

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

**BAĞIMSIZ HAREKETLİ HAVA ARAÇLARI İÇİN
KONUMLANDIRMA SİSTEM TASARIMI**

DOKTORA TEZİ

MURAT EKİCİ

DENİZLİ, OCAK - 2023

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



**BAĞIMSIZ HAREKETLİ HAVA ARAÇLARI İÇİN
KONUMLANDIRMA SİSTEM TASARIMI**

DOKTORA TEZİ

MURAT EKİCİ

DENİZLİ, OCAK - 2023

Bu tez çalışması Pamukkale Üniversitesi tarafından 2020FEBE046 nolu proje ile desteklenmiştir.

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

MURAT EKİCİ

ÖZET

BAĞIMSIZ HAREKETLİ HAVA ARAÇLARI İÇİN KONUMLANDIRMA SİSTEM TASARIMI

DOKTORA TEZİ

MURAT EKİCİ

PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: PROF. DR. CEYHUN KARPUZ)

(EŞ DANIŞMAN: DOÇ. DR. AHMET ÇAĞDAŞ SEÇKİN)

DENİZLİ, OCAK - 2023

İnsansız hava araçlarının ve özellikle dronların hava içerisinde stabil hareket etmelerine yönelik bilim insanlarının yoğun çalışmaları, bu sorunun büyük oranda üstesinden gelinmesini sağlamıştır. Açık ve kapalı alanda GPS'den bağımsız navigasyon sistemleri, günümüz bilim insanlarının üzerinde fazlaca vakit harcadığı bir çalışma alanı haline gelmiştir. Bu çalışmada, ArUco markerlarla görsel odometri kullanan bir hava aracının, anlık topladığı görüntülere dayalı konumlandırmayı yüksek başarımla yapabildiği gösterilmeye çalışılmıştır. Konumlandırma başarımlarının hesaplanabilmesi için CoppeliaSim simülasyon programında bir simülasyon ortamı hazırlanmıştır. Kapalı alan simülasyonu olarak bir depo alanı tasarlanmıştır. Depo alanının etrafına ve alanın ortasına bir dizi toplamda 27 adet raf yerleştirilmiştir. Simülasyonda toplam 27 rafın her biri 6x6'lık ArUco tipi etiket kullanılarak etiketlenmiştir. ArUco etiketlerinin konumları her rafın sağ üst köşesine yerleştirilmiş ve numaralama saat yönünün tersi yönde yapılmıştır. Simülasyon ortamında hava aracının hareketi esnasında, aracın konum, atalet ölçüm birimleri (Inertial Measurement Units-IMU) ve kamera bilgileri alınmaktadır. Kameradan alınan görüntüden, artırılmış gerçeklik (Augmented Reality-AR) etiketlerinin varlığı tespit edilmiş ve etiket ID'sine göre etiketin var olup olmadığı, etiketin kameradaki piksel cinsinden koordinatları ve etiketin alanı hesaplanmıştır. Bu veriye ek olarak hava aracının pusula bilgisi de alınmaktadır. Hava aracının gerçek konum bilgisi ise makine öğrenmesi tahminlemesinde çıkış değeri olarak kullanılmak üzere alınmaktadır. Her konum verisi için bir regresyon modeli oluşturulmuştur. Regresyon modelleri ile hava aracının kamerasının AR etiketleri gördüğü her yerde anlık konum ve poz tahmini üretilmiş ve hata değeri hesaplanmıştır. Hava aracının konum bilgileri olan x, y, z ve poz bilgisi olan γ açısı regresyon tahminleri ile gerçek değerlerin ilişkisi hakkında bilgi veren R^2 performans değerleri hesaplanmıştır. Kullanılan öğrenme algoritmaları için scikit-learn kütüphanesinden faydalanılmış olup varsayılan alt parametreler kullanılmıştır. Uygulanan algoritmalar arasında konumlandırma için en yüksek x değeri tahmininde 0,991 ile AdaBoost, en yüksek y değeri tahmininde 0,976 ile AdaBoost, en yüksek z değeri tahmininde 0,979 ile AdaBoost ve en yüksek Theta değeri tahmininde de ise 0,816 değeri ile AdaBoost algoritması vermiştir. Mevcut konumlandırma ve poz tahmininde elde edilen R^2 metriğine göre AdaBoost algoritması ile yapılan tahmin sonuçlarının daha yüksek olduğu görülmüştür.

ANAHTAR KELİMELER: ArUco; depo; dron; görsel referans işaretçisi; kapalı alan; konumlandırma; lojistik.

ABSTRACT

POSITIONING SYSTEM DESIGN FOR INDEPENDENT MOVING AIRCRAFT

DOKTORAL THESIS

MURAT EKİCİ

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE

ELECTRICAL AND ELECTRONICS ENGINEERING

(SUPERVISOR:PROF. DR. CEYHUN KARPUZ)

(CO-SUPERVISOR:DOÇ. DR. AHMET ÇAĞDAŞ SEÇKİN)

DENİZLİ, JANUARY 2023

Intensive work of scientists on the stable movement of unmanned aerial vehicles and especially drones in the air has largely overcome this problem. Indoor and outdoor GPS (Global Positioning System)-independent navigation systems have become a field of study on which today's scientists spend a lot of time. In this study, we tried to show that an aircraft using visual odometry with ArUco markers can perform localization based on instantaneous images with a high success rate. A simulation environment has been prepared in the CoppeliaSim simulation program to calculate the success rate of the localization. A warehouse space is planned as a closed space simulation. A series of racks are placed around the warehouse area and in the middle of the area, for a total of 27. In the simulation, each of the 27 racks in total is labeled using a 6x6 ArUco type label. ArUco labels are located at the upper right corner of each rack and are numbered counterclockwise. During the movement of the aircraft in the simulation environment, the location, IMU (Inertial Measurement Units) and camera information of the aircraft are obtained. From the image taken from the camera, the presence of augmented reality (AR) Tags are detected and the presence of the AR Tag, the coordinates of the AR Tag in pixels on the camera, and the area of the AR Tag is calculated according to the AR Tag ID. In addition to this data, the compass information of the aircraft is also taken. The actual location information of the aircraft is taken to be used as the output value in machine learning estimation. A regression model has been created for each location data. With the regression models, present location and pose estimates are produced in each region where the aircraft's camera saw AR Tags and the error value is calculated. R^2 performance values, which give information about the relationship between the x, y, z and γ angle regression estimates, which are the position information of the aircraft, and the actual values, were calculated. The scikit-learn library was used for the learning algorithms used and the default sub-parameters were used. Among the algorithms applied, AdaBoost gave 0.991 for the highest x value estimation for positioning, AdaBoost for 0.976 for the highest y value estimation, AdaBoost for 0.979 for the highest z value estimation, and AdaBoost for 0.816 for the highest theta value estimation. Based on the R^2 metric obtained in the current positioning and pose estimation; It has been seen that the prediction results are higher with the AdaBoost algorithm.

