullanımının teşvik edilmesine ve çevresel sürdürülebilirliğin güçlendirilmesine, hem de karbon ayak izinin azaltılmasına dolaylı katkılar sağlaması beklenmektedir.

1.3. Tezin Organizasyonu

Bu tez çalışmasında elektrikli gemilerin limanlarda kıyıdan gemiye şarj sürecini gerçekleştiren robotik şarj istasyonu için yapay zekâ tabanlı yeni bir otonom kontrol sistemi tasarlanmış, geliştirilmiş ve deneysel olarak doğrulanmıştır.

Birinci Bölümde, çalışmanın amacı, önemi ve motivasyonu ortaya konmuş; denizcilik sektöründeki emisyon azaltım hedefleri, elektrikli ve hibrit gemilere geçiş süreci ve bu dönüşümün liman altyapılarında ortaya çıkardığı yeni gereksinimler tartışılmıştır.

Literatürde yer alan robotik şarj çözümleri, bilgisayarlı görme tabanlı konumlandırma yöntemleri ve yapay zekâ destekli kontrol yaklaşımları sistematik ve eleştirel biçimde incelenmiş; mevcut boşluklar belirlenerek bu tez çalışmasının alana sağlayacağı katkılar açıklanmıştır.

İkinci Bölümde, derin öğrenme tabanlı nesne tespiti ve çoklu nesne takibi yöntemleri ayrıntılı olarak ele alınmıştır. Bu kapsamda temel yapılar tanıtılmış; iki aşamalı tespit yöntemlerinden Faster R-CNN ve FPN, tek aşamalı yöntemlerden SSD ve YOLO mimarileri karşılaştırmalı biçimde açıklanmıştır. Ayrıca transformer tabanlı yaklaşımlar olan ViT, DETR, RT-DETR ve RF-DETR ele alınmış; çoklu nesne takibi alanında DeepSORT, ByteTrack, StrongSORT, BoT-SORT ve OC-SORT algoritmalarının çalışma prensipleri, avantajları ve sınırlılıkları tartışılmıştır.

Üçüncü Bölümde, geliştirilen otonom robotik STS şarj sisteminin donanım ve yazılım altyapısı sunulmuştur. Donanım tarafında, robotik platform, PLC kontrol altyapısı, motor sürücüler, lineer aktüatörler ve sensör entegrasyonu açıklanmıştır. Yazılım tarafında, Jetson Nano üzerinde çalışan YOLO ve DETR tabanlı görsel algılama algoritmaları, konum-mesafe çıkarımı ve gerçek zamanlı haberleşme süreçleri detaylandırılmıştır. Ayrıca, bu bölümde tez kapsamında oluşturulan özgün şarj soketi veri seti tanıtılmış; farklı açılar, ışık koşulları ve perspektiflerden elde edilen görüntüler üzerinde yapılan veri ön işleme ve sınırlı veri artırma (çevirme, yeniden ölçekleme, ışık değişimleri vb.) adımları açıklanmıştır. Takip algoritmalarının performans analizine temel oluşturmak üzere, tezde kullanılan SMD veri seti tanıtılmıştır.

Dördüncü Bölümde, geliştirilen şarj soketi tespit ve takip sisteminin deneysel çalışmaları ve performans analizleri sunulmuştur. YOLOv3, YOLOv5 ve YOLOv8 modelleri üzerinde mimari karşılaştırmalar yapılmış; farklı kayıp fonksiyonlarının (Focal, SIOU, Boundary-Aware) optimizasyonları ve veri artırma stratejilerinin tespit başarımı üzerindeki etkileri ablasyon analizleriyle değerlendirilmiştir. Transformer tabanlı DETR, RT-DETR ve RF-DETR mimarilerinde doğruluk-hız dengesi incelenmiş; RT-DETR üzerinde çok aşamalı adaptif veri artırma uygulanarak farklı operasyonel senaryolarda modelin genelleme kabiliyeti güçlendirilmiştir. Ayrıca, çoklu nesne takibinde kullanılan DeepSORT, ByteTrack, BoT-SORT ve diğer MOT algoritmalarının performansları, SMD üzerinde ölçülerek performans testleri gerçekleştirilmiştir.

Beşinci Bölümde, geliştirilen sistemin gerçek zamanlı kullanıcı arayüzü tanıtılmış, donanım-yazılım entegrasyonu ve laboratuvar ortamında prototip uygulamaları ile saha benzetimleri üzerinden sistemin güvenilirliği, hız kabiliyeti ve hizalama hassasiyeti uygulamalı olarak gösterilmiştir.

Altıncı ve Son Bölümde, çalışmanın genel değerlendirmesi yapılmış; elde edilen bulgular doğrultusunda sonuçlar tartışılmış ve gelecekteki çalışmalara yönelik öneriler sunulmuştur.





2. DERİN ÖĞRENME TABANLI NESNE TESPİT VE TAKİP YÖNTEMLERİ

Bu bölümde, derin öğrenme tabanlı nesne tespit ve takip süreçlerinde kullanılan yaklaşımlar kapsamlı şekilde ele alınmaktadır. Derin öğrenmenin yaygınlaşmasından önce bilgisayarlı görme alanında geleneksel görüntü işleme tabanlı yöntemler kullanılmıştır. Bu kapsamda renk tabanlı yaklaşımlar (HSV), kenar tespit yöntemleri (Sobel, Canny) ve öznitelik çıkarımına dayalı teknikler (SIFT, SURF, HOG) uzun yıllar boyunca yaygın biçimde kullanılmıştır. Bu yöntemler, belirli koşullarda nesne sınırlarının belirlenmesi veya sahne içerisinden anlamlı özniteliklerin çıkarılmasında etkili sonuçlar üretmiş olsa da; aydınlatma değişimleri, karmaşık arka planlar ve perspektif değişimleri gibi faktörler karşısında performans kaybı yaşamıştır. Özellikle el ile tanımlanan özniteliklere bağımlılık, genelleme yeteneğini sınırlamış ve bu yöntemlerin gerçek zamanlı, yüksek doğruluklu uygulamalarda yetersiz kalmasına yol açmıştır. Bu kısıtlamalar, öğrenmeye dayalı yaklaşımların geliştirilmesini teşvik etmiş ve çok katmanlı yapıları sayesinde karmaşık örüntüleri öğrenebilen derin sinir ağlarının bilgisayarlı görme alanında kullanılmasına zemin hazırlamıştır. Böylece, derin öğrenme tabanlı yöntemler klasik görüntü işleme yaklaşımlarının yerini büyük ölçüde alarak nesne tespit ve takip yöntemlerinde yeni bir paradigma oluşturmuştur.

2.1. Derin Sinir Ağları (DNN)

DNN'ler, verileri doğrusal olmayan işlemlerle dönüştüren ve çok sayıda gizli katmandan oluşan mimarilerdir. DNN ailesi, farklı veri türlerine uygun çeşitli yapıları kapsar; bunlar arasında Çok Katmanlı Algılayıcılar (Multi Layer Perceptrons, MLP), Yinelemeli Sinir Ağları (Recurrent Neural Networks, RNN), ızgara yapısındaki görüntü verileri için optimize edilmiş Evrimsel Sinir Ağları (Convolutional Neural Network, CNN) ve Dönüştürücüler (Transformers) yer almaktadır [41, 42]. Öğrenme süreçleri, hataların geriye doğru dağıtılarak ağ parametrelerinin güncellendiği geri yayılım algoritması ve parametre optimizasyonu için yaygın biçimde kullanılan stokastik gradyan iniş gibi gradyan tabanlı optimizasyon yöntemlerine dayanmaktadır.

2.2. Evrişimsel Sinir Ağları (CNN)

CNN, doğrudan ham verilerden uçtan-uca öğrenmeyi sağlayan bir derin sinir ağı mimarisidir. Özellikle görüntü gibi uzamsal yapıya sahip verilerdeki örüntüleri modellemede son derece etkilidirler. Bu başarılarının temelinde yerel alıcı alanlar (local receptive fields), ağırlık paylaşımı (weight sharing) ve konum değişmezliği (translation invariance) gibi yapısal özellikler yer almaktadır. Bu sayede CNN'ler, girdilerdeki konumdan bağımsız olarak uzamsal örüntüleri etkin biçimde tanımlayabilirler [43, 44]. Genellikle bir CNN mimarisi; evrişim katmanları, aktivasyon fonksiyonları, havuzlama işlemleri ve tam bağlantılı katmanlardan oluşmaktadır. Evrişim katmanlarında giriş verisine öğrenilebilir filtreler uygulanarak özellik haritaları (feature maps) oluşturulur. İki boyutlu bir evrişim işlemi ise temel olarak Denk. 2.1'deki gibi tanımlanabilir.

$$S(i,j) = (I * K)(i,j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m,n) \quad (2.1)$$

Burada I giriş görüntüsünü, K filtreyi (evrişim çekirdeği), $S(i,j)$ filtre K 'nın görüntü I üzerindeki (i,j) konumuna uygulanmasıyla elde edilen evrişim işlemi çıktı değerini temsil eder. Evrişim işleminden sonra doğrusal olmayan özellik kazandırmak amacıyla genellikle bir veya birden fazla aktivasyon fonksiyonu (ReLU, sigmoid, softmax) uygulanabilir. Bu işlem sırasında filtre, görüntü üzerinde kaydırılarak her konumda eşleşen değerler çarpılarak toplanır ve böylece yeni bir matris (özellik haritası) oluşturulur. Bu özellik haritası, görüntüdeki kenar, doku, köşe gibi belirgin yapıları ortaya çıkararak sonraki katmanlara daha anlamlı veriler sunar. Örnek olarak literatürde sıklıkla kullanılan aktivasyon fonksiyonlarından biri olan ReLU'nun genel matematiksel ifadesi, negatif değerleri sıfırlayıp pozitifleri olduğu gibi geçiren bir fonksiyon olarak Denk. 2.2'de verilmiştir.


$$f(x) = \max(0, x) \quad (2.2)$$

Havuzlama (pooling) katmanları, özellikle uzamsal boyutları azaltmak ve modelin küçük yerel değişimlere karşı dayanıklılığını artırmak için kullanılır. Maks-havuzlama (max-pooling) genellikle en yaygın kullanılan yöntemdir. Mimari, son olarak tam bağlantılı katmanlarla tamamlanır ve bu katmanlar, önceki katmanlarda öğrenilen

temsilleri sınıflandırma veya diğer görevler için kullanılmaktadır. CNN modelleri, düşük seviyeli kenar ve doku özelliklerinden başlayarak, yüksek seviyeli anlamsal nesnelere kadar çok katmanlı bir özellik hiyerarşisi öğrenebilir. Bu sayede, geleneksel görüntü işleme yöntemlerinde manuel olarak gerçekleştirilen özellik çıkarımı süreci, CNN mimarilerinde veriyle eğitilen ve otomatik olarak öğrenilen bir temsil mekanizmasına dönüşmüştür.

2.3. Nesne Tespiti ve Tespit Algoritmaları

Nesne tespiti, bir görüntü ya da video karesinde yer alan anlamlı nesnelerin hem konumlarının belirlenmesini hem de sınıflandırılmasını amaçlayan temel bilgisayarlı görme görevlerinden biridir [45]. Bu süreç, sahnedeki nesnelerin yerleştirilmesini ve hangi sınıfa ait olduklarının tayin edilmesini eş zamanlı olarak gerçekleştirir (Şekil 2.1). İlk nesne tespit yaklaşımları, Viola-Jones algılama modeli [46] ve Deformable Part Model (DPM) [47] gibi yöntemlere dayanmaktadır. Bu yöntemler, elle tasarlanmış öznitelikler ve kural tabanlı işlem hatları üzerine kurulmuş olup; belirli koşullar altında kabul edilebilir doğruluk sunmalarına karşılık, karmaşık, dinamik veya değişken çevresel koşullarda yeterli genelleme yeteneği gösterememiştir.



Şekil 2.1. Nesne tespiti sürecinin genel işlem adımları.

Bu sınırlamaları aşmak amacıyla geliştirilen derin öğrenme tabanlı yöntemler, özellikle CNN'ler aracılığıyla daha esnek ve öğrenilebilir özellik temsilleri sunarak; farklı sahne yapılarında ve veri türlerinde yüksek başarımla kullanılabilir hale gelmişlerdir [48]. Derin öğrenme tabanlı nesne tespit modelleri genel olarak iki aşamalı ve tek aşamalı algılayıcılar olarak iki kısma ayrılabilir. İki aşamalı

algılayıcılar, ilk aşamada potansiyel olarak nesne barındıran bölgeleri önerir ve ikinci aşamada ise bu aday bölgeleri sınıflandırarak konumlarını hassaslaştırmaktadır. R-CNN [49], Fast R-CNN [50] ve Faster R-CNN [51] gibi yöntemler bu gruba örnek olup, özellikle yüksek karmaşıklığa sahip ve yoğun şekilde küçük nesneler içeren sahnelerde yüksek oranda doğruluk sağlamaktadır. Ancak çok aşamalı yapıları nedeniyle işlem maliyetleri yüksektir ve bu durum, gerçek zamanlı uygulamalarda kullanılmalarını zorlaştırmaktadır.

Bu sınırlamaların üstesinden gelmek için geliştirilen tek aşamalı algılayıcılar ise bölge önerisi gibi ayrı bir işlem aşamasına ihtiyaç duymadan, daha hızlı ve tek aşamalı bir çözüm sunarlar. Bu yaklaşım, hesaplama açısından daha verimli olup özellikle gömülü sistemler ve uç tabanlı uygulamalarda gerçek zamanlılık gereksinimlerini karşılamada öne çıkmaktadır. Bu gruba YOLO [52-54], SSD [55] ve RetinaNet [56] gibi modeller örnek verilebilir. Bu modeller, düşük hesaplama karmaşıklığı ile çalışarak sınırlı kaynaklara sahip sistemlerde dahi hızlı ve etkili nesne tespiti sağlamaktadır.

Tek aşamalı algılayıcılar içerisinde son yıllarda Transformer tabanlı mimariler, nesne algılama alanında güncel ve dikkat çekici bir yaklaşım olarak öne çıkmaktadır. Dikkat mekanizmaları (attention mechanisms) sayesinde genel bağlamı doğrudan öğrenebilen bu yapılar, çapa kutuları (anchor boxes) ve Non-Maximum Suppression (NMS) gibi elle tanımlanmış bileşenlere ihtiyaç duymadan çalışabilmektedir. Bu gruba ait öncü modellerden DETR [57] ve Deformable DETR [58] girdi üzerindeki uzun menzilli bağımlılıkları etkili biçimde modelleyerek yoğun nesne örtüşmesi ve konumsal karmaşanın yüksek olduğu senaryolarda güçlü performans sunmaktadır.


2.3.1. İki aşamalı nesne tespit algoritmaları

Bu kısımda, nesne tespit sürecini önce bölge önerisi, ardından sınıflandırma ve yerleştirme adımlarıyla gerçekleştiren iki aşamalı yaklaşımlar ele alınmaktadır. Bu yöntemler, derin öğrenme tabanlı nesne algılamanın öncü uygulamaları olmaları ve mimari temelleri şekillendirmeleri açısından öncelikli olarak incelenmiştir.

2.3.1.1. Feature pyramid network (FPN)

FPN, nesne algılama modellerinde yaygın olarak kullanılan, özellikle çok ölçekli nesne tespiti ihtiyacına yanıt vermek üzere geliştirilmiş etkili bir mimaridir [59]. FPN,

farklı boyutlardaki nesneleri daha doğru algılayabilmek amacıyla, çoklu çözünürlük seviyelerinde öznitelik çıkarımı yapan bir özellik piramidi oluşturur. Şekil 2.2’de görüldüğü üzere, mimari hem yukarıdan aşağıya hem de aşağıdan yukarıya bilgi akışı sağlamaktadır. Böylece düşük seviyeli detay bilgileri ile yüksek seviyeli anlamsal temsiller birleştirilerek farklı çözünürlük katmanlarında daha güçlü bir temsil elde edilir. Bu yapı, özellikle küçük nesnelerin hassas şekilde tespit edilmesini kolaylaştırır. FPN, giriş öznitelik haritalarının sayısı L ve her bir özellik haritasının boyutu $W_i \times H_i$ olacak şekilde çok katmanlı bir piramit inşa eder. Her katman, Denk. 2.3 ile tanımlanır. Burada P_k , k . seviyesindeki çıktısını; U_k ise aynı seviyede aşağıdan yukarıya gelen öznitelik bilgisini temsil eder. Upsample işlemi, bir üst katmandan gelen özniteliği genişleterek mevcut katmana aktarır. Aşağıdan yukarıya bağlantılar Denk. 2.4 ile tanımlanmakta olup, bu aşamada evrişim işlemi (conv) uygulanır. Son olarak, FPN'nin çıktısı P_1 ile P_L arasındaki tüm öznitelik haritalarının birleşimiyle elde edilir (Denk. 2.5). Bu bütünlük yapı, hem yerel detayları hem de küresel bağlamı bir arada modelleyerek çok ölçekli nesne tespitinde yüksek doğruluk sağlamaktadır [60].