KEYWORDS: ArUco; drone; indoor; logistics; positioning; virtual fiducial marker; warehouse.

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	vi
TABLO LİSTESİ	vii
SEMBOL LİSTESİ	viii
ÖNSÖZ	x
1. GİRİŞ	1
1.1 Tezin Önemi	1
1.2 Tezin Amacı.....	3
1.3 Literatür Özeti.....	3
2. HAVA ARAÇLARI	11
2.1 Uçma Kavramı.....	11
2.1 Uçuş Prensiplerine Göre Hava Araçları.....	12
2.1.1 Havadan Hafif Hava Araçları	12
2.1.1.1 Balon	13
2.1.1.2 Hava Gemisi (Blimp-Zeplin).....	13
2.1.2 Havadan Ağır Hava Araçları	15
2.2 Kanat Yapısına Göre Hava Araçları	15
2.2.1 Sabit Kanatlı Hava Araçları	15
2.2.2 Döner Kanatlı.....	16
2.2.2.1 Helikopter	16
2.2.2.2 Dron.....	17
2.2.3 Çırpan Kanatlı Hava Araçları	17
2.3 Kullanılan Güç Sistemlerine Göre Hava Araçları	18
2.3.1 Motorsuz Hava Araçları.....	18
2.3.2 Motorlu Hava Araçları	18
2.4 Tasarım Şekline Göre Hava Araçları.....	19
2.4.1 Hibrit	19
2.5 Kontrol Tipine Göre Hava Araçları	19
2.5.1 İnsanlı Hava Aracı	19
2.5.2 İnsansız Hava Aracı (İHA)	19
3. KONUMLANDIRMA SİSTEMLERİ	21
3.1 Kapalı Alan Ve Gps Engelli Durum Konumlandırma.....	22
3.2 Kapalı Alan Mutlak Konumlandırma	23
3.2.1 Radyo Alan Kuvvetini Kullanan Yöntemler.....	24
3.2.2 Radyo Dalgası Varış Zamanı Gecikmesini Kullanan Yöntemler	24
3.2.3 RFID Kullanan Yöntemler.....	24
3.3 Kapalı Alan Görsel Mutlak Konumlandırma	25
3.3.1 Arttırılmış Gerçeklik Etiketleri (ARUco Marker).....	26
3.4 Kapalı Alan Göreceli Konumlandırma	29
3.5 Kapalı Alan Göreceli Görsel Konumlandırma	30
4. KONUMLANDIRMA YÖNTEMLERİ VE SENSÖR TİPLERİ	32
4.1 Manuel Hesaplama	32
4.2 Yıldızlara Bakarak – Sekstant	33

4.3 Mesafe Sensörleri	33
4.3.1 Ses Sensörleri.....	33
4.3.2 Duyulabilir Ses – Mikrofon/Mikrofonlar.....	34
4.3.3 Ultrasonik Sensörler.....	34
4.3.4 Kapasitif Sensörler.....	34
4.3.5 Endüktif Sensörler	35
4.3.6 Manyetik Sensörler	35
4.3.7 RFID Proximity Sensörler	36
4.3.8 RF Radar	37
4.3.9 Mikrodalga–UWB.....	37
4.3.10 Lidar (Light Detection and Ranging).....	38
4.4 Eylemsizlik (Atalet) Sensörleri.....	38
4.4.1 İvmeölçer (Akselerometre)	38
4.5 Açısal Sapma Ölçüm Sensörleri	41
4.5.1 Jiroskop- Gyroscope-Gyro.....	41
4.5.2 Pusula-Manyetometre	42
4.6 Kameralar	43
4.6.1 Tek Ve Çift (Mono Ve Stereo) Kamera Sistemleri	43
4.6.2 Çok Yönlü (Omnidirectional) Kamera Sistemleri	45
4.6.3 Olay Kamera Sistemleri	46
4.7 Ataletsel Seyrüsefer.....	47
4.7.1 INS (Inertial Navigation System)	47
4.7.1.1 Gimbaled Ins Ve Strapdown Ins.	50
4.7.1.2 Imu (Inertial Measurement Unit)	51
4.8 Görsel Odometri	52
4.8.1 Görüntü ve Görüntü İşleme	52
4.8.1.1 RANSAC İle Homografi Hesaplanması	57
4.8.2 Optik Akış (Optical Flow)	60
4.8.2.1 Pearson Korelasyon Katsayısı (r).....	62
5. YÖNTEM.....	63
5.1 Kullanılan Simülasyon Programı CoppeliaSim.....	63
5.2 Simülasyon Ortamı ve Veri Toplama.....	65
5.3 Referans İşaretçilerinin Algılanması ve Simülasyon Ortamına Yerleştirilmesi.....	67
5.4 Makine Öğrenmesi Algoritmaları ve Regresyon.....	69
5.5 Regresyon Algoritmaları	70
5.5.1 K En Yakın Komşular.....	70
5.5.2 Adaptive Boosting	71
5.5.3 Rastgele Orman (Random Forest)	71
5.5.4 XGBoost (Extreme Gradient Boosting).....	72
5.5.5 Yapay Sinir Ağları-Çok Katmanlı Algılayıcı (Multilayer Perceptron)	72
5.6 Performans Değerlendirme ve Model Seçimi.....	73
5.7 Depo Gezme ve Raf Doluluk Algılama Algoritması.....	74
6. BULGULAR	77
6.1 Veri Toplama Bulguları ve Kanıtları.....	77
6.1.1 X Ekseninde Konumlandırma.....	77
6.1.2 Y Ekseninde Konumlandırma.....	78
6.1.3 Z Ekseninde Konumlandırma	79
6.1.4 Theta Poz Tahmini (YAW Açısı)	80