Şekil 2.2. FPN yapısında çok ölçekli özellik haritalarından tahmin üretimi [59].

$$P_k = U_k + \text{upsample}(P_{k+1}) \quad (2.3)$$


$$U_k = \text{conv}(P_{k-1}) \quad (2.4)$$

$$P_{out} = \text{concat}(P_1, P_2, \dots, P_L) \quad (2.5)$$

2.3.1.2. Faster R-CNN

Faster R-CNN [51], nesne tespiti için geliştirilmiş iki aşamalı bir derin öğrenme mimarisidir. R-CNN ailesinin bir üyesi olan bu model, Fast R-CNN [50] yapısının

daha hızlı ve entegre çalışmasını sağlamak amacıyla tasarlanmıştır. Mimariye ilişkin genel yapı Şekil 2.3'te gösterilmiştir. Faster R-CNN, nesne tespiti sürecini iki temel aşamada gerçekleştirir. İlk aşamada, Bölge Öneri Ağı (Region Proposal Network, RPN) kullanılarak giriş görüntüsünden, nesne bulunma olasılığı yüksek konumları temsil eden öneri bölgeleri üretilir. Bu bölgeler, modelin dikkate alması gereken alanları belirlemede rehberlik eder. İkinci aşamada ise, RPN tarafından oluşturulan bu bölgeler, ağıın sınıflandırma ve yerelleştirme işlemlerini gerçekleştiren R-CNN bileşenine iletilir. Her bir öneri bölgesi, önceden çıkarılmış öznetelik haritaları üzerinden detaylı şekilde işlenerek nesnenin sınıfı belirlenir ve sınırlayıcı kutu konumu hassas biçimde düzeltilir [62].



Şekil 2.3. Faster R-CNN mimarisinin çalışma prensibi [60].


2.3.2. Tek aşamalı nesne tespit algoritmaları

Bu kısımda, tek aşamada hem sınıflandırma hem de konumlandırma görevlerini gerçekleştiren, dolayısıyla yüksek hız ve gerçek zamanlı uygulamalar için daha çok tercih edilen tek aşamalı nesne tespit algoritmalarına odaklanılacaktır.

2.3.2.1. Single shot multibox detector (SSD)

SSD, gerçek zamanlı uygulamalar için geliştirilmiş, derin öğrenme tabanlı tek aşamalı bir nesne algılama modelidir [55]. Mimari, VGG-16 tabanlı bir omurga yapısı


kullanarak farklı çözünürlüklere sahip çoklu öznitelik haritalarından eş zamanlı çıkarım yapar. Her bir harita üzerinden çeşitli boyutlardaki nesneler için sınırlayıcı kutular (bounding boxes) üretilir; bu kutular üzerinde hem sınıf tahmini hem de konum regresyonu gerçekleştirilir. Toplamda 8732 adet tahmin üretilen modelde, çıkan kutular NMS algoritması ile elenerek nihai nesne tespiti elde edilir (Şekil 2.4). SSD, hızlı çalışması ve çoklu ölçekten bilgi alabilme yeteneği ile gömülü sistemlerde ve düşük gecikmeli uygulamalarda tercih edilmektedir.



Şekil 2.4. SSD modelinin genel mimarisi [55].


2.3.2.2. You only look once (YOLO)

YOLO, tek aşamalı nesne algılama gerçekleştiren, gerçek zamanlı ve derin öğrenme tabanlı bir model ailesidir [53]. Bu yaklaşım, görüntüyü bir ızgaraya bölerek her hücrenin belirli bir alandaki nesneleri algılamasından sorumlu olmasını sağlar. Her hücre, bir veya birden fazla sınırlayıcı kutu ve bunlara karşılık gelen sınıf olasılıklarını tahmin eder. Bu yapı sayesinde, çok sayıda nesne ve sınıf bilgisi tek aşamalı, hızlı bir işlemle elde edilebilmektedir. Şekil 2.5'te YOLO modelinin temel mimarisini oluşturan katmanlar görsel olarak sunulmaktadır.



Şekil 2.5. YOLO modelinin genel mimarisi [53].


Bu mimari, özellikle nesne tespitini tek bir aşamada gerçekleştirmesiyle bilinir. Farklı ölçeklerdeki öznitelik haritalarını işleyebilen mimarisiyle YOLO, büyük ve orta boyutlu nesnelerde yüksek başarı gösterirken, küçük nesnelerin tespitinde bazı sınırlılıklarla karşılaşabilir. Bu nedenle zaman içinde farklı sürümler geliştirilmiş; algılama doğruluğu, işlem hızı ve donanım uyumluluğu açısından çeşitli iyileştirmeler yapılmıştır. Şekil 2.6'da sırasıyla YOLO mimarisinin sürüm gelişimi özetlenmiştir.



Şekil 2.6. YOLO algoritmalarının gelişim süreci ve sürüm zaman çizelgesi [63].

2.3.2.3. YOLOv5


YOLOv5, Ultralytics tarafından geliştirilen ve YOLO mimarisini temel alan hafif, hızlı ve modüler bir nesne tespit modelidir [64, 65]. Özellikle düşük kaynak tüketimi ve kolay uygulanabilirliği sayesinde, gömülü sistemlerde yaygın olarak kullanılmaktadır. Giriş aşamasında veri artırma, ölçekleme ve adaptif anchor kutuları gibi işlemler içeren bu sürüm; omurga (backbone) kısmında Cross Stage Partial (CSP) ve focus modülleriyle işlem karmaşıklığını azaltırken, gradyan akışını iyileştirmektedir (Şekil 2.7). Boyun (neck) katmanında farklı çözünürlüklerdeki öznitelikler birleştirilerek, baş (head) kısmında sınıf ve konum tahmini gerçekleştirilir [61]. YOLOv5, bu çalışmada hızlı eğitim süreci, açık kaynak eklenti desteği ve esnek yapılandırılabilirliği nedeniyle tercih edilmiştir. Bu özellikleri geliştirme sürecine önemli ölçüde hız kazandırmış; modüler yapısı ise sistemin farklı alt görevlere kolayca entegre edilmesine imkân sağlamıştır. YOLOv5'in PyTorch tabanlı modüler yapısı, modelin farklı görevler için kolayca uyarlanmasına ve araştırmacılar tarafından geniş ölçekte optimize edilmesine olanak sağlamaktadır [66, 67].



Şekil 2.7. YOLOv5 modelinin genel mimarisi. Omurga, boyun ve baş katmanları ayrı bölümler halinde gösterilmektedir [33].

2.3.2.4. YOLOv8

YOLOv8, Ultralytics tarafından geliştirilen ve nesne tespiti yanında segmentasyon ve sınıflandırma gibi görevlerde yüksek doğruluk sunan bir modeldir [68]. Anchor-free yaklaşımı kullanarak sınırlayıcı kutuları doğrudan regresyon ile tahmin eder. Böylece eğitim süreci basitleşir ve özellikle küçük nesnelerde başarı artar. Bu sürümde, CSPDarknet yerine daha hafif ve optimize edilmiş özel bir omurga yapısı mimarisi kullanılmıştır. Ayrıca boyun ve baş yapıları ile çok ölçekli öznetelikleri birleştirerek daha kararlı ve isabetli tahminler üretir. YOLOv8, padding-aware decoding özelliği sayesinde, özellikle küçük nesnelerde köşe kayıplarını azaltarak tespit doğruluğunu artırmaktadır (Şekil 2.8). YOLOv8, bu tezde takip modülleriyle entegrasyon kolaylığı nedeniyle tercih edilmiştir. Çünkü bu sürüm, gelişmiş API yapısı, ONNX ve TensorRT gibi platformlara aktarılabilirliği ve özellikle gerçek zamanlı nesne takibi için optimize edilmiş mekanizmalarıyla öne çıkmaktadır. Geliştirilmiş çözünürlük uyumu ve donanım esnekliği sayesinde, sistemin izleme doğruluğu önemli ölçüde artırılmıştır.



Şekil 2.8. YOLOv8 modelinin genel mimarisi [69].


2.3.3. Transformer tabanlı yöntemler

Transformer tabanlı mimariler, kendi-kendine dikkat (self-attention) mekanizması sayesinde küresel bağımlılıkları modelleyebilme yeteneği ile CNN yaklaşımlarına alternatif oluşturmuştur. Geleneksel CNN, yerel özneliliklere odaklanan sabit boyutlu filtrelerle çalıştığından uzun menzilli bağıntıları sınırlı ölçüde modelleyebilir. Buna karşılık, Transformer mimarileri, her bir girdinin tüm diğer girdilerle olan ilişkisini doğrudan hesaba katarak daha kapsamlı ve bağlamsal temsiller elde edebilmektedir. Bu özellik, özellikle nesne tespiti, segmentasyon ve takip gibi görevlerde küresel bağlamanın kritik rol oynadığı durumlarda önemli avantajlar sunar.

2.3.3.1. Vision transformers (ViT)

ViT mimarisi, Dosovitskiy vd. [78] tarafından önerilen ve Transformer mimarisinin görüntü sınıflandırma görevlerinde etkili bir şekilde kullanılabileceğini ortaya koyan öncü bir çalışmadır. Geleneksel CNN mimarilerinin yerleşik ön kabulleri olan lokalite ve translyasyon değişmezliği yerine, ViT modeli, giriş görüntüsünü sabit boyutlu

yamalara ayırarak bu yamaları sıralı bir veri dizisi olarak işler (Şekil 2.9). Her bir yama (parça), doğrusal gömme işlemiyle bir vektöre dönüştürülür ve bu vektörlere pozisyon bilgisi eklenerek elde edilen temsil dizisi kodlayıcıya giriş olarak verilir. Şekil 2.9'un sağ kısmında, kodlayıcı katmanında yer alan çok başlı dikkat mekanizması ve katman içi işlemler şematik olarak gösterilmektedir. Bu yapı sayesinde ViT, görüntüdeki küresel bağlamı doğrudan modelleyerek sınıflandırma gibi görevlerde yüksek performans sergileyebilmektedir.




Şekil 2.9. ViT mimarisi ve kodlayıcı yapısı. Görüntü yamalarının doğrusal gömme, pozisyon kodlama ve dikkat mekanizması ile işlenmesi verilmiştir [78].

Ayrıca, bu yaklaşım, konvolüsyonel katmanlara ihtiyaç duymadan yalnızca dikkat mekanizmalarıyla etkili öznitelik çıkarımı yapılabileceğini göstermiştir. ViT, büyük veri setlerinde yüksek performans sunarken, küçük veri setlerinde aşırı öğrenmeye (overfitting) daha yatkındır.

2.3.3.2. Detection transformer (DETR)

DETR [57], transformer tabanlı kodlayıcı-çözücü mimarisi ile konvolüsyonel bir omurgayı birleştirerek uçtan uca nesne tespiti gerçekleştiren bir modeldir. DETR, geleneksel yöntemlerde yer alan anchor kutusu ve NMS gibi bileşenleri ortadan kaldırarak, nesne tespitini doğrudan bir küme tahmin problemi olarak formüle eder. Şekil 2.10'da gösterildiği üzere, model CNN ve dönüştürücü mimarisini birleştirerek nesne tespitlerini doğrudan ve paralel biçimde tahmin eder; eşleşmeyen çıktılar ise “nesne yok” sınıfına atanır. Öğrenilebilir sorgu vektörleri aracılığıyla sabit sayıda tahmin üretilir ve bu tahminler, gerçek nesnelerle bipartit (çift taraflı) eşleme yoluyla

ilişkilendirilir. Modelde, öznitelik haritası ResNet-50 gibi bir CNN ile çıkarılır ve encoder'a aktarılır. Sabit sayıda öğrenilebilir sorgu vektörü decoder'a iletilir; decoder her sorgu için bir sınıf ve sınırlayıcı kutu tahmini yapar. Eşleştirme, Hungarian algoritması ile gerçekleştirilir. DETR'nin başlıca sınırlamaları yavaş yakınsama ve küçük nesnelerde düşük tespit başarısıdır.



Şekil 2.10. DETR mimarisi [57]. Omurgadan elde edilen öznitelikler kodlayıcı-çözücü katmanında işlenerek sorgular üzerinden sınıf ve konum tahminleri yapılır.

2.3.3.3. Real-time detection transformer (RT-DETR)

RT-DETR, Zhang vd. [79] tarafından geliştirilen ve gerçek zamanlı nesne tespiti için optimize edilmiş uçtan uca bir transformer modelidir. Model, çok ölçekli öznitelikleri işleyen hibrit encoder yapısı ve belirsizliği azaltmaya yönelik sorgu seçimi algoritmasıyla öne çıkmaktadır. Geleneksel yöntemlerde yer alan NMS adımını tamamen ortadan kaldırarak, hız ve doğruluk açısından tutarlı sonuçlar üretir. Ayarlanabilir decoder katman sayısı sayesinde farklı uygulama senaryolarında hız–doğruluk dengesi sağlayabilmektedir. Bununla birlikte, RT-DETR hız kazanımı amacıyla bazı yapısal sadeleştirmeler içerdiğinden, özellikle karmaşık sahnelerde DETR kadar ayrıntılı bağlamsal temsiller elde edememektedir.

2.3.3.4. Roboflow detection transformer (RF-DETR)

RF-DETR, Roboflow tarafından geliştirilen ve DINOv2 tabanlı deformable-attention mekanizmasıyla çalışan Transformer tabanlı bir nesne tespit modelidir [80]. Model, nesne tespitini küresel bağlamı doğrudan dikkate alarak kategori ve konum eşleşmesi üzerinden gerçekleştirir ve böylece geleneksel yöntemlerde kullanılan NMS gibi ek işlemlere ihtiyaç duymaz. Örtüşen nesneler, karmaşık arka planlar ve sınıf belirsizliği içeren zorlu sahnelerde yüksek doğruluk sağlamasıyla öne çıkmaktadır. Deformable attention mekanizması sayesinde hesaplama yükünü azaltırken, mAP@50 gibi yaygın performans metriklerinde YOLO'nun güncel sürümleriyle rekabet edebilmektedir.

Literatürde, tek sınıflı senaryolarda yüksek mAP@50 değerlerine ulaştığı ve düşük epoch sayılarında bile hızlı yakınsama sağladığı rapor edilmiştir. Tablo 2.1’de, DETR, RT-DETR ve RF-DETR modelleri gerçek zamanlı çalışma yetenekleri, dikkat mekanizması tasarımları ve gömülü sistemlere uyumluluk açısından karşılaştırmalı biçimde sunulmuştur.

Tablo 2.1. DETR ve türevlerinin mimari özellik karşılaştırması


Özellik / Model	DETR	RF-DETR	RT-DETR
Gerçek zamanlı çalışma	X	X	✓
DINO / DINOv2 tabanlılık	X	✓	X
Belirsizliğe dayalı sorgu seçimi	X	X	✓
Çok ölçekli özellik işleme	X	✓	✓
Gömülü sistem uygunluğu	X	X	✓

2.4. Nesne Takibi ve Takip Algoritmaları

Nesne takibi, bir sahnede tespit edilen nesnelerin zaman içindeki konumlarının izlenmesi olarak tanımlanır. Bu alanda öncül yöntemler arasında Kalman filtresi, parçacık filtresi ve optik akış gibi klasik teknikler yer almaktadır. Bu yöntemler, özellikle durağan ya da düşük karmaşıklıkta sahnelerde başarılı sonuçlar verebilmektedir. Ancak çoklu nesne takibi (Multiple Object Tracking, MOT) gibi daha karmaşık görevlerde, bu klasik yöntemlerin yetersiz kaldığı ortaya konmuştur. Son yıllarda, derin öğrenmenin bilgisayarlı görme alanına entegrasyonu nesne takibi alanında önemli gelişmeler yaşanmıştır. Özellikle tespit-takip birleştirme yaklaşımı öne çıkmış; DeepSORT, FairMOT ve ByteTrack gibi algoritmalar bu yeni paradigmanın başarılı temsilcileri olarak geliştirilmiştir. Bu modeller, nesne algılama ağlarından elde edilen çıktılarla nesne kimliklerinin zaman içinde korunmasını sağlamaktadır. Örneğin, DeepSORT nesne kimliklerini korumak için görsel özellik vektörlerinden yararlanırken; FairMOT ise, tespit ve takip işlemlerini aynı ağ içinde eş zamanlı olarak gerçekleştirme yeteneğiyle öne çıkmaktadır. Bu bağlamda öne çıkan nesne takip algoritmaları aşağıda sunulmaktadır.

2.4.1. DeepSORT

DeepSORT, özellikle gerçek zamanlı video analizinde sıklıkla kullanılan gelişmiş çoklu nesne takip (MOT) algoritmalarından biridir. Algoritma, nesne tespitten elde edilen sınırlayıcı kutuların ve görsel özniteliklerin ardışık kareler boyunca tutarlı şekilde izlenmesini sağlar. Bu amaçla, CNN tabanlı görünüm öznitelikleri ile Kalman filtresi tabanlı konum tahminini birlikte kullanılır. Şekil 2.11’de gösterildiği üzere, algoritma ilk adım olarak her bir video karesi üzerinde nesnelerin tespitiyle başlar. Bu aşamada genellikle YOLO ailesi (YOLOv4, YOLOv5 gibi) veya Faster R-CNN gibi bir nesne tespit modeli kullanılır. Sonraki aşamada, tespit edilen nesnelere ait uzamsal konum bilgileri ile görünüm tabanlı öznitelikler kullanılarak izleme işlemi sürdürülür. DeepSORT, yalnızca konum bilgisine değil, aynı zamanda bir CNN aracılığıyla çıkarılan görünüm vektörlerine de dayanarak nesneler arasında daha isabetli eşlemeler gerçekleştirir. Bu yaklaşım, özellikle birbirine yakın ya da benzer hareket eden nesnelerin ayırt edilmesinde önemli bir avantaj sunar [82].



Şekil 2.11. DeepSORT modelinin genel mimarisi [82].