6.2 Mevcut Sistemler ile Karşılaştırma	81
6.3 Depo Gezinti ve Raf Doluluk Algılama	82
7. SONUÇ VE ÖNERİLER.....	85
8. KAYNAKLAR.....	87
9. EKLER.....	102
EK A Homography Matrisinin Çıkartılmasında Kullanılan Kodlar	102
EK B 10DOF IMU Verilerinin Anlık Olarak Ekranı aktarılması.....	107
EK C Drone Üzerinden IMU Verilerini Okumak İçin Tasarlanan Sistem..	108
EK D İç mekan ArUco tespit çalışmaları	110
EK E Açık Alan ArUco Tespit Çalışmaları	112
EK F ArUco Marker'in Kamera Tarafından Tespit Edilmesi ve Markerin Kamera Odağına Olan Uzaklığının Ölçülmesi	113
10. ÖZGEÇMİŞ.....	115

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1:	Hava araçlarında kullanılan navigasyon sistemleri (Güner, 2012).....	5
Şekil 1.2:	Dünyanın Manyetik ve Coğrafik Kutupları (68137984.png (494×380), t.y.)	5
Şekil 1.3:	GPS Uydu Dizilimi (GPS Sistemi Nasıl Çalışır?, 2016).	7
Şekil 2.1:	Blimp-Zeplin (“Hava gemisi”, 2022).....	14
Şekil 2.2:	Autogyro (“Döner kanatlı hava aracı”, 2020).	16
Şekil 3.1:	Sık kullanılan ArUco Marker türleri.	26
Şekil 3.2:	ArUco Etiket Algılama.....	27
Şekil 4.1:	a) Bir kuvvete maruz kalmamış accelerometer, b) Bir kuvvete maruz kalmış accelerometer.	39
Şekil 4.2:	Üç ekseninde ivme ölçme mantığı.	40
Şekil 4.3:	X ve Y eksenlerinde meydana gelen ivmenin ölçülmesi.	40
Şekil 4.4:	Dünyaya göre bir platformun gyrolar aracılığıyla açısız sapma miktarının sens edilmesi.	42
Şekil 4.5:	Açısız sapmaya maruz kalmış accelerometerların durumu.....	42
Şekil 4.6:	Monocular Odometry.	43
Şekil 4.7:	İkili Görme.	44
Şekil 4.8:	Derinlik Haritası I.....	44
Şekil 4.9:	Derinlik Haritası II.	44
Şekil 4.10:	Çok Yönlü Kamera Sistemleri.	45
Şekil 4.11:	Aynalı Çok Yönlü Kamera Görüntüsü.....	45
Şekil 4.12:	Strapdown Inertial Navigation System Blok yapısı.	47
Şekil 4.13:	INS Blok Şeması.	50
Şekil 4.14:	a) Gimbaled INS, b) Strapdown INS.	51
Şekil 4.15:	Tipi Bir IMU’ nun Bileşenleri.....	52
Şekil 4.16:	Optik akış örneği I.....	61
Şekil 4.17:	Optik akış örneği II.	62
Şekil 4.18:	Gerçek zamanlı Optical Flow.....	62
Şekil 5.1:	Kapalı alan simülasyon ortam görüntüleri.	66
Şekil 5.2:	Sık kullanılan ArUco Marker türleri [48].....	67
Şekil 5.3:	ArUco etiket algılama.	68
Şekil 5.4:	Makine öğrenmesi ve görsel referans işaretleyiciler ile anlık konumlandırma sistemi.	70
Şekil 5.5:	Envanter sayım programı akış şeması.	75
Şekil 5.6:	Envanter sayımı işlem adımları ekran görüntüleri.	76
Şekil 6.1:	X Ekseni AdaBoost makine öğrenme algoritması tahminlemesi.....	78
Şekil 6.2:	Y Ekseni Adaboost makine öğrenme algoritması tahminlemesi.	79
Şekil 6.3:	Z Ekseni AdaBoost makine öğrenme algoritması tahminlemesi.	80
Şekil 6.4:	Theta poz tahmini AdaBoost makine öğrenme algoritması tahminlemesi.	81
Şekil 6.5:	ArUco Marker’in kamera tarafından tespit edilmesi ve dronun konumlandırılması için gerekli dataların alınması.	83

TABLO LİSTESİ

Sayfa

Tablo 1.1: Navigasyon destek sistemleri.....	10
Tablo 2.1: Hava araçları sınıflandırması (Durmus, 2020).....	12
Tablo 4.1: SINS ve GINS'in karşılaştırılması (Noureldin ve diğ., 2013 ^b).....	51
Tablo 5.1: Regresyon için performans metrikleri.....	74
Tablo 6.1: X eksenini AdaBoost makine öğrenme performansı.....	77
Tablo 6.2: Y eksenini AdaBoost makine öğrenme performansı	79
Tablo 6.3: Z eksenini AdaBoost makine öğrenme performansı	80
Tablo 6.4: Theta poz tahmini AdaBoost makine öğrenme performansı.....	81
Tablo 6.5: Sistemlerin dron hareket alanına bağlı olarak yaptıkları hata miktarı ..	82

SEMBOL LİSTESİ

AIDC	:	Otomatik Tanımlama ve Veri Yakalama
AR	:	Agumented Reality
ArUco Marker	:	Arttırılmış Gerçeklik Etiketleri
BRIEF	:	Binary Robust Independent Elementary Features
BRISK	:	Binary Robust Invariant Scalable Keypoints
C	:	Concensus Set
CENSURE	:	Center Surround Extremas for Realtime Feature Detection and Matching
DGPS	:	Differential GPS
DLT	:	Doğrudan Doğrusal Dönüşüm
DME	:	Distance Measuring Equipment
DRONE	:	Gyrocopter, helikopter ve multikopter
EKF	:	Geliştirilmiş Kalman Filtresi
FAST	:	Features From Accelerated Segment Test
FREAK	:	Fast Retina Keypoint
GALILEO	:	Galileo Galilei
GINs	:	Gimballed INS
GLONASS	:	GLOBal'naya NAVigatsiyonnaya SPutnikovaya Sistema
GNSS	:	Global Navigation Satellite System
GPS	:	Global Positioning System
GRASP	:	General Robotics, Automation, Sensing and Perception Lab.
GYRO	:	Gyroscope
ILS	:	Instrument Landing System
IMU	:	Inertial Measurement Unit
INS	:	Inertial Navigation System
İHA	:	İnsansız Hava Aracı
KNN	:	K-Nearest Neighbors
LIDAR	:	Light Detection and Ranging
MAE	:	Mean Absolute Error
MLP	:	MultiLayer Perceptron
MSE	:	Mean Square Error
MSER	:	Efficient Maximally Stable Extremal Region
ORB	:	Oriented FAST and Rotated BRIEF
RANSAC	:	Random Sample Consensus
RF	:	Radyo Frekans
RFID	:	Radio Frequency Identification
RLG	:	Ring Laser Gyroscope
SIFT	:	Scale Invariant Feature Transform
SINS	:	strapdown INS
SİHA	:	Silahlı İnsansız Hava Aracı
SLAM	:	Simultaneous Localization And Mapping
SURF	:	Speed Up Robust Features
SUSAN	:	Smallest Univalued Segment Assimilating Nucleus
TACAN	:	Tactical Air Navigation
UWB	:	Ultra Geniş Bant
VFM	:	Virtual Fiducial Marker