Takip mekanizmasının temelinde, her bir nesnenin gelecekteki konumunu tahmin eden Kalman filtresi bulunmaktadır. Eşleme işlemi, Mahalanobis mesafesi ile görünüm benzerliğinin birlikte değerlendirilmesiyle gerçekleştirilir. Bu sayede her bir tespit, en uygun geçmiş iz ile eşleştirilerek nesneye ait kimlik bilgisi korunmuş olur. DeepSORT’un temel avantajı, yalnızca geometrik konumlara dayalı takip yapan klasik SORT algoritmasına kıyasla daha yüksek doğruluk sağlaması ve kimlik geçişlerini önemli ölçüde azaltmasıdır. Bu yönüyle, kalabalık veya karmaşık sahnelerdeki nesne takibi görevleri için etkili bir çözüm sunmaktadır [83].

2.4.2. Multiple object tracking (MOT)

Bilgisayarlı görme alanında, video sekanslarındaki birden fazla nesnenin hareketini izlemek amacıyla geliştirilen algoritmalar, MOT kapsamında değerlendirilmektedir [71]. MOT'un temel amacı, bir videonun ardışık karelerinde tespit edilen nesneleri doğru biçimde eşleştirerek zaman içerisindeki hareket izlerini çıkarmaktır. Bu görev, gözetim sistemleri, otonom araçlar ve insan-bilgisayar etkileşimi gibi birçok uygulama alanında kritik bir rol oynamaktadır. MOT yöntemlerinde temel zorluklar arasında kimlik tutarlılığının korunması, örtüşen nesnelerin ayrıştırılması, ani hareket değişimlerine uyum sağlanması ve uzun süreli takibin sürdürülebilirliği yer almaktadır. Günümüzde MOT için klasik izleme temelli yaklaşımların yanı sıra, derin öğrenme tabanlı takip yöntemleri de yaygın olarak kullanılmaktadır.

2.4.3. FairMOT

FairMOT modeli, MOT alanında nesne tespiti ve yeniden tanıma (Re-Identification, Re-ID) görevlerini tek bir birleşik mimari içinde gerçekleştiren derin öğrenme tabanlı bir yapıdır [70]. Geleneksel yaklaşımlarda bu işlemler genellikle ayrı modüllerle yürütülürken, FairMOT her iki görevi dengeli şekilde bütünleştirerek daha verimli ve tutarlı bir çözüm sunar. Model, CenterNet tabanlı bir merkez nokta temsili kullanarak nesneleri, sınırlayıcı kutular yerine merkez koordinatları üzerinden tanımlar [72]. Bu yaklaşım, özellikle birbirine yakın ya da örtüşen nesnelerin daha güvenilir şekilde tespit edilmesini sağlar (Şekil 2.12).



Şekil 2.12. FairMOT modelinin genel mimarisi. Kodlayıcı-çözücü ağı öznetelikleri çıkarır, ardından nesne tespiti yapar, Re-ID ile kimlik bilgileri korur [70].

Modelin kodlayıcı-çözücü ağ mimarisi, hem tespit hem de Re-ID işlemlerini eş zamanlı olarak yürütebilmektedir. Çıkış katmanlarında tespit görevine yönelik olarak ısı haritası, kutu boyutu ve merkez ofseti tahmin edilirken; Re-ID aşamasında her nesne için ayırt edici, sabit boyutlu gömme vektörleri üretilmektedir. Bu yapı, tespit sırasında elde edilen özniteliklerin doğrudan Re-ID modülünde de kullanılmasına olanak tanıyarak hesaplama verimliliğini artırmakta; ayrıca kimlik ayrımı açısından güçlü bir görsel temsil sunmaktadır [73]. FairMOT, tespit ve yeniden tanıma görevlerini aynı omurga yapısı üzerinde ortak özellik haritalarıyla öğrenerek Re-ID özniteliklerinin güncel tespitlerle uyumlu olmasını sağlamaktadır.

2.4.4. ByteTrack

ByteTrack, birden fazla nesnenin takibi için geliştirilmiş yenilikçi bir bilgisayarlı görme modelidir [74]. Model, bir videodaki benzersiz nesnelere kimlikler atayarak bunların zaman içinde izlenmesini mümkün kılar. Şekil 2.13’de ByteTrack algoritmasının pseudo kodu verilmiştir.

Algorithm 1: BYTE (ByteTrack) sözde kodu

Girdi: Video dizisi V ; nesne algılayıcı Det; skor eşiği τ
Çıktı: Videonun izler kümesi $\mathcal{T}$

```

 $\mathcal{T} \leftarrow \emptyset$  // Başlangıçta iz kümesi boş
foreach  $f \in V$  do // Her kare için döngü
     $\mathcal{D} \leftarrow \text{Det}(f)$  // Algılamaları (kutuları) al
     $\mathcal{D}_{high} \leftarrow \emptyset, \mathcal{D}_{low} \leftarrow \emptyset$  // Yüksek ve düşük skor kümelerini hazırla
    foreach  $d \in \mathcal{D}$  do // Her algılama için
        if  $d.score > \tau$  then
             $\mathcal{D}_{high} \leftarrow \mathcal{D}_{high} \cup \{d\}$  // Yüksek skor kümesine ekle
        else
             $\mathcal{D}_{low} \leftarrow \mathcal{D}_{low} \cup \{d\}$  // Düşük skor kümesine ekle

    foreach  $t \in \mathcal{T}$  do
         $t \leftarrow \text{KalmanFilter.Predict}(t)$  // İzlerin yeni konumlarını öngör
         $(match_1, \mathcal{T}_{rem}, \mathcal{D}_{high}^{rem}) \leftarrow \text{ASSOCIATE}(\mathcal{T}, \mathcal{D}_{high}, \text{Similarity}\#1)$ 

    // 1. eşleştirme (yüksek skorlar)
     $(match_2, \mathcal{T}_{still}, \mathcal{D}_{low}^{rem}) \leftarrow \text{ASSOCIATE}(\mathcal{T}_{rem}, \mathcal{D}_{low}, \text{Similarity}\#2)$ 

    // 2. eşleştirme (düşük skorlar)
     $\mathcal{T} \leftarrow \mathcal{T} \setminus \mathcal{T}_{still}$  // Eşleşmeyen izleri sil

    foreach  $(t, d) \in match_1 \cup match_2$  do
         $t \leftarrow \text{KalmanFilter.Update}(t, d)$  // Eşleşen izleri güncelle

    foreach  $d \in \mathcal{D}_{high}^{rem}$  do
         $\mathcal{T} \leftarrow \mathcal{T} \cup \{\text{INIT\_TRACK}(d)\}$  // Yeni iz başlat

return  $\mathcal{T}$  // Sonuçta tüm izleri döndür

```

Şekil 2.13. ByteTrack algoritmasının pseudo kod gösterimi [74].

ByteTrack algoritmasının temel mantığı, neredeyse tüm tespit kutularını koruması ve bunları yüksek puanlı ve düşük puanlı olarak ayırmasıdır. İlk aşamada, yüksek puanlı tespit kutuları mevcut izlerle ilişkilendirilir. Algoritma, her bir video karesindeki nesne tespitlerini elde eder ve bu tespitleri güven skoruna göre yüksek ve düşük olmak üzere iki gruba ayırır. Bu doğrultuda, Kalman filtresi ile mevcut izlerin konumları güncellenir ve yüksek skorlu tespitlerle mevcut izler arasında benzerliğe dayalı bir eşleme gerçekleştirilir. İlk eşlemede ilişkilendirilemeyen izlerle düşük skorlu tespitler, ikinci bir eşleme adımında karşılaştırılır. Son aşamada, eşleştirilemeyen izler silinirken; eşleşmemiş yüksek skorlu tespitler yeni izler olarak takibe alınır. Bu çift aşamalı eşleme yapısı sayesinde ByteTrack, düşük skorlu tespitleri de değerlendirme kapsamına alarak kaçırılan nesnelerin geri kazanılmasını sağlar ve genel takip performansını artırır.

2.4.5. StrongSORT

StrongSORT, klasik DeepSORT algoritmasının sınırlarını aşmak amacıyla geliştirilmiş bir versiyondur. Bu model, güçlü bir nesne tespit ve gelişmiş bir yeniden tanımlama (Re-ID) modülü ile entegre çalışarak hem tespit hem de takip doğruluğunu artırmaktadır. Algoritmanın öne çıkan katkılarından biri, eksik tespitler ve iz kayıplarını azaltmak için iki yardımcı bileşen eklemesidir: Gaussian-smoothed Interpolation ve Appearance-Free Link. Gaussian-smoothed Interpolation, nesnenin tespit edilemediği karelerde konum bilgisini Gaussian süreç regresyonu ile tahmin ederek boşlukları doldurur. Appearance-Free Link ise, yalnızca mekânsal ve zamansal bilgilerden yararlanarak kısa iz parçalarını küresel düzeyde ilişkilendirir. Bu iki yapı modele yalnızca küçük bir ek işlem yükü getirmesine rağmen, izleme performansına anlamlı katkılar sağlamaktadır. StrongSORT'un en önemli avantajları arasında yüksek kimlik koruma başarımı, eksik tespitlere karşı tolerans ve daha hassas konum tahmini yer almaktadır. Ancak, Re-ID tabanlı ek modüller nedeniyle klasik yöntemlere kıyasla daha fazla hesaplama kaynağı gerektirmektedir [75].


2.4.6. BoT-SORT

BoT-SORT, track-by-detection yaklaşımına dayalı olarak geliştirilmiş güçlü bir çoklu nesne takip algoritmasıdır. Model, hareket tabanlı eşleştirme ile görsel özniteliklere dayalı Re-ID bilgilerini bir araya getirerek kimlik koruma başarımını artırır ve ID switch oranlarını azaltır. Algoritmanın en önemli yeniliklerinden biri, kamera hareket

telafisi (camera motion compensation) modülüdür. Bu modül, özellikle hareketli kamera senaryolarında tespit ve tahmin arasındaki konumsal farklılıkları telafi ederek izleme sürecinin kararlılığını yükseltmektedir. Ayrıca Kalman filtresine dayalı durum tahmin sürecinde yapılan iyileştirmeler, sınırlayıcı kutu boyutlarının daha isabetli güncellenmesine imkân tanımaktadır. BoT-SORT, MOTA ve IDF1 metriklerinde yüksek performans sunmakta, Re-ID destekli uzun süreli kimlik takibi sağlayabilmektedir. Bununla birlikte, Re-ID modülüne olan yüksek bağımlılık, karmaşık sahnelerde benzer görünümlü nesnelerin karışmasına yol açabilmekte ve işlem yükünü artırabilmektedir [76].

2.4.7. OC-SORT

OC-SORT, klasik SORT algoritmasının sınırlarını aşmak amacıyla geliştirilmiş gözlem merkezli (observation-centric) çoklu nesne takip yöntemidir. Klasik SORT, yalnızca Kalman filtresine dayalı konum tahmini gerçekleştirdiği için nesnelerin uzun süre gizlenmesi veya doğrusal olmayan hareketlerde hata birikimiyle karşılaşabilmektedir. Bu sorunu aşmak için OC-SORT, Observation-Centric Re-Update (ORU) mekanizmasını önermektedir. Şekil 2.14, OC-SORT algoritmasının tespitlerden iz güncellemelerine uzanan işlem hattını göstermektedir.



Şekil 2.14. OC-SORT algoritmasının işlem hattı (pipeline) gösterimi [77].


ORU mekanizması sayesinde, nesne yeniden tespit edildiğinde geçmiş iz kayıpları geriye dönük olarak düzeltilmekte ve takip doğruluğu artırılmaktadır. Ayrıca yön tutarlılığına (directional consistency) dayalı eşleme stratejisi ile yanlış ilişkilendirmeler önemli ölçüde azaltılmaktadır. Böylece OC-SORT, özellikle yoğun sahnelerde, doğrusal olmayan hareketlerin ve uzun süreli kaybolmaların bulunduğu durumlarda daha kararlı bir takip performansı sunmaktadır [77].

3. GELİŞTİRİLEN OTONOM KONTROLLÜ ROBOTİK KIYI ŞARJ SİSTEMİ

Bu bölümde, elektrikli gemilerin daha hızlı, hassas ve güvenli biçimde şarj edilmesini sağlamak amacıyla geliştirilen, otonom kontrollü robotik kıyı şarj sistemine ait donanım ve yazılım bileşenleri sunulmaktadır. Çalışmanın saha uygulamaları, TÜBİTAK TEYDEB destekli REGES (Robotik Elektrikli Gemi Batarya Besleme Sistemi) projesi kapsamında, ELKON firması ile iş birliği içinde yürütülmüştür. Bu kapsamda sistemin mekanik yapısı, robotik platformu ve PLC tabanlı kontrol altyapısı ELKON Ar-Ge laboratuvarında geliştirilmiş ve başarıyla test edilmiştir. Tez çalışması kapsamında, daha çok sistemin yazılım tarafına odaklanılmış; özellikle yapay zekâ ve bilgisayarlı görme tabanlı otonom kontrol algoritmalarının geliştirilmesi, görüntü işleme destekli konumlandırma ve bu algoritmaların gömülü sistem üzerinde çalıştırılarak PLC ile gerçek zamanlı haberleşme yoluyla hareket komutlarının iletilmesi sağlanmıştır. Geliştirilen kontrol algoritmalarının donanımla bütünleşik şekilde çalışmasıyla sistem, gerçek zamanlı karar verme ve tahrik yeteneği kazanmıştır.

Donanım yapısı, geliştirilen yazılımın sahada uygulanabilirliğini test etmek amacıyla genel hatlarıyla sunulmakta; ancak bu tez kapsamındaki özgün akademik katkı, yapay zekâ ve görüntü işleme temelli yazılım modüllerine odaklanmaktadır. Bu modüller, özellikle gerçek zamanlı nesne tespiti, soket hizalama ve otonom kontrolün güvenilirliğini artıracak biçimde geliştirilmiş ve sistemin yenilikçi yönünü ortaya koymuştur. Şekil 3.1’de geliştirilen otonom kontrollü kıyı şarj sistemi ile gemi bataryası arasındaki enerji aktarım süreci şematik olarak gösterilmektedir. Sistemin genel mimarisi; sabit bir kıyı robotik şarj istasyonu, gemi üzerindeki dişi soket ve bu iki birim arasındaki enerji aktarım hattı üzerinden şekillenmektedir. Şarj süreci, görüntü işleme destekli konumlandırma ile başlamakta ve soketin tespitinin ardından lazer sensörlerle hizalanarak otomatik enerji transferi sağlanmaktadır. Şarjın tamamlanmasıyla birlikte sistem, işlemi güvenli biçimde sonlandırmakta; böylece süreç, insan müdahalesi olmaksızın gerçekleşmektedir. Bu süreçte hem donanımsal altyapı hem de yazılım tabanlı kontrol mekanizmaları eş zamanlı olarak çalışmaktadır.

Kıyı Robotik Şarj İstasyonu




Şekil 3.1. Geliştirilen otonom kontrollü robotik kıyı şarj sistemi ile gemi bataryası arasındaki enerji aktarım süreci.

3.1. Donanım Altyapısı

Robotik şarj istasyonu, üç eksenle hareket edebilen mekanik bir yapıya sahiptir. Bu yapı, PLC kontrollü tahrik mekanizması, Jetson Nano tabanlı görüntü işleme modülü, kamera ve çeşitli sensörlerin entegre çalışmasıyla oluşturulmuştur. Fiziksel altyapı, sabit bir kıyı istasyonu üzerine entegre edilen kontrol, hareket ve algılama birimlerinden oluşmaktadır. Şekil 3.2’de sistemin donanımsal bileşenleri ve veri akışları şematik olarak sunulmuştur. Şarj süreci; gemi üzerindeki dişi soketin görüntü işleme algoritmalarıyla tespit edilmesi ve ardından PLC-Modbus protokolü aracılığıyla hareketli erkek soketin yaklaşık 60 cm mesafeye kadar hassas şekilde hizalanmasıyla başlatılmaktadır. Bu noktadan sonra enerji aktarımı otomatik olarak devreye girmekte olup, erkek soket üç eksenle konumlandırılabilir şekilde tasarlanmıştır. Ayrıca Snap7 kütüphanesi kullanılarak PLC ile doğrudan bellek tabanlı iletişim sağlanmış, Modbus tabanlı haberleşmeye ek olarak daha esnek ve güvenilir bir kontrol imkânı oluşturulmuştur. Yatay (sol-sağ) ve düşey (aşağı-yukarı) eksenlerdeki hareketler sırasıyla iki ayrı motor ile sağlanırken; iç-dış (ileri-geri) yöndeki hareketler ise lineer bir aktüatör aracılığıyla gerçekleştirilmektedir. Her iki motor, 380V AC gerilimle çalışan sürücüler tarafından kontrol edilmektedir. Sistemin genel güç beslemesi üç fazlı bir hat üzerinden sağlanmakta olup, kontrol bileşenleri

için pano içerisinde 220V AC ve 24V DC gerilim seviyeleri elde edilmekte; bu sayede sürücüler, Jetson Nano, RGB kamera, sensörler ve diğer yardımcı birimler uygun şekilde enerjilendirilmektedir.



Şekil 3.2. PLC tabanlı kontrol ve tahrik sistemi blok diyagramı.

3.1.1. PLC tabanlı kontrol altyapısı

Sistemin kontrol altyapısı, Siemens SIMATIC S7-1200 model bir PLC kullanılarak oluşturulmuştur. PLC yazılımı, hem manuel hem de otomatik çalışma modlarını destekleyecek şekilde yapılandırılmıştır. Manuel modda, kontrol panelinde yer alan yön butonları aracılığıyla erkek soket manuel olarak farklı yönlerde hareket ettirilebilmektedir. Ayrıca referans butonu yardımıyla sistem, önceden tanımlanmış başlangıç konumuna otomatik olarak dönebilmektedir. Otomatik modda ise, Jetson Nano platformu üzerinde çalışan görüntü işleme algoritmaları ile elde edilen konum bilgileri Ethernet Switch üzerinden PLC'ye iletilmekte ve erkek soket, bu verilere göre hedefe yönlendirilmektedir.