VICON : Motion Systems Ltd
VOR : VHF Omni Directional Radio-Range System
VSLAM : Simultaneous Localization And Mapping
VTOL : Vertical TakeOff and Landing

ÖNSÖZ

Öncelikle tez konusunu seçerken ülkemizin stratejik planlarını ve isteklerimi göz önünde bulundurup bana yardımcı olan tez danışmanım Prof. Dr. Ceyhun KARPUZ hocama, doktora ilk başladığım günden itibaren her aradığımda her an ulaşılabilir olan Dr. Öğr. Üyesi Ahmet ÖZEK hocama, tez çalışmam sırasında çıkmaz sokaklara girmeme engel olan, tezin son halini almasında benimle birlikte an be an çalışan eş danışman Doç. Dr. Ahmet Çağdaş SECKİN hocama sonsuz minnet duygusuyla teşekkürlerimi sunarım. Tez çalışmam süresince kıymetli bilgi ve fikirlerini benimle paylaşarak, çalışmamın sonuçlanmasında değerli katkılar sağlayan tez izleme komitesi üyesi Prof. Dr. M. Fevzi KÖSEOĞLU hocama teşekkür ederim. Tez izleme komitesi üyesi olup tez çalışmam sırasında hakkın rahmetine kavuşan değerli hocam Prof. Dr. Veysel KUZUCU hocamı da saygıyla anmak isterim. Mekanı cennet olsun. Tezin sonuçlanması için gerekli kaynak ihtiyacımıza destek olan Pamukkale Üniversitesi BAP birimine ayrıca teşekkür etmek isterim.

Doktora başladığım günden itibaren ve tez sürecinde benden desteğini bir an bile esirgemeyen, isimlerini sayamayacağım, değerli arkadaşlarıma ve tüm öğretim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen her zaman yanımda olan sevgili aileme teşekkürlerimi bir borç bilirim.

1. GİRİŞ

1.1 Tezin Önemi

Günümüzde küresel sivil hava trafiği baş döndürücü bir büyüklüğe ulaşmıştır. Teknolojik gelişmeler, ülkelerin hava savunma ve saldırı sistemlerini de çağın gereklerine uygun hale getirmesini zaruri kılmıştır. Konvansiyonel hava savunma sistemlerinin, uzun menzilli alçak, orta, yüksek seviye saldırı füze sistemlerinin, insansız hava araçlarının, silahlı insansız hava araçlarının, otonom özelliği kazandırılmış drone ve robotik sistemler gibi platformların görevlerini tam olarak yerine getirebilmeleri için kesin doğrulukta çalışan, dışarıdan müdahalelere kapalı bir navigasyon sistemine ihtiyaçları vardır.

Literatür taraması yapıldığında görülmektedir ki günümüz robotik, sivil ve askeri havacılık alanında çalışmalar yapan bilim insanlarının nihai hedefi; kendi platformu üzerinde, dış ortamdan tamamen yalıtılmış, bir noktadan bir noktaya navigasyonu kesin kararlılıkta hesaplayabilen ve böylece rotayı belirleyebilen bir sistem tasarlamaktır.

Türkiye'nin savunma ve havacılık sanayiinde, çeşitli iddialı projeler bulunmaktadır. Bunlar arasında savaş uçağı, askeri helikopter, helikopter motoru, savaş gemisi, denizaltı, tank, tank güç grubu, hava savunma füze sistemleri, zırhlı muharebe araçları, uydu ve uydu fırlatma sistemi, silahlı insansız hava araçları (İHA), İHA motorları ve tanksavar füze sistemleri yer alır.

Türkiye, ana sistem seviyesinde projelerin gerçekleştirilmesi için yeteneklere sahip olarak, dışa bağımlılıkta oluşabilecek güvenlik risklerini azaltmak amacıyla kritik alt sistem, hammadde ve malzemelerinin yurt içinde geliştirmeyi ve aynı zamanda alt sistem seviyesinde özgün ürünler üretmeyi hedeflemektedir.

Firmaların tedarik bölümleri, sadece hazır malzeme satın almakla yetinmezler, aynı zamanda alt yüklenicilere parça ve alt sistem tasarım ve üretimi için hizmet verirler. Son zamanlarda, ana yüklenici firmaların tedarik bölümleri, "Tedarik ve

Sanayileşme Bölümleri" adı altında organize edilmeye başlamıştır. Bu yolla hem tedarik sürecinde üretim ve maliyetleri azaltmak hem de sanayi bölgesinde yerli üretimi teşvik etmek hedeflenmektedir.

Milli savunma ve havacılık sanayisinin gelişmesi ve derinleşmesi; yurt dışı tedarikin ilk maliyet ve uzun vadeli lojistik destek maliyetleri dikkate alındığında çok pahalı olmasının yanı sıra, daha birçok risk içerir. Bunlar arasında; kritik alt sistemlere (örn: görev bilgisayarı, güç grubu) kullanım kısıtlaması yapılması, bu sistemler aracılığı ile bilgi transferi yapılma riski, gerektiğinde lojistik desteğin kesilebilmesi ile ülkenin güvenliğinin etkilenmesi ve ihraç edilen ana sistemlerde kullanılan kritik alt sistemler ve hammaddelerin tedarik edildiği ülkelerin ihracat kısıtlamasına gitme riski gibi sebeplerdir. Yurt içi tedarik, maliyetleri daha az olmasının yanı sıra milli güvenlik açısından daha elverişli bir seçenek olmaktadır.

Ülkemizin güvenliği ve ekonomisi açısından önem taşıyan savunma ve havacılık sanayisinin gelişimini sağlamak için, firmaların tedarik bölümlerinin güçlendirilmesi önemlidir. Bu ihtiyacı karşılamak için, nitelik ve nicelik yönünden geliştirilmeli, sanayi derinleşerek tabana yayılmalı ve teknolojik olarak da derinleştirilmelidir. Bu şekilde, ülkenin güvenliği için hayati bir konu olan savunma ve havacılık sanayisi, hem ulusal güvenlik açısından önemli bir sektör haline gelir hem de ulusal ekonomi açısından stratejik bir sektör olarak öne çıkar.