PLC'nin dijital giriş-çıkış portları üzerinden sürücüler, sınır anahtarları, lineer aktüatör, konum sensörleri ve kontrol paneli bileşenleri kontrol edilmektedir. Özellikle sınır anahtarları, motor hareketlerinin önceden tanımlı fiziksel limitler içinde güvenli biçimde gerçekleştirilmesini sağlamaktadır.

3.1.2 Algılama ve görüntü işleme donanımı

Gemi üzerindeki dişi socketin konumunun tespiti için, şarj istasyonu üzerine bir RGB kamera yerleştirilmiştir. Kamera ile yakalanan görüntüler, derin öğrenme tabanlı nesne tespit algoritmalarının çalıştırıldığı NVIDIA Jetson Nano platformuna aktarılmaktadır. Jetson Nano, düşük güç tüketimli bir gömülü bilgisayar olup, bu çalışmada nesne tespiti, konum hesaplama ve karar üretme gibi görevleri gerçek zamanlı olarak yürüten merkezî birim olarak kullanılmıştır. Üzerinde çalışan YOLO ve DETR tabanlı nesne tespit mimarileri aracılığıyla, kamera görüntülerinden dişi socketin konumu tespit edilmekte ve bu konum bilgisi Ethernet üzerinden Modbus protokolü ile PLC'ye iletilmektedir. PLC, bu referans veriye dayanarak erkek socketi hedefe yönlendirmektedir. Kameraya ek olarak, erkek socket üzerine entegre edilmiş lazer tabanlı mesafe sensörleri kullanılmaktadır. Bu sensörler, socketler arasındaki mesafeyi milimetrik hassasiyetle ölçerek PLC'ye bildirmekte ve son konumlandırma aşamasında sistemin güvenli hizalama gerçekleştirmesini sağlamaktadır. Elde edilen bu bilgiler doğrultusunda motorlar ve lineer aktüatör çalıştırılarak erkek socket, gemi üzerindeki dişi socketle hassas şekilde hizalanmakta; böylece ileri-geri yönlü konumlandırma gerçekleştirilerek güvenli enerji aktarımı için gerekli fiziksel temas ve mekanik kenetlenme (docking) işlemi sağlanmaktadır.

Donanım altyapısı, sistemin çevresel algılama, nesne tespiti, konuma dayalı karar alma ve otonom kenetlenme işlemlerinin fiziksel temelini oluşturmaktadır. Bu yapı üzerine entegre edilen görüntü işleme donanımı ve yazılım modülleri sayesinde sistem, tam otonom bir şekilde çalışacak biçimde yapılandırılmıştır.


3.2. Yazılım Altyapısı

Yazılım bileşenleri; nesne tespiti, konum çıkarımı, mesafe ölçümü ve hareket planlamasını içeren çok aşamalı bir kontrol sürecinden oluşmaktadır. Sistem, RGB kameradan elde edilen görüntüleri Jetson Nano üzerinde çalışan algoritmalar aracılığıyla işleyerek gemi üzerindeki dişi socketin konumunu belirlemektedir. Elde edilen bu konum bilgisi, PLC'ye iletilmekte ve hareket sistemi bu verilere göre tetiklenmektedir. Bu çalışmada, bilgisayarlı görme tabanlı otonom kontrol algoritmaları geliştirilmiş ve sistemin çevresel algılamadan karar üretimine, hareket komutu oluşturmada fiziksel uygulamaya kadar tüm süreci kendi başına yürütebilmesi sağlanmıştır. Yazılım akışı; görüntüden bilgi çıkarımı, konum tespiti,

PLC'ye komut iletimi ve otomatik fiziksel kenetlenme işlemi gibi adımları bir döngü halinde yürüterek sistemin tam otonom çalışmasına olanak tanımaktadır. Bu süreçte örnek akış diyagramlarında YOLOv5 modeli kullanılmıştır; ancak aynı yazılım mimarisi, HSV tabanlı yöntemler, YOLO'nun farklı sürümleri ile transformer tabanlı DETR ve türevleri gibi çeşitli nesne tespit modellerine de uygulanmış, böylece sistemin esnekliği korunmuştur.

3.2.1 Görüntüden karara: yazılım iş akışı


Yazılım süreci, kameranın çevresel görüntü yakalamasıyla başlamakta, ardından görüntü işleme algoritmaları yardımıyla dişi socketin konumu tespit edilmektedir. Tespit başarısız olduğunda sistem yeni bir görüntü yakalayarak döngüyü tekrar etmektedir. Konum tespiti başarılı olduğunda, pozisyon bilgisi PLC'ye iletilmekte; PLC ise bu bilgiyi kullanarak motorları ve aktüatörü çalıştırmakta ve erkek socketi hedef konuma yönlendirmektedir. Sonrasında, lazer sensörler devreye girerek socketler arasındaki mesafeyi kontrol etmekte ve hizalamanın doğruluğunu sağlamaktadır. Bağlantı kurulduğunda enerji aktarımı başlatılmakta; şarj işlemi süresince sistem durumu izlemekte ve işlem tamamlandığında bağlantıyı otomatik olarak kesmektedir. Bu süreç, Şekil 3.3'te akış diyagramı ile gösterilmiştir.



Şekil 3.3. Şarj sürecine ait görüntü işleme ve PLC tabanlı akış diyagramı.

3.2.2. Nesne tespiti ve konum bilgisi üretimi

Geliştirilen elektrikli gemi şarj sisteminde, gemi üzerindeki dişi soketin doğru ve gerçek zamanlı konumunun tespiti büyük önem taşımaktadır. Bu amaçla, bilgisayarlı görme temelli bir nesne tespit yaklaşımı benimsenmiş ve derin öğrenme tabanlı bir YOLOv5 modeli kullanılarak yüksek doğrulukta konum bilgisi elde edilmiştir. Nesne tespit süreci eğitim ve tespit olmak üzere iki temel aşamadan oluşmaktadır. Şekil 3.4'te, nesne tespiti sürecine ait eğitim ve tespit aşamalarını içeren iş akışı akış diyagramı biçiminde sunulmaktadır. Sol bölümünde modelin eğitim süreci ve sağ bölümünde ise sistemin gerçek zamanlı tespit aşamasındaki veri işleme adımları gösterilmektedir (Şekil 3.4).



Şekil 3.4. YOLO tabanlı olarak geliştirilen soket tespit modelinin eğitim ve tespit aşamalarına ait akış diyagramı.

Eğitim aşamasında, soket nesnesine ait etiketli görseller çeşitli ön işleme ve boyutlandırma işlemlerinden geçirilerek modele giriş olarak sunulur. Her bir görüntü için, anchor (çapa) kutularına karşılık gelen konum tahmin değerleri $(t_x, t_y, t_w, t_h, t_o)$ hesaplanmakta ve bu değerler üzerinden tahmin edilen sınırlayıcı kutular $(b_x, b_y, b_w, b_h, p_c)$ oluşturulmaktadır. Tahmin edilen bu kutular, görüntülere ait gerçek konum etiketleri ile karşılaştırılmakta ve kayıp fonksiyonu kullanılarak hata miktarı belirlenmektedir. Geri yayılım algoritması ile modelin ağırlıkları güncellenmekte ve bu işlem belirlenen epoch sayısına ulaşınca kadar tekrarlanmaktadır.

Modelin eğitimi tamamlandıktan sonra, sistem gerçek zamanlı tespit sürecine geçmektedir. Bu aşamada, gömülü sistemde bulunan kamera aracılığıyla alınan görüntüler eğitilmiş YOLOv5 modeline aktarılmaktadır. Model, her bir çapa kutusu için konum tahminleri üretir; ardından bu çıktılar, NMS gibi filtreleme yöntemleriyle işlenerek gereksiz veya çakışan kutular elenirler. Böylece, en güvenilir tespit sonucu elde edilmektedir. Tespit edilen dişi soket konumu, Jetson Nano gömülü sisteminden PLC'ye iletilmektedir. PLC, bu bilgiye dayanarak erkek soketi hedef konuma yönlendirmekte ve üç eksenle hareket ettirilen bu soket, lazer sensörlerle yapılan hassas konum kontrolü sonucunda gemi üzerindeki dişi soketle hizalanmaktadır. Bağlantı tamamlandığında enerji aktarımı başlatılmakta, şarj süreci boyunca bağlantı durumu sistem tarafından izlenmektedir. Şarj işlemi sona erdiğinde ise sistem, bağlantıyı güvenli şekilde sonlandırmaktadır.


3.2.3. YOLO modelinde sınırlayıcı kutu tahminleri ve konum hesaplaması

YOLO mimarisinde sınırlayıcı kutuların tahmini, çapa kutularına göre yapılan parametre dönüşümleriyle gerçekleştirilmektedir. Model, her bir grid hücresine karşılık gelen çapa kutusu için (t_x, t_y, t_w, t_h) gibi parametrik çıktılar üretir. Bu parametreler, sırasıyla sınırlayıcı kutunun x ve y koordinatları ile genişlik ve yüksekliğini ifade eden tahmin değerleridir. Bu değerler, Denk. 3.1 ve Denk. 3.2'deki dönüşümler ile fiziksel koordinatlara dönüştürülmektedir.

$$bx = \sigma(t_x) + c_x \quad | \quad by = \sigma(t_y) + c_y \quad (3.1)$$

$$b_w = p_w e^{t_w} \quad | \quad b_h = p_h e^{t_h} \quad (3.2)$$

Burada σ sigmoid fonksiyonunu; c_x, c_y grid hücresinin sol üst köşesinin koordinatlarını; p_w, p_h ise anchor kutunun genişlik ve yüksekliğini ifade etmektedir. Bu dönüşüm sonucunda, model tarafından tahmin edilen sınırlayıcı kutu, görüntü üzerinde mutlak konum bilgisine sahip hale gelmektedir. Şekil 3.5'te bu hesaplamaların şematik gösterimi sunulmuştur. Kırmızı kutu, model tarafından tahmin edilen sınırlayıcı kutuyu temsil ederken; siyah kesikli çizgilerle gösterilen kutu ise zemin gerçeği kutusunu ifade etmektedir. Bu yapı sayesinde, eğitim sırasında tahmin ile zemin gerçeği arasındaki fark minimize edilerek doğruluk artırılmaktadır.



Şekil 3.5. YOLO modelinde tahmin edilen sınırlayıcı kutunun hesaplanması.

3.2.4. PLC ile haberleşme ve hareket komutu oluşturma


Jetson Nano tarafından üretilen konum bilgisi, Ethernet üzerinden Modbus protokolü aracılığıyla PLC'ye aktarılmaktadır. PLC, gelen referans veriye göre motorlar ve lineer aktüatör için gerekli hareket komutlarını üretmektedir. Yatay ve düşey yönlerdeki hareketler motor-1 ve motor-2 ile, ileri-geri hareket ise lineer aktüatör ile sağlanmaktadır. Her eksenindeki hareket sınırları sınır anahtarları ile tanımlanarak güvenli çalışma sağlanmaktadır. Hareket başladıktan sonra, lazer mesafe sensörlerinden alınan verilerle soketler arası mesafe doğrulanmakta ve PLC bu bilgiye göre son hizalamayı yapmaktadır. Bağlantı sağlandığında enerji aktarımı otomatik olarak başlatılmakta, şarj süresi boyunca sistem izlenmekte ve işlem tamamlandığında bağlantı yine otomatik olarak sonlandırılmaktadır. Bu yapı, sistemin “algıla, karar ver, hareket et, hizala ve aktar” döngüsü içinde otonom şekilde çalışmasını sağlamaktadır. Jetson Nano ve PLC arasındaki çift yönlü haberleşme, sistemin gerçek zamanlı ve senkronize bir şekilde işleyişini mümkün kılmaktadır.

3.3. Özgün Veri Seti ve Performans Metrikleri

Bu çalışmada, elektrikli gemilere ait şarj soketlerinin görüntü tabanlı tespiti ve limana yaklaşan gemilerin takibi amacıyla derin öğrenme tabanlı modeller geliştirilmiştir. Bu kapsamda iki farklı görüntü tabanlı veri seti kullanılmıştır: İlki, bu çalışmaya özgü olarak oluşturulan şarj soketi görüntülerinden oluşan özel veri seti; ikincisi ise çoklu nesne takip algoritmalarının performans değerlendirmelerinde yaygın biçimde kullanılan açık kaynaklı SMD veri setidir.

3.3.1. Özgün elektrikli gemi şarj soketi veri seti

Bu çalışmada geliştirilen bilgisayarlı görme temelli şarj soketi tespit sistemi, elektrikli gemi üzerindeki dişi şarj soketinin konumunu doğru biçimde belirlemek üzere eğitilmiştir. Bu amaçla, yalnızca bu çalışmaya özgü olarak oluşturulmuş özgün bir veri seti kullanılmıştır. Görüntüler RGB kamera ile kaydedilmiş; veri çeşitliliği sağlamak için farklı açı, aydınlatma, parlaklık, gölge ve perspektif koşulları dikkate alınmıştır. Soket nesnesi çeşitli açılardan görüntülenmiş olup, kullanılan şarj soketlerinin fiziksel yapısı Şekil 3.6’da gösterilmektedir. Burada, şarj istasyonuna entegre edilen ve robotik mekanizma tarafından hareket ettirilen erkek soket ile elektrikli gemi üzerine sabitlenmiş dişi soket gösterilmiştir. Her iki yapı, görsel tanıma sürecinde etiketlenen nesneler olarak model eğitiminde kullanılmıştır. Örnek veri seti görüntülerine Şekil 3.7’de yer verilmekte, veri çeşitliliğinin ortam ve ışık koşullarına göre dağılımı ise Şekil 3.8’de nicel olarak sunulmaktadır.




Şekil 3.6. Robotik şarj sistemine ait erkek ve dişi soket arayüzleri (sol: erkek soket, sağ: dişi soket).



Şekil 3.7. Çeşitli açılardan ve ışık koşullarında çekilmiş şarj soketi görüntüleri.

Modelin eğitime geçilmeden önce, görüntüler üzerinde çeşitli ön işleme adımları uygulanmıştır. İlk olarak, cihaz tarafından farklı açılarda kaydedilmiş olma ihtimaline karşı otomatik yön düzeltme (auto-orient) işlemi gerçekleştirilmiş ve böylece veri setindeki görsellerin oryantasyon tutarlılığı sağlanmıştır.



Şekil 3.8. Veri setindeki görüntülerin ortam ve ışık koşullarına göre sayısal dağılımı.


Bu adımdan sonra, tüm görüntüler derin öğrenme tabanlı nesne tespit modellerinin gerektirdiği sabit giriş boyutuna uyumlu olacak şekilde 640×640 piksel çözünürlüğe yeniden ölçeklendirilmiştir. Bu iki temel adım sayesinde modelin öğrenme verimliliği artmış ve giriş standardizasyonu sağlanmıştır. İşleme tabi tutulmuş görüntülere ait

örnekler Şekil 3.9’da gösterilmektedir. Ayrıca, modelin genelleme kabiliyetini artırmak ve sınırlı veri ortamında aşırı uyum (overfitting) riskini azaltmak amacıyla veri setine kontrollü düzeyde veri artırma teknikleri uygulanmıştır.



Şekil 3.9. Veri artırma uygulamaları: orijinal ve dönüştürülmüş görüntüler.

Özellikle yatay (horizontal flip) ve dikey (vertical flip) dönüşümler uygulanarak modelin farklı açılardan gelen varyantlara karşı duyarlılığı artırılmıştır. Şekil 3.10’da, bu teknikler sonucu elde edilen görüntü dönüşümleri gösterilmekte olup, kırmızı kutular elenen yanlış tespitleri, yeşil kutu ise doğru tespiti ifade etmektedir.



Şekil 3.10. Veri artırma örnekleri: (a) orijinal, (b) dikey çevirme, (c) yatay çevirme.

Veri setinin aydınlatma, konum ve çevresel koşullar açısından dengeli bir dağılıma sahip olması, modelin gerçek durum (real-case) uygulamalarında daha kararlı sonuçlar üretmesini sağlamaktadır. Etiketleme süreci, etkileşimli ve açık kaynaklı bir platform olan ‘makesense.ai’ kullanılarak gerçekleştirilmiştir. Her bir görüntüdeki şarj soketi, dikkörtgensel sınırlayıcı kutular ile işaretlenmiş ve YOLO formatına uygun olarak [sınıf, x_{merkez} , y_{merkez} , genişlik, yükseklik] biçiminde normalize edilerek ‘txt’ uzantılı dosyalarına kaydedilmiştir. Son aşamada, özgün veri seti toplamda 4000 görüntüden oluşturulmuş; bu verilerin %70’i eğitim (train), %15’i doğrulama (validation) ve %15’i test amacıyla ayrıştırılmıştır. Böylece geliştirilen modelin öğrenme, doğrulama ve değerlendirme süreçleri dengeli biçimde yapılandırılmıştır.

3.3.2. Singapore maritime dataset (SMD)

SMD, çoklu nesne takibi (MOT) uygulamaları için yaygın olarak kullanılan açık erişimli bir denizcilik veri setidir [81]. Veri setinde, insansız deniz araçları (Unmanned Surface Vehicles, USV), gemi takip sistemleri ve otonom navigasyon algoritmaları gibi bilgisayarlı görme tabanlı denizcilik uygulamalarını destekleyecek şekilde hazırlanmış yüksek çözünürlüklü görüntüler yer almaktadır. Bu görüntüler, sabit ve hareketli kameralarla farklı hava koşulları ve günün çeşitli saatlerinde kaydedilmiş sahneleri içermektedir (Şekil 3.11). Her sahnede birden fazla deniz aracına ait sınıf etiketi ve konum bilgisi yer almakta olup, görüntüler çoklu nesne tespit ve takip algoritmalarının eğitimi ve değerlendirilmesine uygun şekilde etiketlenmiştir.



Şekil 3.11. SMD veri setinden farklı gemi türlerini içeren örnek sahneler.

Bu tezde, limana yaklaşan gemi senaryolarında takip algoritmalarının performansını incelemek için SMD veri seti kullanılmıştır. Veri setinde mavna, kargo gemisi, sürat teknesi, yelkenli, römorkör ve şamandıra gibi deniz taşıtları sınırlayıcı kutularla etiketlenmiştir. Ardışık karelerden oluşan sahneler üzerinden, takip algoritmalarının ID tutarlılığı, izleme doğruluğu ve çerçeve sürekliliği gibi metriklerle değerlendirilmesi sağlanmıştır. SMD'nin çevresel çeşitliliği, algoritmaların gerçek senaryolardaki zamansal dayanıklılığını test etmek için uygun bir ortam sunmuştur.

4. DENEYSEL ÇALIŞMALAR VE PERFORMANS ANALİZLERİ

Bu bölümde, önerilen şarj soketi tespit ve takip sisteminin performansı, Bölüm 3.3’te tanıtılan özgün şarj soketi veri seti ve SMD kullanılarak değerlendirilmiştir. Deneysel çalışmalar; farklı model mimarileri, veri artırma yöntemleri ve kayıp fonksiyonu optimizasyonları ile tespit ve takip algoritmalarının sistem performansına etkilerini incelemek amacıyla yürütülmüştür. Analizler hem ayrıntılı ablasyon çalışmalarıyla hem de farklı donanım platformlarında yürütülmüştür.

Deneysel çalışmalar üç ana başlık altında gerçekleştirilmiştir:

- YOLO tabanlı şarj soketi tespit çalışmaları: YOLOv3, YOLOv5 ve YOLOv8 modelleri üzerinde mimari karşılaştırmalar gerçekleştirilmiş; özellikle YOLOv5 üzerinde Focal, SIoU ve Boundary-Aware kayıp fonksiyonları kullanılarak performans iyileştirmesi sağlanmıştır.
- Transformer tabanlı şarj soketi tespit çalışmaları: DETR, RT-DETR ve RF-DETR mimarileri incelenmiş; RT-DETR üzerinde çok aşamalı adaptif veri artırma stratejisi ile farklı senaryolarda genelleme başarımı artırılmıştır.
- MOT tabanlı gemi takip çalışmaları: DeepSORT, ByteTrack, OC-SORT, SORT, BoT-SORT ve StrongSORT algoritmaları kullanılarak limana yanaşan gemilerin takibi test edilmiş ve tespit modülleriyle entegrasyonu sağlanmıştır.

Bölümün ilk kısmında YOLO tabanlı tespit deneyleri ele alınacak, ardından DETR tabanlı çalışmalar ve takip algoritmaları sonuçları sunulacaktır.

4.1. Değerlendirme Metrikleri

4.1.1. Tespit metrikleri

Bu çalışmada geliştirilen şarj soketi tespit modelinin başarımı, çeşitli istatistiksel değerlendirme metrikleri kullanılarak nicel performans analizi gerçekleştirilmiştir. Performans ölçümleri, sınıflandırma çıktılarının doğruluğunu ve modelin genel kararlılığını değerlendirmek amacıyla yapılmıştır. Hesaplamalar, temel olarak Doğru Pozitif (TP), Yanlış Pozitif (FP), Yanlış Negatif (FN) ve Doğru Negatif (TN)

değerlerine dayanmaktadır. İlk olarak, modelin tespit ettiği pozitiflerin ne kadarının gerçekten doğru olduğunu ölçen kesinlik (precision) metriği hesaplanmıştır. Bu metrik, özellikle yanlış pozitiflerin önemli olduğu senaryolarda belirleyici olup, Denk. 4.1 ile hesaplanır. Diğer taraftan, modelin tüm gerçek pozitif örnekleri ne ölçüde doğru tespit edebildiğini gösteren duyarlılık (recall) metriği, Denk. 4.2’de verilen formül doğrultusunda tanımlanır. Bu iki ölçüt, modelin doğruluk ve kapsamını farklı açılardan değerlendirdiği için birlikte yorumlanmalıdır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (4.1)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4.2)$$

Kesinlik ve duyarlılık değerlerinin aynı anda yüksek olması istenir; bu nedenle bu iki değer dengesini sağlayan F1 skoru hesaplanır. Denk. 4.3’te verilen bu metrik, özellikle dengesiz sınıf dağılımlarında modelin genel başarımını daha güvenilir ve tutarlı yansıtır. Bunun yanı sıra, modelin genel doğru sınıflandırma oranı ise doğruluk (accuracy) metriği ile ölçülür. Denk. 4.4’te verildiği gibi, tüm doğru tahminlerin toplam tahminler içindeki oranını ifade eder.

$$\text{F1 Skoru} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4.3)$$

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.4)$$

Nesne tespiti uygulamalarında sınıf bazlı değerlendirme önemlidir. Bu amaçla, her sınıf için ortalama doğruluk (AP) metriği hesaplanır ve precision-recall eğrisi altındaki alan kullanılır. Ayrık ve sürekli durumlar için hesaplama yöntemleri Denk. 4.5 ve Denk. 4.6’da verilmiştir. Tüm sınıflara ait AP değerleri hesaplandıktan sonra bu değerlerin ortalaması ile mean Average Precision (mAP) metriği elde edilmektedir.

$$AP = \sum_n (R_n - R_{n-1}) P_n \quad (4.5)$$

$$AP = \int_0^1 P(R) dR \quad (4.6)$$

Model performansını değerlendirmek için $mAP@0.5$, $IoU \geq 0.5$ koşulu altında hesaplanırken; $mAP@0.75$ daha katı bir eşik sunar. $mAP@0.5:0.95$ ise 0.5'ten 0.95'e kadar 0.05'lik artışlarla elde edilen sonuçların ortalamasını alarak modelin farklı hassasiyet düzeylerindeki başarımını bütüncül biçimde yansıtmaktadır.

4.1.2. Takip metrikleri

MOT algoritmalarının başarımını değerlendirmek amacıyla çeşitli metrikler geliştirilmiştir. Bu metrikler, hem nesne takip doğruluğunu hem de kimlik izleme başarımını bütünsel şekilde ele almaktadır. Bu çalışmada, performans analizinde yaygın kullanılan temel takip metriklerine yer verilmiştir.

İlk olarak, genel takip doğruluğunu değerlendiren çoklu nesne izleme doğruluğu (MOTA) metriği kullanılmıştır. MOTA, sistemin kaçırılan tespitleri FN , FP ve kimlik değiştirme hatalarını (IDSW) birlikte dikkate alarak genel hata oranını yansıtmaktadır. MOTA değeri, bu hataların zaman içindeki toplamına göre normalize edilerek Denk. 4.7 ve Denk. 4.8'de gösterilen formüller ile hesaplanır. Burada GT_t , her zaman adımında yer alan gerçek nesne sayısını ifade eder.

$$MOTA = 1 - \frac{\sum (FN_t + FP_t + IDSW_t)}{\sum GT_t} \quad (4.7)$$

$$MOTA = 1 - \frac{\sum_t (FN_t + FP_t + IDSW_t)}{\sum_t GT_t} \quad (4.8)$$

Takip doğruluğunun yanı sıra sistemin konumsal hassasiyetini değerlendirmek amacıyla çoklu nesne izleme hassasiyeti (MOTP) metriği hesaplanmıştır. MOTP, eşleşen nesneler arasındaki ortalama konum hatasını gösterir ve daha düşük değerler daha yüksek konum hassasiyetine işaret eder. MOTP, tüm zaman adımları boyunca eşleşen nesne çiftlerinin ortalama mesafesi olarak ifade edilir (Denk. 4.9).

$$MOTP = \frac{\sum d_{t,i}}{\sum c_t} \quad (4.9)$$

Burada $d_{t,i}$; i ninci eşleşen nesne çifti arasındaki mesafeyi, c_t ise her karedeki doğru eşleşme sayısını ifade eder. Takip algoritmalarının tespit ve eşleştirme doğruluğunu birlikte değerlendirmek için yüksek düzeyde izleme doğruluğu (HOTA) metriği kullanılmıştır. HOTA, tespit doğruluğu (DetA) ile ilişkilendirme doğruluğunun (AssA) geometrik ortalaması olarak Denklem (4.10)'da tanımlanmaktadır.

$$HOTA = \sqrt{(DetA \times AssA)} \quad (4.10)$$

Özellikle kimlik takibi açısından sistemin başarımını değerlendirmek için, Identity F1 Score (IDF1) metriği kullanılmıştır. IDF1, takip edilen nesnelerin doğru kimlikle ne ölçüde eşleştirildiğini değerlendirir ve Denk. 4.11’de verilen formül doğrultusunda hesaplanır. Burada IDTP, doğru kimlikli eşleşmelerin sayısını, IDFP ve IDFN ise sırasıyla yanlış pozitif ve yanlış negatif kimlik eşleşmelerini temsil eder.

$$IDF1 = \frac{2 \times IDTP}{2 \times IDTP + IDFP + IDFN} \quad (4.11)$$

Son olarak, sistemin zaman içinde kaç kez kimlik hatası yaptığı Identity Switches (IDSW) metriği ile belirlenmiştir. Bu metrik, herhangi bir nesne için ardışık karelerde kimliğin değiştiği durumları sayarak hesaplanmaktadır. Kimlik değişimi, sistemin aynı fiziksel nesneye farklı kimlikler ataması durumunda meydana gelir ve takip sistemlerinin kararlılığı açısından kritik bir göstergedir.

$$IDSW = \sum 1(ID_t \neq ID_{t-1}) \quad (4.12)$$

4.1.3. Kayıp fonksiyonları

Nesne tespiti görevlerinde modelin başarımını artırmak amacıyla çeşitli kayıp fonksiyonları kullanılmaktadır. Bu fonksiyonlar, sınırlayıcı kutuların konumsal doğruluğunu ve sınıf tahminlerinin isabetini eş zamanlı olarak optimize etmeyi hedefler. Başlangıçta, kutuların kesişim-birleşim oranına dayalı olarak tanımlanan Intersection over Union (IoU) metriği, tahmin edilen kutunun yerel doğruluğunu değerlendirmek için temel bir ölçüt olarak benimsenmiştir (Denk. 4.13).

$$IoU(B, B^{gt}) = \frac{|B \cap B^{gt}|}{|B \cup B^{gt}|} \quad (4.13)$$

Ancak IoU'nun sıfır olduğu durumlarda gradyan üretilmemesi, öğrenmenin durmasına yol açabilmektedir. Bu sorunun üstesinden gelmek için IoU tabanlı gelişmiş kayıp fonksiyonları önerilmiştir. Bunlardan ilki olan Generalized IoU (GIoU), kutuların hiç kesişmediği durumlarda bile öğrenmeyi sürdürebilmek için, tahmin ve gerçek kutuyu birlikte kapsayan minimum dikdörtgen alanını dikkate alır (Denk. 4.14).

$$\mathcal{L}_{GIoU} = 1 - IoU + \frac{|C - (B \cup B^{gt})|}{|C|} \quad (4.14)$$

Distance IoU (DIOU) ise, kutu merkezleri arasındaki Öklidyen mesafeyi minimize ederek yalnızca örtüşmeyi değil, aynı zamanda konumsal hizalanmayı da iyileştirmeyi amaçlar. Burada ρ , merkezler arası mesafeyi; C , minimum kapsayan kutunun köşegen uzunluğunu ifade eder (Denk. 4.15). Complete IoU (CIoU) ise kutuların en-boy oranlarını da dikkate alarak daha bütünsel bir optimizasyon sağlar. Burada v , tahmin ve gerçek kutu arasındaki en-boy oranı farkını temsil ederken, α bu terimin etkisini dengeleyen bir ağırlık katsayısıdır (Denk. 4.16).

$$\mathcal{L}_{DIOU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} \quad (4.15)$$

$$\mathcal{L}_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (4.16)$$

Sınıf tahminlerinde kullanılan Focal loss, özellikle dengesiz veri kümelerinde modelin nadir görülen sınıfları da öğrenebilmesini sağlamak için geliştirilmiştir. Bu fonksiyon, klasik çapraz entropi kaybına odaklama terimi eklenerek tanımlanır. Burada p_t , doğru sınıf için tahmin edilen olasılığı; $\gamma > 0$ ise zor örneklerle odaklanma düzeyini belirler. Bu yapı sayesinde modelin kolay örneklerle aşırı uyum sağlaması engellenirken, zor örnekler üzerinden daha verimli bir öğrenme gerçekleşir (Denk. 4.17).

$$\mathcal{L}_{Focal}(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (4.17)$$

4.2. YOLO Tabanlı Şarj Soketi Tespit Çalışmaları

Bu bölümde YOLO'nun farklı sürümleri (YOLOv3, YOLOv5, YOLOv8) karşılaştırmalı olarak incelenmiştir. Amaç, bu yapıların mimari farklılıklarını, veri işleme kabiliyetlerini ve gömülü sistem uyumluluklarını değerlendirerek en uygun modeli belirlemektir. YOLOv3, Darknet-53 tabanlı yapısı ile hız avantajı sunsa da küçük ölçekli şarj soketi tespitinde sınırlı kalmıştır. YOLOv5, PyTorch tabanlı modüler mimarisiyle veri artırma ve kayıp fonksiyonu optimizasyonlarını etkin biçimde desteklemiştir. YOLOv8 ise anchor-free yapısı ve padding-aware decoding

özellığı sayesinde özellikle küçük nesne ve kenar bölgelerindeki tespit doğruluğunda öne çıkmıştır. Nicel sonuçlar Tablo 4.1’de sunulmuştur.


Tablo 4.1. YOLO sürümlerinin performans metriklerinin karşılaştırması.

Model	Precision	Recall	F1-Score	mAP@0.5	mAP@0.5:0.95
YOLOv3	0.85	0.74	0.79	0.86	0.55
YOLOv5	0.91	0.90	0.89	0.96	0.88
YOLOv8	0.96	0.92	0.94	0.97	0.91


Tüm modeller, NVIDIA A100 GPU üzerinde eğitilmiş; ayrıca Jetson Nano (~5–10 FPS) ve Jetson Xavier Nx (~20–30 FPS) platformlarında gerçek zamanlı test edilmiştir. Eğitim süresince veri artırma teknikleri (random crop, HSV renk uzayı değişimleri, Gaussian blur) uygulanmıştır. YOLOv5 modeli, sistemin temel tespit modülü olarak tercih edilmiş ve kayıp fonksiyonları ile optimize edilmiştir (Şekil 4.1).

Eğitim süreci boyunca dört temel performans metriğı takip edilmiştir. Şekil 4.1(a) incelendiğinde, mAP@0.5 değerinin eğitimin ilk adımlarında hızlı bir artış gösterdiği ve kısa sürede yaklaşık %96 seviyesine ulaştığı görülmektedir. Bu durum, modelin erken dönemde anlamlı şarj soketi temsillerini öğrenebildiğini ortaya koymaktadır. Şekil 4.1(b)’de sunulan mAP@0.5:0.95 metriğı ise yaklaşık %88.5 seviyesinde seyrederek farklı boyutlardaki soketlerde yüksek genelleme başarımı sağlandığını göstermektedir. Precision eğrisi (Şekil 4.1c), yanlış pozitif oranının düşük seviyede kaldığını ve tespit edilen soketlerin büyük çoğunluğunun doğru olduğunu kanıtlamaktadır. Recall metriğı ise (Şekil 4.1d) oldukça iyi bir seviyeye ulaşarak, modelin sahnede yer alan şarj soketlerinin büyük kısmını doğru şekilde tespit edebildiğini göstermiştir. Bu sonuçlar birlikte değerlendirildiğinde, YOLOv5’in yüksek doğruluk, düşük hata oranı ve geniş ölçekli genelleme kabiliyeti ile sistemin gereksinimlerini karşıladığı anlaşılmaktadır.

Şekil 4.2’de verilen Precision-Confidence, Recall-Confidence, Precision-Recall ve F1-Confidence eğrileri de bu durumu desteklemekte; modelin özellikle 0.1-0.85 confidence aralığında dengeli ve istikrarlı bir performans sergilediğini ortaya koymaktadır.



Şekil 4.1. YOLOv5 modelinin eğitim sürecinde (a) $mAP@0.5$, (b) $mAP@0.5:0.95$, (c) precision ve (d) recall metriklerinin adım bazında değişimi.



Şekil 4.2. YOLOv5 modeline ait (a) Precision-Confidence eğrisi, (b) Recall-Confidence eğrisi, (c) Precision-Recall eğrisi ve (d) F1-Confidence eğrisi.

Modelin gerek grntler zerindeki bařarımı, farklı evresel kořullar altında alınan test verileriyle de doęrulanmıřtır. řekil 4.3'te grldę zere, gndz, glge ve dřk ıřık gibi farklı senaryolarda; ayrıca deęiřen mesafe ve aı kořullarında model, yksek gven skorları ile kararlı tespitler gerekleřtirmiřtir.




řekil 4.3. YOLOv5 tabanlı řarj soketi tespit modlnn gerek ortam grntleri zerindeki tespit sonuları.