Son 15-20 yıl içinde, savunma ve havacılık sanayimizde, özellikle ana yüklenici firmalarımıza, ana sistem projelerinin yurt içinde gerçekleştirilmesi sorumluluğu verilmiştir. Bu sayede Türk Silahlı Kuvvetleri'nin ihtiyaçlarının yaklaşık %65 oranında yurt içi katkı payı ile karşılanması sağlanmıştır. Kendi kendine yetebilme düzeyine hızla ilerleyen ülkemizin, yerli kaynaklar kullanarak gerçekleştirdiği sistem tasarımı ve geliştirmedeki payı her geçen gün hızla artmaktadır.

Özellikle savunma sanayimiz için önem arz eden karadan karaya, karadan havaya, havadan havaya, havadan karaya fırlatılabilen roketlerin hedeflerini tam olarak tespit edebilmeleri, yerli imkânlarla üretilen hava araçlarımızın seyrüsefer görev bilgisayarlarının gerçekleştirilebilmesi için yerli imkânlarla üretilmiş navigasyon sistemlerine ihtiyaçları vardır.

1.2 Tezin Amacı

Görülmektedir ki milli sivil ve askeri araçlarımızı yerli bilgi birikimi ve teknolojimizi kullanarak gerçekleştirebilmek, gelişmekte olan ulusal havacılık ve savunma sanayimizin önündeki en büyük engellerden birisidir. Hava araçlarında kullanılan elektronik ekipmanların tasarım ve yazılımlarına müdahale edememek, bu araçların görevlerini ifa ederken ne doğrulukta görev yapacaklarını kestirememek demektir. Bu sebeple bu tür platformlarda kullanılan elektronik sistemlerin yerli imkânlar ile üretilmesi ve yazılımlarının yine yerli imkânlarla gerçekleştirilmesi büyük önem arz etmektedir.

Bu tez çalışmasında bir hava aracına GPS' den tam bağımsız hareket edebilme kabiliyeti katmak amaçlanmıştır. Günümüzün stratejik gereksinimleri, barış zamanında dost olan ülkelerin teknolojik imkanlarını kullanmaya olanak sağlarken, savaş zamanında ülkelerin savunma ve saldırı kabiliyetleri o ülkenin milli imkanları ölçüsündedir. Bu nedenle barış dışı zamanlarda da kullanılabilir, bir hava aracına dış sistemlerden bilgi alışverişinde bulunmadan navigasyon yaptırabilecek bir seyrüsefer sistemi tasarlamak yıllardan beri bilim insanlarının çalışma sahası olmuştur. Türkiye'deki teknolojik gelişmeler ülkemizin dünyadaki saygınlığını arttırırken dostta güven düşmana ise korku vermektedir. Ülkemizin havacılık sektöründeki ve hava aracı üretimindeki kabiliyeti hergeçen gün artmaktadır. Milli savaş uçağımızı yapmaya başladığımız bu günlerde temel aviyonik sistemlerin vaz geçilmezi olan navigasyon sisteminin her şart, ortam ve zamanda çalışabilir olması büyük önem arz etmektedir. Bağımsız çalışabilen bir navigasyon sisteminin havaaraçlarımıza özgürlük katacağı unutulmamalıdır. Bu tezde böyle bir sistemin hayata geçirilmesi amaçlanmıştır.

1.3 Literatür Özeti

Geçmişten günümüze kadar insanoğlunun keşfetme arzusu her geçen gün katlanarak artmıştır. İnsanoğlu; gözünün görebildiği her yere ulaşabilmeyi amaç edinmiş bir canlı olarak, keşfetme arzusunu hayata geçirebilmek için bir yerden başka bir yere gitmek ve tekrar başlangıç noktasına dönebilmesi gerektiğini ilk başta fark etmiştir. Bu sebeple ilk çağlardan beri insanlar bu konu üzerinde çok uzun süreler çalışmıştır.

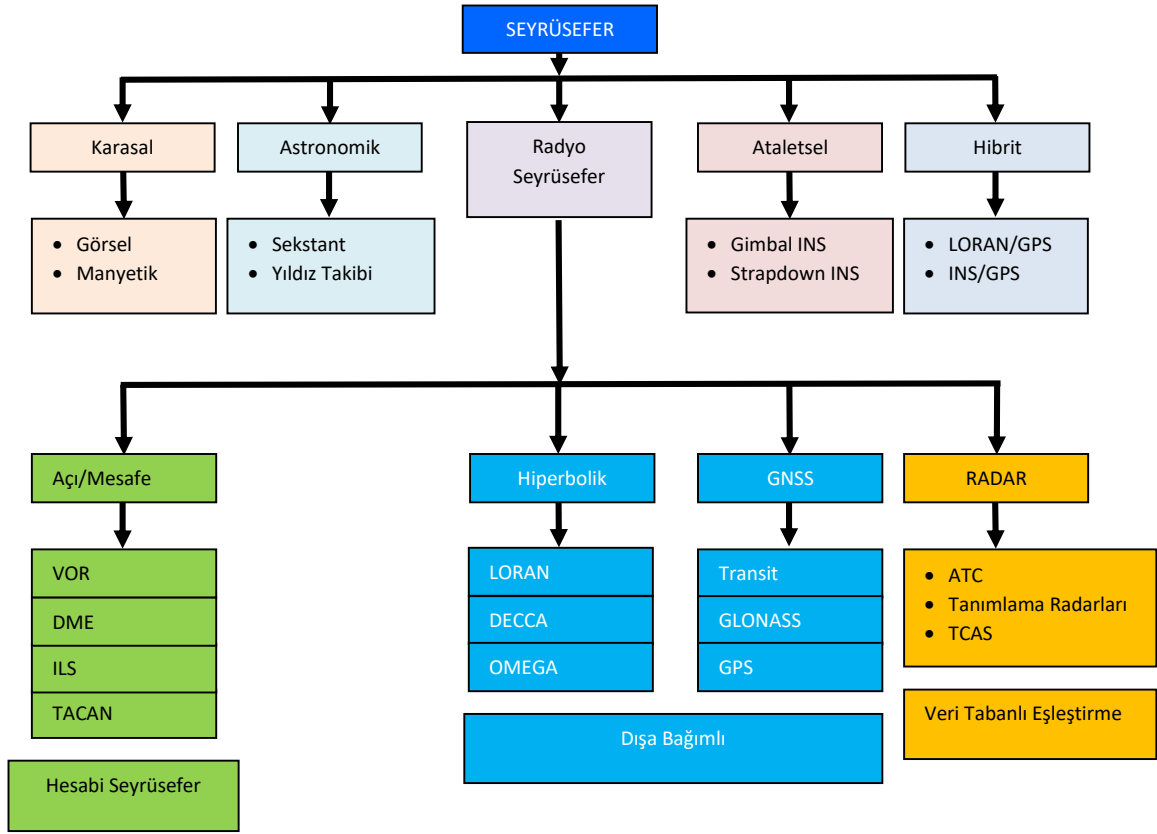
Navigasyon kelimesi latince seyahat (deniz seyahati) anlamına gelen “navigare” kelimesinden gelmektedir. Gemi anlamına gelen “navi” ve sürmek anlamına gelen “agere” kelimelerinden türetilmiştir (Bekir, 2007; Noureldin ve diğ., 2012) . Bir yerden başka bir yere güvenli bir biçimde gidebilmek için en uygun rotayı belirleme ve bu rotayı takip edebilme işi navigasyon (Navigation-Seyrüsefer-Rota Tayini) olarak tanımlanabilir. Navigasyon aynı zamanda kısaca yön bulmak olarak da tarif edilebilir.