Kısmi rtřme, perspektif bozulması ve deęiřken arka plan yapıları gibi zorlayıcı durumlarda bile řarj soketi hedefinin doęru řekilde iřaretlenmesi, modelin sahada uygulanabilirlięini ortaya koymaktadır. Bu bulgular, YOLOv5 tabanlı tespit modlnn yalnızca laboratuvar ortamında deęil, gerek dnyada da gvenilir bir řekilde alıřabileceęini gstermektedir.

4.2.1. YOLOv5 zerinde kayıp fonksiyonu optimizasyonu


řarj soketi tespit modlnde yksek doęruluk elde edilmesine raęmen, zellikle farklı mesafe ve aı kořullarında konumlama hatalarının ve sınıf tanımlama belirsizliklerinin belirli bir seviyede devam ettięi gzlemlenmiřtir. Bu durum, sistemin saha kořullarındaki genelleme kabiliyetini olumsuz etkileyebileceęinden, modelin hata bileřenlerinin ayrıntılı olarak incelenmesi ve iyileřtirilmesi gereklilięini ortaya koymuřtur. Bu amala, kayıp fonksiyonlarının optimizasyonu zerine odaklanılmıř; farklı kayıp fonksiyonu eřitlerinin, tespit modlnn konum doęruluęu, nesne varlıęı

algılama ve sınıf tanımlama performansı üzerindeki etkileri değerlendirilmiştir. Şekil 4.4'te, bu kapsamda karşılaştırılan üç farklı kayıp fonksiyonu -Focal, SIoU ve Boundary-Aware Loss (BAL)- için elde edilen sonuçlar sunulmaktadır. Bu bulgular, BAL'ın sınıf tespitinde Focal ile benzer seviyede, SIoU'ya yakın yüksek sonuçlar sunduğunu, ancak konumlama doğruluğunda diğer yöntemlere kıyasla daha belirgin bir üstünlük sağladığını göstermektedir. Dolayısıyla, elektrikli gemi şarj soketi tespiti gibi hem konum hem de sınıf doğruluğunun kritik olduğu uygulamalarda, çoklu metrik optimizasyonunu gözetten bir yaklaşımın tercih edilmesi gerekmektedir.



Şekil 4.4. Focal, SIoU ve BAL kayıp fonksiyonlarının şarj soketi tespitinde kutu (box), nesne (obj) ve sınıf (cls) kayıplarındaki göreceli iyileşme oranları (%).

Şekil 4.5'te, YOLOv5 modelinde varsayılan (base) loss fonksiyonu ile SIoU, BAL ve Focal kayıp fonksiyonlarının eğitim süreci boyunca precision, recall, mAP@0.5 ve mAP@0.5:0.95 metriklerindeki değişim eğrileri görülmektedir. Tüm alternatif kayıp fonksiyonları, Base modele kıyasla daha hızlı yakınsama göstermiş ve eğitim sonunda daha yüksek nihai değerlere ulaşmıştır. BAL, precision metriğinde başlangıçtan itibaren yüksek seviyede ilerleyerek dikkat çekerken, Focal loss özellikle recall eğrisinde dengeli ve sürekli bir artış sağlamıştır. mAP metriklerinde ise hem BAL hem de Focal, SIoU'ya kıyasla biraz daha yüksek sonuçlar elde etmiştir. Tablo 4.2'de görüldüğü üzere, BAL özellikle Obj Loss'ta en yüksek artışı sağlamış, Cls Loss'ta ise Focal'e yakın sonuçlar elde ederken, SIoU çok az daha yüksek değer vermiştir; Box Loss'ta ise diğerlerine göre belirgin bir yüksek sonuç göstermiştir.



Şekil 4.5. Farklı kayıp fonksiyonlarının eğitim sürecinde precision, recall ve mAP değişim eğrileri.

Tablo 4.2. Farklı kayıp fonksiyonlarının (Focal, SIOU, BAL) şarj soketi tespit performansına etkileri (%).


Kayıp Fonksiyonları	Box	Obj	Cls
Focal (%)	10.96	18.75	13.64
SIOU (%)	9.51	19.05	14.29
BAL (%)	13.42	19.38	14.21

4.3. Transformer Tabanlı Şarj Soketi Tespit Çalışmaları

Bu bölümde, DETR, RF-DETR ve RT-DETR modelleri arasındaki karşılaştırmalı deneyler sunulmakta ve performanslar AP (Average Precision) ile AR (Average Recall) metrikleri üzerinden değerlendirilmektedir. Şekil 4.6'da sunulan ısı haritası, modellerin farklı değerlendirme metriklerindeki başarılarını görsel olarak ortaya koymaktadır. AP@[0.50:0.95] metriği genel doğruluk başarımını özetleyen temel metrik olup, RF-DETR 0.887 ile en yüksek değeri elde etmiştir. RT-DETR 0.875 değeri ile RF-DETR'ye yakın sonuçlar üretirken, DETR 0.836 ile geride kalmıştır. Daha spesifik değerlendirmeler olan AP@[0.50] ve AP@[0.75] metriklerinde de RF-


DETR'nin sırasıyla 0.935 ve 0.903; RT-DETR'in 0.930 ve 0.9 ile rekabetçi sonuçlar sunduğu görülmektedir. Büyük nesne değerlendirme metriği AP@[Large]'ta da RF-DETR 0.888 ile üstünlük sağlamıştır.

Duyarlılık metrikleri olan AR@[100], AR@[10] ve AR@[1] metriklerinde RF-DETR'nin tamamında 0.900 ve üzeri değerler elde ettiği, RT-DETR'nin benzer düzeyde performans gösterdiği, DETR'nin ise tüm metriklerde 0.857 seviyesinde kaldığı gözlemlenmiştir. Bu bulgular, deformable attention mimarisinin RF-DETR modeline farklı ölçeklerde nesne tespitinde yüksek doğruluk ve erişim oranları sağlama noktasında belirgin bir avantaj kazandırdığını ortaya koymaktadır.



Şekil 4.6. DETR, RF-DETR ve RT-DETR modellerine ait karşılaştırmalı başarımların ısı haritası (heatmap) biçiminde gösterimi.

Şekil 4.7'de sunulan kutu grafik, DETR, RF-DETR ve RT-DETR modellerinin başarı metriklerinin dağılımını göstermektedir. RF-DETR, yüksek medyan (~0.90) ve dar dağılım aralığıyla en istikrarlı model olarak öne çıkmaktadır. RT-DETR, benzer bir medyan değere ulaşmasına rağmen daha geniş bir dağılım sergileyerek istikrar açısından RF-DETR'nin gerisinde kalmıştır. DETR ise en düşük medyan (~0.85) ve en geniş aralıkla en tutarsız modeldir. Bu sonuçlar, RF-DETR'nin farklı koşullar altında daha güvenilir bir performans sunduğunu ortaya koymaktadır.



Şekil 4.7. DETR, RF-DETR ve RT-DETR modellerinin başarı değerlerinin dağılımını gösteren kutu grafiği.


4.3.1. RT-DETR performansının çok aşamalı veri artırma ile iyileştirilmesi

Çok aşamalı adaptif veri artırma, eğitim sürecinin farklı evrelerinde uygulanan artırma tekniklerinin, veri seti özellikleri, model hata dağılımı ve hedef metrikler doğrultusunda dinamik olarak seçilip uyarlanmasıdır. Bu yöntem, veri çeşitliliğini artırmakla kalmaz; temsil uzayının kapsama oranını genişleterek özellikle yüksek varyansa sahip veri setlerinde modelin genelleme kabiliyetini ve karar sınırı kararlılığını güçlendirir. Bu çalışmada söz konusu strateji, gerçek zamanlı nesne tespitinde düşük gecikme ve gömülü sistemlerde yüksek verimlilik sunması nedeniyle RT-DETR modeli üzerinde uygulanmıştır.

Şekil 4.8’de RT-DETR modelinde uygulanan veri artırma tekniklerinin aşamalı katkıları gösterilmektedir:

- CLAHE + Shadow: CLAHE, kontrast sınırlamalı adaptif histogram eşitleme yöntemiyle düşük aydınlatmalı bölgelerde detay kaybını önler. Gölgeleme eklenmesi ise modelin değişken ışık koşullarına karşı invariyan özellikler öğrenmesini sağlar.
- Mosaic: Dört bağımsız görüntünün farklı ölçek ve konumlarda birleştirilmesiyle nesne konumu ve ölçek çeşitliliğini artırarak modelin genelleme kabiliyetini geliştirir.

- MixUp/CutMix: MixUp, iki görüntünün piksel seviyesinde lineer kombinasyonunu; CutMix ise bir görüntüden alınan yamaların diğerine eklenmesini kullanarak veri dağılımını sürekli hale getirir ve karar sınırlarını yumuşatır.
- TTA (Test-Time Augmentation): Test aşamasında farklı artırmalar uygulanarak elde edilen tahminlerin birleştirilmesi (ensemble) sayesinde kutu regresyonu ve sınıflandırma skorlarında kararlılığı artırır.




Şekil 4.8. RT-DETR modelinde çok aşamalı adaptif veri artırma tekniklerinin mAP skoruna etkisi.

Şekil 4.8’de, farklı veri artırma tekniklerinin RT-DETR modelinde mAP skoruna bağımsız katkıları yüzelik artış olarak gösterilmektedir. Bununla birlikte, bu teknikler aşamalı ve adaptif biçimde bir arada uygulandığında, Baseline modele kıyasla kademeli iyileşmeler sağlanmış ve modelin genel başarımı en yüksek seviyeye ulaşmıştır. Bu sonuç, çok aşamalı veri artırma stratejilerinin RT-DETR modelinin genelleme kabiliyetini güçlendirerek özellikle küçük nesne tespiti ve değişken sahne koşullarında belirgin performans artışı sağladığını ortaya koymaktadır.

4.4. Çoklu Nesne Takip Algoritmalarının Performans Sonuçları

Bu kısımda, geliştirilen sistemin nesne takibi bileşenleri ele alınmakta ve kullanılan çoklu nesne takip algoritmalarının genel yapısı ile değerlendirme yöntemleri açıklanmaktadır. Takip algoritmaları, tespit edilen nesnelerin zaman içerisindeki konum ve kimlik bilgilerinin korunmasını sağlayarak sürekli izleme ve analiz olanağı sunmaktadır. Bu doğrultuda, çalışmada literatürde yaygın olarak kullanılan SORT,

DeepSORT, ByteTrack, BoT-SORT, OC-SORT ve StrongSORT gibi MOT algoritmaları tercih edilmiştir. Takip algoritmalarının değerlendirilmesinde iki temel hedef gözetilmiştir: (i) MOT algoritmalarının genel performansını nesne tespiti ve kimlik takibi doğrultusunda ölçmek; (ii) hareketli sahneler ve birden fazla hedef içeren karmaşık senaryoları analiz edebilmek. Bu kapsamda, denizcilik ortamlarında farklı hava koşulları, aydınlatma seviyeleri ve nesne yoğunluklarını barındırmasıyla bilinen Singapore Maritime Dataset (SMD) kullanılmıştır. Bu veri seti, gerçekçi ve zorlu koşullar altında algoritmaların güvenilir biçimde test edilmesine olanak sağlayarak çalışmada referans noktası olarak tercih edilmiştir. Şekil 4.9’da, farklı MOT algoritmalarının FPS (hız) ve MOTA (izleme doğruluğu) metriklerine göre dağılımları sunulmuştur. Grafik, her bir algoritmanın hız–doğruluk dengesini görselleştirerek uygulama senaryolarına en uygun yöntemin seçimi için karşılaştırmalı bir bakış açısı sağlamaktadır.



Şekil 4.9. Çoklu nesne takip algoritmalarının FPS (hız) ve MOTA (izleme doğruluğu) değerlerine göre karşılaştırılması.

Elde edilen sonuçlara göre, ByteTrack algoritması, yüksek FPS değeri ve yaklaşık %80 seviyesindeki MOTA doğruluğu ile en dengeli çözümü sunmaktadır. Gerçek zamanlı çalışabilirliği ve güçlü izleme performansı sayesinde sistemin takip bileşeni için en avantajlı yöntemlerden biri olarak öne çıkmaktadır. BoT-SORT algoritması da benzer şekilde yüksek doğruluk ve orta seviyede hız sağlamış; özellikle kamera hareket kompanzasyonu gibi gelişmiş özellikleri sayesinde izleme kalitesini

iyileştirirken gerçek zamanlı çalışabilirliği korumuştur. SORT algoritması, yaklaşık 18 FPS hızında çalışmasına rağmen %81 civarında MOTA doğruluğu elde etmiş ve basit yapısı sayesinde düşük hesaplama maliyetleriyle dikkat çekmiştir.

Ancak uzun süreli takiplere karşı daha hassas olduğu gözlemlenmiştir. OC-SORT ve StrongSORT algoritmaları 11–13 FPS aralığında çalışmakta olup, buna rağmen %80’in üzerinde MOTA değeri sunarak belirli senaryolarda güçlü bir alternatif olarak değerlendirilebilmektedir. Öte yandan, DeepSORT algoritması yaklaşık 10 FPS hız ile en yavaş yöntemlerden biri olmasına rağmen, MOTA değerinin %70 seviyesinde kalması sebebiyle diğer yöntemlere kıyasla daha sınırlı bir performans göstermiştir. Genel değerlendirme açısından, ByteTrack ve BoT-SORT algoritmaları, sistemin hedeflediği gerçek zamanlı ve yüksek doğruluklu izleme ihtiyaçlarını en iyi karşılayan yöntemler olarak öne çıkmaktadır. Bununla birlikte, SORT ve StrongSORT gibi yöntemler de hesaplama kaynaklarının kısıtlı olduğu senaryolarda alternatif olarak değerlendirilebilir.



5. SAHA UYGULAMALARI VE GERÇEK ZAMANLI TESTLER

Bu bölümde, geliştirilen otonom kontrollü robotik şarj sisteminin saha uygulamaları, bütünleşik kontrol yapısı ve kullanıcı arayüzüne ilişkin detaylar sunulmaktadır. Sistem; PyQt tabanlı kullanıcı arayüzü, görsel veriye dayalı konumlandırma algoritmaları, gömülü platform ve PLC kontrollü hareket mekanizmalarıyla entegre edilmiştir. Bu yapı, deniz araçlarına ait şarj soketlerinin otonom hizalanmasını ve güvenli enerji aktarımını sağlamak amacıyla tasarlanmış ve laboratuvar ortamında prototip testleriyle doğrulanmıştır.

Kullanıcı arayüzü, operatöre hem izleme hem de manuel müdahale imkânı sunmakta; sistem bileşenlerinin durumu, kamera görüntüleri, bağlantı göstergeleri, hata kodları ve işlem geçmişi gerçek zamanlı olarak takip edilebilmektedir. Ayrıca soket koordinatları ve mesafe bilgileri arayüzde anlık olarak görselleştirilmekte, bu sayede gerektiğinde operatörün müdahalesi kolaylaştırılmaktadır. Arayüz gömülü sistem üzerinde çalışmakta ve PLC ile veri alışverişi Modbus protokolü üzerinden gerçekleştirilmektedir.


Robotik yapı, bilgisayarlı görme algoritmaları yardımıyla hedef soketin konumunu belirlemekte; mesafe ölçümleriyle birlikte elde edilen veriler PLC tabanlı kontrol ünitesine aktarılmaktadır. Bu noktada, gömülü platform üzerinde optimize edilmiş kontrol modelleri kullanılarak farklı çevresel koşullarda soketin doğru tespiti sağlanmıştır. PLC, motor sürücüler aracılığıyla robotik kolu yönlendirerek hizalama sürecini gerçekleştirmektedir.

Geliştirilen sistem, farklı hizalama senaryoları ve çevresel koşullar altında test edilmiş; tepki süresi, hizalama doğruluğu ve işlem süreleri ölçülerek performansı değerlendirilmiştir. Testler, güvenli bağlantı süresinin 30 saniyenin altına indirildiğini ve operasyonel verimliliğin artırıldığını göstermiştir.

5.1. Uygulama Arayüzleri


Elektrikli gemiler için şarj soketi tespit uygulaması, kullanıcıya hem renk tabanlı hem de derin öğrenme tabanlı yöntemleri deneyimleme imkânı sunan bir arayüz üzerinden

çalışmaktadır. Arayüz, gerçek zamanlı kamera görüntüsü veya önceden kaydedilmiş video verileri üzerinde çalıştırılabilmekte; ayrıca sistemin gömülü PLC ile bağlantı durumu anlık olarak izlenebilmektedir. Şekil 5.1’de uygulamanın ana arayüzü görülmektedir. HSV tabanlı yöntem, düşük işlem yükü ve hızlı çalışabilme avantajı sayesinde sade ve homojen arka planlı sahnelerde etkili sonuçlar verirken; aydınlatma değişimlerine ve karmaşık arka planlara karşı daha hassas bir yapı sergilemektedir. Bu klasik yöntemde soketin renk bilgisi kullanılarak tespit edilmekte ve konum bilgisi yeşil çerçeve ile görselleştirilmektedir. YOLO ve DETR tabanlı yöntemler, veri üzerinden öğrenbilme yetenekleri ile yeni sahnelere uyum sağlayarak karmaşık ortamlarda daha yüksek doğruluk ve genelleme başarımı sunmaktadır.



Şekil 5.1. Elektrikli gemiler için şarj soketi tespit uygulamasının ana arayüzü.