Elbette en kolay navigasyon görerek yapılan navigasyondur. Belirli bir nokta belirlenir. O noktaya ulaşabilmek için beş duyu organından biri olan görme duyusundan faydalanılır. Belirli nirengi noktaları belirlenerek hedefe ulaşılması için gereken rota çizilebilir. Ancak görme duyumuzun sınırları, açık denizde, havada, uzayda, ışığın ulaşamadığı yerlerde ve gece şartlarında görerek navigasyon gerçekleştirmemize engel teşkil eder. Oysa asıl amacımız bu ortamlarda da navigasyonu gerçekleştirebilmektir.

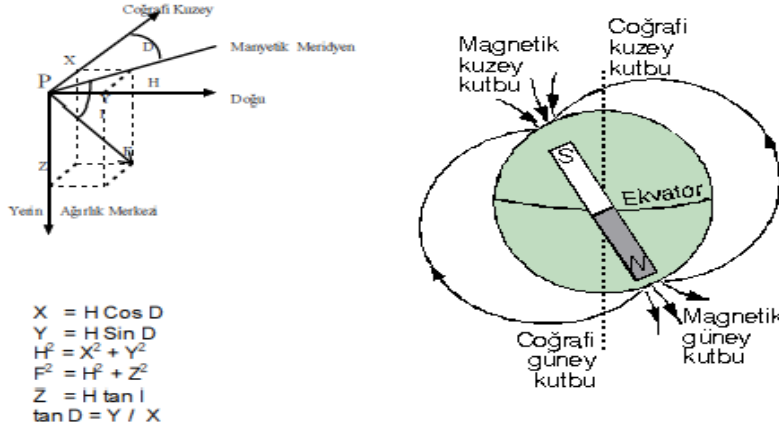
Görünen belirli noktaları referans alarak, bir yerden başka bir yere belirli bir rota çizerek gidip, başlangıç noktasına geri dönebilmek Kara Navigasyonu (Land Navigation), deniz taşıtları için Deniz Navigasyonu (Marine Navigation), hava taşıtları için Hava Navigasyonu (Air Navigation), uzay boşluğunda gerçekleştirilen navigasyon için Uzay Navigasyonu (Space Navigation) tanımlamalarını doğurmuştur.

Günümüz hava taşıtları için hava navigasyonu en önemli konulardan biridir. Şekil 1.1’de de görüleceği gibi bir hava taşıtı için birçok navigasyon uygulaması aynı platform üzerinde münferit ya da birlikte çalışır halde bulunmaktadır (Güner, 2012). En klasik yöntem manyetik pusulalar kullanarak, haritalar yardımıyla gerçekleştirilen navigasyondur ki dünyanın manyetik alan çizgilerinden faydalanarak çalışır.

Dünyanın ekvator çizgisi etrafında manyetik alan çizgilerinin yeryüzüne paralel uzandığı varsayıldığında yerkürenin manyetik kuzey bilgisini doru bir biçimde gösterebilir. Ancak kutup bölgelerine yaklaşıldıkça manyetik alan çizgileri yeryüzünün kutup bölgelerine doğru eğilerek yeryüzüne olan paralelliklerini kaybederler. Bu durum doğru bir manyetik kuzey istikametinin belirlenmesini güçleştirir. Ayrıca Şekil 1.2’de görüleceği gibi manyetik kuzeyin tespit edilmesi, coğrafik kuzey tespiti için başka hesaplamalarında yapılmasını zorunlu kılar.



Şekil 1.1: Hava araçlarında kullanılan navigasyon sistemleri (Güner, 2012).




Şekil 1.2: Dünyanın Manyetik ve Coğrafik Kutupları (68137984.png (494×380), t.y.).

Bütün bunlara rağmen hava araçlarında zorunlu bir standart olarak hala kullanılmakta olan manyetik pusula, acil durumlarda navigasyon için gerekli yön bilgisini sağlamaya devam eden, vaz geçilmesi kolay olmayan bir sistem olarak önemini hala korumaktadır.

Hava araçlarında en yaygın kullanılan bir diğer navigasyon yöntemi ise radyo navigasyon yöntemidir. Kendi içerisinde birkaç türü mevcuttur. VOR (VHF Omni Directional Radio-Range System), DME (Distance Measuring Equipment), VOR/DME, ILS (Instrument Landing System), TACAN (Tactical Air Navigation) (Winick ve Brandewie, 1970), GNSS (Global Navigation Satellite System), GPS (Global Positioning System), GLONASS (GLOBal'naya NAVigatsiyonnaya Sputnikovaya Sistema), GALILEO (Galileo Galilei). Bu sistemlerin güvenilir çalışmaları test edilmiştir. En zorlu görevler yüklenmiş hava araçlarında en yaygın kullanılan radyo navigasyon yöntemleridir.

VOR, DME, ILS, TACAN gibi sistemler, hava araçlarının navigasyonlarında güvenilir şekilde kullanılabilir (Winick & Brandewie, 1970). Bu sistemlerin temel çalışma prensibi; yeryüzüne yerleştirilmiş radyo vericilerinden yayınlanan radyo yayınlarının hava araçlarında bulunan alıcılar tarafından tespit edilmesi ve değerlendirilmesi yöntemine dayanır. Yani yeryüzünde yerleşik halde bulunan bu radyo vericilerinin çalışır halde olması gerekmektedir. Barış zamanında bu istasyonların çalışır olması garanti edilebilirken, savaş zamanlarında çalışır olmaları garanti edilemez. Bu durum hava araçları için navigasyonun gerçekleştirilememesi anlamını taşır.

GNSS, GPS, GLONASS, GALILEO navigasyon sistemleri günümüzde hemen hemen her türlü platformda en yaygın kullanılan, hassasiyeti en yüksek navigasyon yöntemleridir. Örneğin GPS yeryüzünden 20187 Km yüksekliğe yerleştirilmiş 24 adet uydudan oluşur. Bunlardan 21 tanesi aktif 3 tanesi yedek olarak bulundurulur. Tüm küresel navigasyonun tamamı neredeyse bu sistem üzerinden yapılır. GPS uydu dizilimini Şekil 1.3'te görüldüğü gibidir. Uydu sistemlerini kullanarak yapılan navigasyonun da avantaj ve dezavantajları mevcuttur. GPS alıcılarının küçük boyutlu, düşük maliyetli ve düşük enerji ihtiyaçları en büyük avantajlarını oluştururken, GPS uydu işleticisi ülkelerin istendiğinde GPS sinyallerini manipüle edebilmeleri, sinyalleri zayıflatabilmeleri bu sistemleri kullanan kullanıcılar için büyük bir dezavantaj oluşturmaktadır.



Şekil 1.3: GPS Uydu Dizilimi (GPS Sistemi Nasıl Çalışır?, 2016).

GPS, günümüzde hemen hemen tüm askeri ve sivil platformların tamamında en güvenilir navigasyon sistemi olarak kullanılmaya devam etmektedir. Ancak askeri sistemlerin GPS den bağımsız navigasyon yapabilmesi için araştırmacılar hala çalışmalarını sürdürmektedir. Özellikle kapalı alanlardaki GPS sinyal zayıflığı ya da yokluğu, sadece askeri değil aynı zamanda sivil navigasyon uygulamalarının da GPS den bağımsız hale getirilmesini daha da önemli yapmaktadır.

INS (Inertial Navigation System) ise yukarıda saydığımız sistemlerin tamamen dışında platform üzerinde kendi kendine hava aracının kinematikini kullanarak navigasyonun gerçekleştirilmesini sağlayan bir yöntemdir. Bunun için hava aracının her üç ekseninde ivmelenmesini sens eden 3 adet accelerometer ve yine her üç ekseninde sapma miktarını sens eden 3 adet laser gyroscopedan faydalanılır (Noureldin ve diğ., 2013^c, 2013^a).

Navigasyon sistemlerinde son yıllarda gerçekleşen büyük ilerlemeler, öncelikle teknoloji ve araç-gereç-aygıt bazında gerçekleşmiştir. Örneğin, GPS gibi dünya çapında uydu sistemleri, yerli veritabanları, hız sensörleri, yerçekimi sensörleri gibi aygıtlar ve yazılım teknolojileri ile navigasyon sistemleri çok daha hassas ve güvenilir hale gelmiştir. Bu ilerlemeler, araç veya taşıma aracının konumunun belirlenmesi, yönünün takip edilmesi ve ileriye dönük navigasyon için önemli bir rol oynamaktadır.

Ancak, yöntemsel açıdan baktığımızda, yüzyıllar öncesinde gemilerin kullandığı seyrüsefer teknikleri ve günümüzde kullanılan navigasyon sistemleri arasında çok büyük bir fark yoktur. Hala, rotayı belirlemek için kullanılan referans noktaları geometrik olarak aynıdır. Önceki yüzyıllar için bu doğal referans noktaları güneş, ay ve yıldızlar iken, günümüzde bu referans noktaları dünya çapında uydu sistemleri olarak kullanılmaktadır. Bu nedenle navigasyon sistemleri yöntemsel olarak hala aynı geometrik temellere dayanmaktadır. Bildiğimiz navigasyon sistemleri kör seyir sistemleri, dışa bağımlı sistemler ve veritabanı eşleme sistemleri olarak üçe ayrılabilir (Ekütekin, 2007; Güner ve diğ., 2013^a; Siouris, 2004).

GPS (Global Positioning System) navigasyon sistemi, dünya çapında çalışan uydu sistemiyle çalışır ve her yerde (kapalı alanlar ve denizin altı hariç) navigasyon yapmayı olanaklı kılar. Ancak, GPS sistemi bazı durumlarda karıştırılabilir veya kullanılamayabilir. Bu durumlarda, alternatif navigasyon yöntemleri kullanılabilir. GPS hatalarının zamandan bağımsız olmasından dolayı, alternatif navigasyon yöntemleri de zamandan bağımsız olmalıdır. Örneğin, dünya çapında uydu sistemi olan GLONASS, Galileo gibi sistemler kullanılabilir. Ancak bu sistemlerin de kullanım alanları sınırlıdır ve tüm dünyada navigasyon yapmayı olanaklı kılamazlar. GPS sisteminin karıştırılmasına karşı çeşitli yöntemler bulunmaktadır. Bu yöntemler arasında, DGPS (Differential GPS) ve Geosenkron uydu ağı gibi uydu tabanlı alternatifler, RF (Radio Frequency) yöntemleri ve inertial navigasyon sistemleri gibi araç-gereç-aygıt tabanlı alternatifler sayılabilir. Ancak, bu yöntemler de karıştırmaya dayanıklı olmadıkları için sınırlı bir etkililiğe sahiptirler.

Yer konuşlu radyo navigasyon sistemleri, alternatif navigasyon yöntemlerinden biridir ve uydu sistemlerine alternatif olarak kullanılabilirler. Bu sistemler, VOR (Very High Frequency Omni-directional Range), NDB (Non-Directional Beacon) ve TACAN (Tactical Air Navigation) gibi yer konuşlu radyo istasyonlarını kullanırlar. Bu sistemler, navigasyon için hız, yön ve konum bilgilerini sağlar. Ancak, yer konuşlu radyo navigasyon sistemleri, eski altyapıların idame ve hassasiyet problemleri ile karşı karşıyadırlar.