Şekil 5.2’de bu üç yöntemden YOLOv5 tabanlı modüle ait arayüz sunulmaktadır. Bu modülde, önceden eğitilmiş YOLOv5 modeli gerçek zamanlı olarak çalıştırılmakta ve tespit edilen şarj soketi sınırlayıcı kutu ile işaretlenmektedir. Ayrıca kutu üzerine sınıf etiketi (socket) ve tespit doğruluk skoru yansıtılmaktadır. Sistem, entegre lazer sensörlerden alınan verilerle soketin konum ve mesafe bilgilerini hesaplamakta ve bu bilgileri gömülü PLC sistemine anlık olarak iletmektedir. Bağlantı durumu, arayüzün sol üst köşesindeki gösterge aracılığıyla yeşil (bağlantı var) veya kırmızı (bağlantı yok) olarak kullanıcıya bildirilmektedir. YOLOv5 tabanlı yaklaşım, dinamik ortam koşullarında yüksek doğruluk ve kararlılık sağlayarak, gerçek zamanlı uygulama gereksinimlerini karşılamaktadır.




Şekil 5.2. YOLOv5 tabanlı uygulama arayüzü üzerinden gerçek zamanlı şarj soketi tespiti ve konum-mesafe bilgilerinin gösterimi.

Şekil 5.3'te geliştirilen elektrikli STS şarj sistemi test düzeneklerinden biri gösterilmektedir. Üst bölümde, tespit edilmesi hedeflenen dışı şarj soketi yer almakta; alt bölümde ise, bu soketin konum ve mesafe bilgilerinin gerçek zamanlı olarak işlendiği uygulama arayüzü görülmektedir. Arayüz, tespit edilen soketi sınırlayıcı kutu ile işaretleyerek sınıf etiketi (socket) ve doğruluk skorunu görüntülemekte; elde edilen bilgiler entegre lazer sensör desteğiyle hassas mesafe ölçümü yapılarak gömülü PLC sistemine anlık olarak iletilmektedir.


5.2. Deneysel Uygulama ve Gerçekleme

Geliştirilen robotik STS şarj sistemi, donanım ve kontrol bileşenlerinin entegrasyonu tamamlandıktan sonra laboratuvar ortamında kapsamlı şekilde test edilmiştir. Şekil 5.4'te sistemin ana donanım bileşenleri gösterilmektedir. Sistem; gömülü platform, PLC tabanlı kontrol panosu, kamera ve erkek şarj soketinden oluşmaktadır. Gömülü platform, erkek soketin üç ekseninde hassas hareketini sağlayarak dışı soket ile doğru hizalanmasına imkân tanımaktadır. PLC tabanlı kontrol panosu, tüm hareket ve bağlantı komutlarının yönetildiği merkezi bir kontrol ünitesi olarak görev yapmaktadır. Kamera, bilgisayarlı görme tabanlı tespit algoritmaları için gerekli görsel veriyi sağlamaktadır. Erkek şarj soketi ise enerji aktarımının fiziksel olarak gerçekleştirildiği bileşen olup, hizalama sonrasında dışı sokete güvenli şekilde bağlanmaktadır.



Şekil 5.3. Gerçek zamanlı şarj soketi tespit sistemi ve uygulama arayüzü.

Bu bütünleşik yapı sayesinde, sistem hem görsel algılama hem de mekanik bağlantı görevlerini koordineli biçimde gerçekleştirebilmektedir. Geliştirilen otonom robotik STS şarj sisteminin erkek ve dişi şarj soketleri arasındaki bağlantı süreci, Elkon Ar-Ge Merkezi'nin kontrollü laboratuvar ortamında gerçekleştirilen testler kapsamında gösterilmektedir. Bu testlerde sistem, farklı hareket hızları, değişken aydınlatma koşulları ve çeşitli konumsal senaryolar altında değerlendirilmiştir.



Şekil 5.4. Robotik STS şarj sisteminin donanım bileşenleri: gömülü platform, PLC tabanlı kontrol panosu, kamera ve erkek şarj soketi.

Gerçek çalışma süreci üç aşamadan oluşmaktadır (Şekil 5.5). İlk olarak (a) erkek soket park pozisyonunda beklemekte, bu durum gemi yanaşmadan önceki veya şarj süreci başlamadan önceki hazır bekleme pozisyonunu temsil etmektedir. Ardından (b) bilgisayarlı görme sistemi dişi soketin konumunu tespit eder ve erkek soketi yatay ve

dikey eksenlerde tam hizaya getirir. Bu, geminin şarj bağlantısı yapılmadan hemen önceki hassas konumlandırma aşamasıdır. Son olarak (c) erkek soket dişi sokete tamamen bağlanır, fiziksel ve elektriksel temas sağlanır ve PLC kontrolüyle enerji aktarımı başlatılır. Bu üç aşamalı süreç, laboratuvar testlerinde başarıyla tamamlanmış ve sahadaki uygulamalara yönelik güvenilir sonuçlar elde edilmiştir.



(a)

(b)




(c)

Şekil 5.5. Robotik STS şarj sistemi erkek-dişi soket hizalama süreci: (a) park pozisyonu, (b) hizalanmış konum, (c) kenetlenme durumu.

Bağlantı sürecinin ardından, sistemin sahada gerçek zamanlı olarak nasıl çalıştığı ve görsel algılama çıktılarının kullanıcıya nasıl aktarıldığı önem taşımaktadır. Bu kapsamda geliştirilen arayüz, erkek ve dişi şarj soketlerinin konumlandırılmasını ve

tespit sonuçlarının anlık takibini sağlamaktadır. Şekil 5.6’da robotik şarj sisteminde erkek ve dişi soketlerin fiziksel konumları ile uygulama arayüzü gösterilmektedir. Erkek soket gömülü platform üzerine monte edilmiş olup PLC kontrollü hareket sistemiyle dişi sokete yönlendirilmektedir. Dişi soket sabit platform üzerinde gemi üzerindeki şarj girişini temsil etmektedir. Orta kısımda yer alan ekran ise, bilgisayarlı görme sistemi tarafından tespit edilen dişi soketi sınırlayıcı kutu ve doğruluk skoru ile işaretlemekte, böylece operatör hem fiziksel düzeni hem de yazılım tabanlı süreci eş zamanlı olarak takip edebilmektedir.



Şekil 5.6. Geliştirilen robotik STS şarj sistemi üzerinde erkek ve dişi şarj soketlerinin konumlandırılması ve uygulama arayüzü görünümü.



6. SONUÇLAR, DEĞERLENDİRME VE ÖNERİLER

6.1. Sonuçlar ve Değerlendirme

Bu tez çalışmasında, elektrikli gemilerin kıyıdan-gemiye otonom şarj prosesi için yapay zekâ tabanlı yeni bir kontrol sisteminin tasarımı, gerçekleştirilmesi ve deneysel doğrulaması sunulmaktadır. Sürdürülebilir denizcilik operasyonlarına duyulan artan gereksinimler doğrultusunda geliştirilen sistem, liman ortamlarında daha güvenli, hızlı ve hassas enerji aktarımı için uygulanabilir bir çözüm olarak önerilmiştir. Çalışma kapsamında, çeşitli çevresel koşullarda elde edilen şarj soketi görüntülerinden oluşan özgün bir veri seti literatüre kazandırılmış; PLC, gömülü sistem, RGB kamera ve lazer sensörlerinin entegre edildiği robotik bir yapı tasarlanarak bilgisayarlı görme tabanlı kontrol algoritmaları geliştirilmiştir. Bu bütünleşik yapıda, soketler arasındaki mesafe 60 cm'ye ulaşıncaya kadar görüntü işleme tabanlı hizalama uygulanmış, bu noktadan sonra ise lazer sensörleri tabanlı hassas hizalama devreye alınarak şarj soketinin doğru tespiti, hizalanması ve güvenli enerji aktarımı mümkün kılınmıştır.

Oluşturulan veri seti üzerinde YOLOv3, YOLOv5 ve YOLOv8 mimarileri kullanılarak şarj soketi konum ve mesafe tespiti gerçekleştirilmiş, YOLOv5 üzerinde Focal, SIOU ve Boundary-Aware kayıp fonksiyonlarıyla yapılan optimizasyonlar ile doğruluk oranlarında kayda değer bir artış sağlanmıştır. Ayrıca, DETR, RT-DETR ve RF-DETR gibi transformer tabanlı mimariler analiz edilerek doğruluk, hız ve entegrasyon performansları başarıyla değerlendirilmiş; RT-DETR üzerinde çok aşamalı adaptif veri artırma stratejisi geliştirilerek modelin farklı senaryolarda genelleme başarımı iyileştirilmiştir. Ayrıca, Singapore Maritime Dataset (SMD) üzerinde çoklu nesne takibi amacıyla DeepSORT, ByteTrack, OC-SORT, SORT, BoT-SORT ve StrongSORT algoritmaları uygulanmış ve limana yaklaşan gemilerin izleme performansları ölçülmüştür. Bu sayede, özgün veri setinde yer almayan senaryolar için algoritmaların dayanıklılığı test edilerek farklı koşullara uyum kabiliyeti ortaya konulmuştur.

Kamera ve lazer sensörlerinden elde edilen veriler, veri füzyonu yöntemiyle birleştirilmiş ve Modbus protokolü üzerinden PLC ile gerçek zamanlı haberleşme

sağlanarak robotik sistemin hareket kontrolü gerçekleştirilmiştir. Buna ek olarak, Snap7 kütüphanesi kullanılarak PLC ile doğrudan iletişim kurulmuş ve Modbus tabanlı haberleşmeye kıyasla daha esnek ve güvenilir bir kontrol imkânı sağlanmıştır. Sistem entegrasyonu kapsamında, sensör verilerinin füzyonu ile hassas konumlama yapılmış; Jetson Nano ve Jetson Xavier Nx platformlarında optimize edilen algoritmalar ile geliştirilen PyQt tabanlı arayüz uygulaması aracılığıyla sistem durumu ve ölçüm parametreleri gerçek zamanlı izlenmiştir. Saha testlerinde bağlantı süresinin 30 saniyenin altına indirilmesiyle sistemin operasyonel verimliliği doğrulanmıştır. Elde edilen sonuçlar, otonom robotik şarj sistemlerinin denizcilik sektöründe güvenilirlik, hız ve hassasiyet gereksinimlerini karşılayabileceğini göstermektedir. Bu çalışma, yalnızca teknik başarıları değil; aynı zamanda veri seti çeşitliliğinin, adaptif veri artırma stratejilerinin ve yapay zekâ tabanlı algılama yöntemlerinin endüstriyel kontrol donanımlarıyla entegrasyonunun önemini de ortaya koymaktadır. Ayrıca sistem, üniversite–sanayi iş birliği çerçevesinde geliştirilmiş olup, uygulamaya dönük çözümlere katkı sağlayabilecek nitelikte değerlendirilmiştir.

Gelecek çalışmalar kapsamında sistemin olumsuz deniz koşullarında dinamik gemi hareketlerini yönetebilecek şekilde geliştirilmesi, kablosuz enerji aktarım teknolojileriyle bütünleştirilmesi ve sürekli operasyonel verilerden yararlanarak kestirimci bakım fonksiyonlarının eklenmesi planlanmaktadır. Ayrıca mevcut sistemin denizcilik odaklı tasarımı, kara tabanlı elektrikli araçlara uyarlama potansiyeli taşımakta olup, bu doğrultuda farklı altyapı ve operasyonel gereksinimler dikkate alınarak karşılaştırmalı senaryo analizlerinin yapılması önerilmektedir. Bu kapsamda çalışma, ülkemizin öncelikli alanlarıyla da uyumlu olup yapay zekâ ve makine öğrenmesi tabanlı otonom kontrol yaklaşımlarının geliştirilmesine, robotik-mekatronik sistemlerle şarj sürecinin otomatikleştirilmesine ve enerji depolama-yönetim süreçlerinin daha verimli ve güvenli hale getirilmesine katkı sağlayacaktır.

Sonuç olarak, geliştirilen otonom kontrollü şarj sistemi gerçek zamanlı şarj soketi tespiti ve takip yöntemlerinin etkinliğini göstermede araştırmacılara rehberlik etmesi beklenmektedir. Elde edilen bulguların, tam otomasyonlu şarj sistemleri için bir referans oluşturması, bu teknolojilerin yaygınlaştırılmasına katkı sağlaması ve IMO’nun 2030 ile 2050 karbon azaltım hedefleri doğrultusunda yürütülen sürdürülebilir liman elektrifikasyonu çalışmalarına yön vermesi beklenmektedir.

6.2. Öneriler

Bu tez kapsamında yürütülen çalışmalar, yapay zekâ tabanlı nesne algılama, takip ve veri füzyonu yöntemleriyle entegre edilen otonom kontrol sisteminin uygulanabilirliğini ortaya koymuş; özellikle elektrikli gemilerin şarj sürecinde güvenli ve hızlı bağlantı sağlama açısından başarıyla değerlendirilmiştir. Ayrıca geliştirilen sistemin, gemilerin operasyonel programları dikkate alınarak bağlantı sürelerini azaltabileceği ve insan müdahalesini en aza indirerek tam otomasyonla çalışabileceği gösterilmiştir. Bununla birlikte, sistemin performansını daha da geliştirmek ve farklı koşullarda uygulanabilirliğini artırmak amacıyla aşağıda çeşitli öneriler sunulmuştur.

1. Sistemin farklı çevresel koşullar ve küçük nesnelerin bulunduğu senaryolarda karşılaşılan zorluklarla daha etkili şekilde başa çıkabilmesi için segmentasyon tabanlı yöntemlerin veya hibrit modellerin entegrasyonu önerilmektedir. Özellikle şarj soketinin kısmen gölgede kalması, düşük ışık koşulları veya gemi hareketi nedeniyle soketin görüntüde net seçilemediği senaryolarda, bu tür yaklaşımlar sistemin dayanıklılığını ve operasyonel güvenilirliğini artırabilir.
2. Gelecekteki çalışmalarda, bu tezde oluşturulan özgün şarj soketi veri setinin farklı elektrikli gemi şarj soket tipleri ve kara tabanlı elektrikli araç şarj soket tipleri ile genişletilmesi; ayrıca etiketleme sürecinde otomatikleştirilmiş yöntemlerin kullanılması, modellerin genelleme kabiliyetini ve saha uygulamalarına uyum yeteneğini daha da güçlendirecektir.
3. Tezdeki laboratuvar ve saha senaryolarında doğrulanmış olan sistemin gerçek operasyon koşullarındaki performansı dijital ikiz tabanlı doğrulama yaklaşımı ile geliştirilebilir. Dijital ikiz kullanımı, sistemin sensör verileriyle güncellenerek farklı koşullarda güvenli test imkânı sunmasını ve bakım, güvenlik ile enerji optimizasyonunda maliyet-etkin katkılar sağlamasını mümkün kılmaktadır.
4. RGB kamera ve lazer sensörlerine ek olarak termal kamera, ultrasonik sensör veya LiDAR gibi farklı algılayıcıların saha koşullarında test edilmesi, çevresel etkilerden daha az etkilenen ve daha kararlı sistemler tasarlanmasına imkân tanıyacaktır. Bu nedenle, gelecek çalışmalarda çoklu sensör füzyonunun sistem performansı üzerindeki etkileri detaylı biçimde incelenmelidir.

5. Jetson Nano ve Jetson Xavier Nx üzerinde geliştirilen sistemin performansı yeterli düzeyde bulgular sunmuştur. Ancak sistemin gelecekte kapsamının genişletilmesi ya da farklı gemiler üzerinde uygulanması durumunda, donanım gereksinimlerinin kapsamlı biçimde anlaşılabilmesi için alternatif gömülü platformlarla karşılaştırmalı çalışmalar yapılması önerilmektedir.
6. Geliştirilen PyQt tabanlı arayüzün gelecekte IoT tabanlı bulut sistemleriyle entegre edilmesi, şarj sürecinin uzaktan ve çok noktalı biçimde yönetilmesine olanak sağlayacaktır. Böyle bir entegrasyon, yalnızca gerçek zamanlı performans takibi, bakım planlaması ve filo yönetimi işlevlerini desteklemekle kalmayıp, aynı zamanda sistem verilerinin merkezi bir platformda toplanarak yapay zekâ tabanlı analizlere açılmasına da imkân tanıyacaktır.

KAYNAKLAR

- [1] Islam Rony, Z. et al. (2023). Alternative fuels to reduce greenhouse gas emissions from marine transport and promote UN sustainable development goals. *Fuel*, 338, 127220.
- [2] Fang, S., Wang, Y., Gou, B. and Xu, Y. "Toward future green maritime transportation: An overview of seaport microgrids and all-electric ships," *IEEE Trans Veh Technol*, vol. 69, no. 1, 207-219, 2019.
- [3] Nakkeeran, R., Bharatiraja, C., & Sanjeevikumar, P. (2025). Photovoltaic-Based Vertical Wireless Charging for Sustainable Marine Electric Systems. *Results in Engineering*, 105044.
- [4] Joung, T. H., Kang, S. G., Lee, J. K., & Ahn, J. (2020). The IMO initial strategy for reducing Greenhouse Gas (GHG) emissions, and its follow-up actions towards 2050. *Journal of International Maritime Safety, Environmental Affairs, and Shipping*, 4(1), 1-7.
- [5] Xing, H., Stuart, C., Spence, S., & Chen, H. (2021). Alternative fuel options for low carbon maritime transportation: Pathways to 2050. *Journal of Cleaner Production*, 297, 126651.
- [6] Zis, T., North, R. J., Angeloudis, P., Ochieng, W. Y., & Harrison Bell, M. G. (2014). Evaluation of cold ironing and speed reduction policies to reduce ship emissions near and at ports. *Maritime Economics & Logistics*, 16, 371-398.
- [7] Williamsson, J., Costa, N., Santén, V., & Rogerson, S. (2022). Barriers and drivers to the implementation of onshore power supply—a literature review. *Sustainability*, 14(10), 6072.
- [8] Gutierrez-Romero, J. E., Esteve-Pérez, J., & Zamora, B. (2019). Implementing Onshore Power Supply from renewable energy sources for requirements of ships at berth. *Applied Energy*, 255, 113883.
- [9] Pietzcker, R. C., Osorio, S., & Rodrigues, R. (2021). Tightening EU ETS targets in line with the European Green Deal: Impacts on the decarbonization of the EU power sector. *Applied Energy*, 293, 116914.
- [10] Yau, K. L. A., Peng, S., Qadir, J., Low, Y. C., & Ling, M. H. (2020). Towards Smart Port Infrastructures: Enhancing Port Activities Using Information and Communications Technology. *IEEE Access*, 8, 83387-83404.
- [11] DNV GL. (2019, Eylül). Maritime Forecast to 2050 - Energy Transition Outlook 2019. DNV GL Maritime. <https://www.dnv.com/maritime/publications/maritime-forecast-2050.html> adresinden 11 Temmuz 2025 tarihinde alınmıştır.
- [12] Karimi, S., Zadeh, M., & Suul, J. A. (2020). Shore charging for plug-in battery-powered ships: Power system architecture, infrastructure, and control. *IEEE Electrification Magazine*, 8(3), 47-61.

- [13] Karimi, S., Zadeh, M., & Suul, J. A. (2020). Evaluation of energy transfer efficiency for shore-to-ship fast charging systems. *IEEE International Symposium on Industrial Electronics*, 1271-1277.
- [14] Walzel, B., Hirz, M., & Brunner, H. (2019). Robot-based fast charging of electric vehicles sensor technologies for E-drive systems view project alternative propulsion technologies, new mobility concepts view project. SAE Technical Paper.
- [15] Guidi, G., Suul, J. A., Jensen, F., & Sorforn, I. (2017). Wireless charging for ships: High-power inductive charging for battery electric and plug-in hybrid vessels. *IEEE Electrification Magazine*, 5(3), 22-32.
- [16] Kumar, J., Memon, A. A., Kumpulainen, L., Kauhaniemi, K., & Palizban, O. (2019). Design and analysis of new harbour grid models to facilitate multiple scenarios of battery charging and onshore supply for modern vessels. *Energies*, 12(12), 2354.
- [17] Guo, D., Xie, L., Yu, H., Wang, Y., & Xiong, R. (2021). Electric vehicle automatic charging system based on vision-force fusion. *2021 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, 405-410.
- [18] Mutarraf, M. U., Guan, Y., Xu, L., Su, C. L., Vasquez, J. C., & Guerrero, J. M. (2022). Electric cars, ships, and their charging infrastructure - A comprehensive review. *Sustainable Energy Technologies and Assessments*, 52, 102177.
- [19] Bucher, J., Knipschild, J., & Künne, B. (2021). Development and evaluation of an automatic connection device for electric cars with four DOFs and a control scheme based on infrared markers. *International Journal of Mechatronics and Automation*, 8(4), 1.
- [20] Behl, M., DuBro, J., Flynt, T., Hameed, I., Lang, G., & Park, F. (2019). Autonomous electric vehicle charging system. *2019 Systems and Information Engineering Design Symposium (SIEDS)*, 1-6.
- [21] Hirz, M., Walzel, B., & Brunner, H. (2021). Autonomous charging of electric vehicles in industrial environment. *Tehnički glasnik*, 15(2), 220-225.
- [22] Miseikis, J., Ruther, M., Walzel, B., Hirz, M., & Brunner, H. (2017). 3D vision guided robotic charging station for electric and plug-in hybrid vehicles. *arXiv*.
- [23] Yu, A., Wang, Y., Li, H., & Qiu, B. (2023). Automatic alignment method of underwater charging platform based on monocular vision recognition. *Journal of Marine Science and Engineering*, 11(6).
- [24] Walzel, B., Hirz, M., & Brunner, H. (2022). Robust shape-based matching control of robotic conductive charging systems for electric vehicles. *Computer-Aided Design and Applications*, 19(3), 612-623.
- [25] Tadic, V. (2023). Study on automatic electric vehicle charging socket detection using ZED 2i depth sensor. *Electronics (Switzerland)*, 12(4).
- [26] Quan, P., Lou, Y., Lin, H., Liang, Z., & Di, S. (2022). Research on fast identification and location of contour features of electric vehicle charging port in complex scenes. *IEEE Access*, 10, 26702-26714.

- [27] Quan, P., Lou, Y., Lin, H., Liang, Z., Wei, D., & Di, S. (2022). Research on fast recognition and localization of an electric vehicle charging port based on a cluster template matching algorithm. *Sensors*, 22(9), 3599.
- [28] Kang, H. C., Han, H. N., Bae, H. C., Kim, M. G., Son, J. Y., & Kim, Y. K. (2021). HSV color-space-based automated object localization for robot grasping without prior knowledge. *Applied Sciences (Switzerland)*, 11(16).
- [29] Saravanakumar, S., Vadivel, A., & Ahmed, C. G. S. (2011). Multiple object tracking using HSV color space. *ACM International Conference Proceeding Series*, 247-252.
- [30] Zhang, J., Huang, K., Yu, Y., & Tan, T. (2011). Boosted local structured HOG-LBP for object localization. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1393-1400.
- [31] Li, S., et al. (2021). Detection of concealed cracks from ground penetrating radar images based on deep learning algorithm. *Construction and Building Materials*, 273, 121949.
- [32] Güney, E., et al. (2022). Electric shore-to-ship charging socket detection using image processing and YOLO. *ISMSIT 2022 - 6th International Symposium on Multidisciplinary Studies and Innovative Technologies, Proceedings*, 1069-1073.
- [33] Chaudhary, R. (2024). SD-YOLO-AWDNet: A hybrid approach for smart object detection in challenging weather for self-driving cars Expert Systems with Applications, 256, 124942.
- [34] Zhang, Z., & Yan, L. (2024). A dispatching strategy of autonomous robotic charger boats for charging electric vessels. *IEEE Transactions on Mobile Computing*, 23(11), 10429-10442.
- [35] Radovic, M., Adarkwa, O., & Wang, Q. (2017). Object recognition in aerial images using convolutional neural networks. *Journal of Imaging*, 3(2).
- [36] Zhu, H., Sun, C., Zheng, Q., & Zhao, Q. (2023). Deep learning based automatic charging identification and positioning method for electric vehicle. *CMES-Computer Modeling in Engineering and Sciences*, 136(3), 3265-3283.
- [37] Güney, E., Bayılmış, C., Çakar, S., Erol, E., & Atmaca, Ö. (2024). Autonomous control of shore robotic charging systems based on computer vision. *Expert Systems with Applications*, 238, 122116.
- [38] Pan, M., Sun, C., Liu, J., & Wang, Y. (2020). Automatic recognition and location system for electric vehicle charging port in complex environment. *IET Image Processing*, 14(10), 2263-2272.
- [39] Mahaadevan, V. C., Narayanamoorthi, R., Gono, R., & Moldrik, P. (2023). Automatic identifier of socket for electrical vehicles. *IEEE Access*. 11.
- [40] Quan, P., Lou, Y., Lin, H., Liang, Z., Wei, D., & Di, S. (2023). Research on identification and location of charging ports of multiple electric vehicles based on SFLDLC-CBAM-YOLOv7-Tinp-CTMA. *Electronics*, 12(8), 1855.
- [41] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.

- [42] Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
- [43] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [44] O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint*.
- [45] Zou, Z., Chen, K., Shi, Z., Guo, Y., & Ye, J. (2023). Object detection in 20 years: A survey. *Proceedings of the IEEE*, 111(3), 257-276.
- [46] Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, I-I.
- [47] Felzenszwalb, P. F., Girshick, R. B., McAllester, D., & Ramanan, D. (2010). Object detection with discriminatively trained part-based models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(9).
- [48] Khanam, R., Hussain, M., Hill, R., & Allen, P. (2024). A comprehensive review of convolutional neural networks for defect detection in industrial applications. *IEEE Access*.
- [49] Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1, 5000.
- [50] Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision*, 1440-1448.
- [51] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks.
- [52] Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint*.
- [53] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015). You only look once: Unified, real-time object detection. *arXiv*.
- [54] Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. *arXiv*.
- [55] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). Ssd: Single shot multibox detector. In *Lecture Notes in Computer Science*, 9905, 21-37.
- [56] Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollar, P. (2017). Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 318-327.
- [57] Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., & Zagoruyko, S. (2020). End-to-end object detection with transformers. In *Proceedings of the European Conference on Computer Vision (ECCV)*, 213-229.
- [58] Zhu, X., Su, W., Lu, L., Li, B., Wang, X., & Dai, J. (2020). Deformable detr: Deformable transformers for end-to-end object detection. *arXiv preprint*.

- [59] Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2016). Feature pyramid networks for object detection. *arXiv*.
- [60] Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4), 99.
- [61] Güney, E., Bayılmış, C., & Cakan, B. (2022). Corrections to “an implementation of real-time traffic signs and road objects detection based on mobile GPU platforms”. *IEEE Access*, 10, 103587-103587.
- [62] Güney, E., & Bayılmış, C. (2022). An implementation of traffic signs and road objects detection using faster R-CNN. *Sakarya University Journal of Computer and Information Sciences*, 5(2), 216-224.
- [63] CooVally_AI. (2024). YoloV8 model overview: Architecture, training, and deployment. *CSDN Blog*.
- [64] Guney, E., Bayilmis, C., & Cakan, B. (2022). An implementation of real-time traffic signs and road objects detection based on mobile GPU platforms. *IEEE Access*, 10, 86191-86203.
- [65] Bie, M., Liu, Y., Li, G., Hong, J., & Li, J. (2023). Real-time vehicle detection algorithm based on a lightweight you-only-look-once (YOLOv5n-L) approach. *Expert Systems with Applications*, 213.
- [66] Zhu, L., Geng, X., Li, Z., & Liu, C. (2021). Improving yolov5 with attention mechanism for detecting boulders from planetary images. *Remote Sensing*, 13(18).
- [67] Zhang, J., Qian, S., & Tan, C. (2022). Automated bridge surface crack detection and segmentation using computer vision-based deep learning model. *Engineering Applications of Artificial Intelligence*, 115.
- [68] Varghese, R., & Sambath, M. (2024). Yolov8: A novel object detection algorithm with enhanced performance and robustness. In *2024 International conference on advances in data engineering and intelligent computing systems (ADICS)*, 1-6.
- [69] Solawetz, J., & Francesco. (2024). What is YOLOv8? A complete guide. *Roboflow Blog*.
- [70] Zhang, Y., Wang, C., Wang, X., Zeng, W., & Liu, W. (2020). FairMOT: On the fairness of detection and re-identification in multiple object tracking. *Journal of Vision*, 111(4).
- [71] Wang, Z., Zheng, L., Liu, Y., Li, Y., & Wang, S. (2019). Towards real-time multi-object tracking. *arXiv*.
- [72] Zhou, X., Wang, D., & Krähenbühl, P. (2019). Objects as points. *arXiv*.
- [73] Wang, G., Song, M., & Hwang, J. N. (2022). Recent advances in embedding methods for multi-object tracking: A survey. *arXiv*.
- [74] Zhang, Y., Sun, P., Jiang, Y., Yu, T., Weng, F., & Yuan, Z. (2021). ByteTrack: Multi-object tracking by associating every detection box. *arXiv*.
- [75] Du, Y., Zhang, Y., Liu, Y., Zhao, Y., & Li, H. (2022). StrongSORT: Make DeepSORT great again. *IEEE Transactions on Multimedia*, 25, 8725-8737.

- [76] Aharon, N., Orfaig, R., & Bobrovsky, B.-Z. (2022). BoT-SORT: Robust associations multi-pedestrian tracking. *arXiv*.
- [77] Cao, J., Pang, J., Weng, X., Khirodkar, R., & Kitani, K. (2023). Observation-centric SORT: Rethinking SORT for robust multi-object tracking. *arXiv*.
- [78] Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Houlsby, N. (2021). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv*.
- [79] Zhao, Y., Sun, P., Wang, X., Yu, D., Zhang, Y., & Yuan, Z. (2024). DETRs beat YOLOs on real-time object detection. *arXiv*.
- [80] Sapkota, R., Cheppally, R. H., Sharda, A., & Karkee, M. (2025). RF-DETR object detection vs YOLOv12: A study of transformer-based and CNN-based architectures for single-class and multi-class greenfruit detection in complex orchard environments under label ambiguity. *arXiv*.
- [81] Prasad, D. K., Rajan, D., Rachmawati, L., Rajabally, E., & Quek, C. (2017). Video processing from electro-optical sensors for object detection and tracking in a maritime environment: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 18(8), 1993-2016.
- [82] Parico, A. I. B., & Ahamed, T. (2021). Real time pear fruit detection and counting using YOLOv4 models and deep SORT. *Sensors*, 21(14), 4803.
- [83] Zhang, G., Yin, J., Deng, P., Sun, Y., Zhou, L., & Zhang, K. (2022). Achieving adaptive visual multi-object tracking with unscented Kalman filter. *Sensors*, 22(23), 9106.

ÖZGEÇMİŞ

Ad-Soyad : Emin GÜNEY

ÖĞRENİM DURUMU:

- **Lisans** : Sakarya Üniversitesi / Mühendislik Fakültesi / Bilgisayar Mühendisliği
- **Yüksek lisans** : Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Bilgisayar Mühendisliği
- **Doktora** : Sakarya Üniversitesi/ Bilgisayar Mühendisliği Anabilim Dalı/ Bilgisayar Mühendisliği
- **Doktora sırası araştırma** : Arizona State University/ Ira A. Fulton Schools of Engineering/ Computer Engineering

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2023-2025 yılları arasında, TÜBİTAK 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında doktora öğrenimi süresince bursiyer olarak desteklenmiştir.
- 2024-2025 yılları arasında TÜBİTAK 2214-A Yurt Dışı Doktora Sırası Araştırma Burs Programı kapsamında, ABD’de Arizona State University (ASU)’de 1 yıl süreyle araştırma yapma imkânı sağlayan bursu kazanmıştır.

TEZDEN TÜRETİLEN ESERLER:

- Güney, E., Bayılmış, C., Çakar, S., Erol, E. ve Atmaca, Ö. (2024). Autonomous control of shore robotic charging systems based on computer vision. *Expert Systems with Applications*, 238, 122116.
- Güney, E., Sahin, I. H., Çakar, S., Atmaca, O., Erol, E., Doganli, M. ve Bayılmış, C. (2022). Electric shore-to-ship charging socket detection using image processing and YOLO. *International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 1069-1073.

DİĞER ESERLER:

- Güney, E., Altın, H., Aşçı, A. E., Bayılmış, O. U. ve Bayılmış, C. (2024). YOLO-based personal protective equipment monitoring system for workplace safety. *JITSI: Jurnal Ilmiah Teknologi Sistem Informasi*, 5(2), 77-85.
- Güney, E., Sisman, H. İ. ve Bayılmış, C. (2024). A real-time tracking system for bread production based on YOLOv8 and DeepSORT. *International Conference on Advanced Engineering, Technology and Applications (ICAETA)*, 1-6.
- Güney, E., Bayılmış, C. (2024). YOLOv5-based driver behavior monitoring system for safer roads on Jetson Xavier Nx. *International Conference on Advanced Engineering, Technology and Applications (ICAETA)*, 1-5.
- Eishorafa, M., Güney, E., Pehlivan, İ. ve Bayılmış, C. (2024). Design and implementation of remote lab PID controller experiment based on IoT. *Sakarya University Journal of Computer and Information Sciences*, 7(2), 277-288.
- Güney, E., Yaşar, A., Ağırtaş, G. ve Bayılmış, C. (2023). Mobil platformda IoT temelli ve soket programlamaya dayalı termal sensör uygulaması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(1), 457-465.
- Dereli, S., Okuyar, M. ve Güney, E. (2023). A conceptual system proposal for real-time detection of jellyfish density in coastal areas from UAV images. *Erciyes Üniversitesi Fen Bilimleri Dergisi*, 39(2), 293-303.
- Güney, E., Bayılmış, C. ve Çakan, B. (2022). Corrections to “An implementation of real-time traffic signs and road objects detection based on mobile GPU Platforms”. *IEEE Access*, 10, 103587.
- Güney, E., Bayılmış, C. ve Çakan, B. (2022). An implementation of real-time traffic signs and road objects detection based on mobile GPU platforms. *IEEE Access*, 10, 86191-86203.
- Güney, E., Bayılmış, C. (2022). An implementation of traffic signs and road objects detection using faster R-CNN. *Sakarya University Journal of Computer and Information Sciences*, 5(2), 216-224.
- Güney, E., Ceylan, N. (2022). Response times comparison of MongoDB and PostgreSQL databases in specific test scenarios. *International Congress of Electrical and Computer Engineering*, 178-188.
- Güney, E., Ağırtaş, G. ve Bayılmış, C. (2022). MongoDB based real-time monitoring heart rate using websocket for remote healthcare. *JITEKI: Jurnal Ilmiah Teknik Informatika*, 10(1), 1-9.
- Ceylan, N., Kaçar, S., Güney, E. ve Bayılmış, C. (2022). Detection of grinding burn fault in bearings by squeeze net. *30th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Uzun, S., Güney, E. ve Bingöl, B. (2022). U-Net mimarisi ile beyin tümörü MRI görüntülerinin segmentasyonu. *El-Cezeri Fen ve Mühendislik Dergisi*, 9(4), 1583-1590.
- Güney, E. (2021). Sürücü asistan sistemleri için mobil GPU tabanlı gerçek zamanlı durum analizi ve tespit uygulamaları (Yüksek Lisans Tezi). *Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya*.