Arazi destekli seyrüsefer (terrain aided navigation), uydu sistemlerine alternatif olarak kullanılabilir. Bu sistemler, arazi özelliklerini ve yükseklik verilerini kullanarak navigasyon yapar. Bu sistemler özellikle seyir füzelerinde ve bazı uçak ve

helikopterlerde kullanılmaktadır. Arazi destekli seyrüsefer sistemleri, görev planlaması, arazinin öznitelikleri, yüksek işlem gücü gereksinimi ve donanım ihtiyacı gibi özel problemlere sahiptir. Özellikle, kullanılan arazi verilerinin doğruluğu ve güncelliği sistemin etkililiği açısından önemlidir (Ekütekin, 2007; Güner ve diğ., 2013^b; Siouris, 2004).

Navigasyon sistemlerinin bir kısmında karşımıza çıkan en büyük sorun mesafe ölçümüne sürekli olarak ihtiyaç duymalarıdır. Mesafe ölçümü için kullanılan her yöntem, platformun başka bir takipçi tarafından tespit ve imha edilmesine de olanak sağlar. Bu nedenle günümüzde kullanılan navigasyon sistemlerinde pasif sistemlere yönelmek bir zorunluluk haline gelmiştir.

Konum güncelleme teknikleri arasında, pasif yöntemler ve aktif yöntemler olmak üzere iki yöntem mevcuttur. Pasif yöntemler, konumun belirlenmesi için mesafe ölçümüne ihtiyaç duymazken, aktif yöntemler mesafe ölçümüne ihtiyaç duyarlar.

Pasif yöntemler arasında;

- Kalman filtreleri kullanılarak gerçekleştirilen konum güncelleme
- Dead Reckoning (DR) yöntemi ile gerçekleştirilen konum güncelleme
- Inertial Navigation Systems (INS) kullanılarak gerçekleştirilen konum güncelleme
- Vision-based navigation sistemi ile gerçekleştirilen konum güncelleme gibi yöntemler sayılabilir.

Aktif yöntemler arasında;

- Radar-based navigation sistemi ile gerçekleştirilen konum güncelleme
- LiDAR-based navigation sistemi ile gerçekleştirilen konum güncelleme
- Ultrasonic-based navigation sistemi ile gerçekleştirilen konum güncelleme gibi yöntemler sayılabilir.

Pasif yöntemler genellikle daha az güç tüketir ve daha az maliyetlidir, ancak daha az hassas olabilir. Aktif yöntemler ise daha hassas sonuçlar verebilir ancak daha yüksek maliyetlidirler.

Doğru, mesafe ölçümü için sinyal yayıcılarından RF (Radio Frequency) sinyal almak veya sinyal yayıcılara olan mesafeyi ölçmek için lazer mesafe ölçer kullanmak, platformun ve sinyal kaynaklarının düşman tarafından tespitini kolaylaştırabilir. Bu

yüzden, düşman tesbit cihazları tarafından çok uzak mesafelerden algılanabilen RF v.b. gibi yayınım yapan sistemler yerine sinyal yayıcıların sadece kızılötesi bantta ışığa yapan sistemler olması öngörülmüştür. Çeşitli navigasyon destek sistemlerinin özellikleri Tablo 1.1’de verilmiştir (Güner ve diğ., 2013^a).

Tablo 1.1. Navigasyon destek sistemleri.

Navigasyon Sistemi/Yöntemi	Karıştırmaya Dayanıklılık	Küresel/Bölgesel	Yayın Kontrolü	Hava Şartları Etkisi	GNSS Karıştırıldığında Göreve Devam Edebilme	Tipik Hassasiyet	Füzelerdeki Kullanım
DME/TACAN	Orta	Bölgesel	Platform Aktif	Önemsiz	Evet	~500 Metre	İlave Donanım Gerektirir
VOR	Orta	Bölgesel	Platform Pasif	Önemsiz	Evet	1,5-4 İstikamet Açısı	İlave Donanım Gerektirir
Hiperbolik Navigasyon	Orta/Yüksek	Bölgesel	Platform Pasif	Önemsiz	Evet	0,25-1 Knot	İlave Donanım Gerektirir. Konum doğruluğu ve
Yıldız Destekli Seyrüsefer	Yüksek	Küresel	Platform Pasif	Ağır, açık gökyüzü gereksinimi.	Evet	0,2-1 Knot	İlave Donanım Gerektirir.
TAN/TERCON	Yüksek	Bölgesel	Radar Altimetre Aktif	Önemsiz	Evet	Arazi benzersizliği ve düzlüğüne bağlı olarak	Radar Altimetre gerektirir.
Yer Konuşlu Bilinen Nokta Ağı	Yüksek	Bölgesel	Platform Pasif	Görüş menziline bağlı	Evet	Sinyal yayıcılarının döşeme paternine bağlı	İlave donanım gerektirmez.

Radyo dalgaları kullanılarak yapılan navigasyon sistemleri aşağıdaki üç yönteme göre sınıflandırılabilir.

- Kablosuz baz istasyonunun radyo alan gücünü kullanarak geliştirilen yöntemler (Bahl ve Padmanabhan, 2000; Yamada ve diğ., 2007).
- Kablosuz baz istasyonunun ve radyo dalgası gelme zamanında gecikmeyi kullanan yöntemler (Mogi ve Ohtsuki, 2008).
- RFID kullanarak geliştirilen yöntemler (Yamashita ve diğ., 2002).

Bu sistemlerde, ölçüm için radyo dalgasının kullanılmasının konum tahmininde bir doğruluk sınırına sahip olduğu da bilinmektedir.

2. HAVA ARAÇLARI

2.1 Uçma Kavramı

İnsanoğlu var olduğu günden itibaren, gökyüzünden etkilenmiştir. Gökyüzünde gördüğü yıldızlara ulaşmak istemiş, başının üstünde uçan kuşlar gibi uçabilmeyi hayal etmiştir. En eski efsanelerden, Yunan miolojisine kadar birçok yerde uçma kavramı karşımıza çıkmaktadır. Uçmakla ilgili en eski efsane Daidalos ve oğlu İkarusla ilgili olandır. Daidalos ve oğlu İkarus Girit'te bir labirentin içine hapsedilirler. Labirentten kurtulabilmek için Daidalos'un aklına dahice bir fikir gelir. Kuşların dökülen tüylerini toplayıp, balmumundan hazırladığı bir karışımla birleştirerek uçabilecekleri kanatlar imal eder. Oğlu İkarusa bu kanatlarla uçarken çok yükselip güneşe yaklaşmamasını aksi halde balmumunun eriyerek tüylerin döküleceğini, çok alçaktan uçmamasını bu durumda da denizin neminin balmumunu bozarak tüylerin dağılacağını söyler. Ancak İkarus, uçmanın coşkusuyla yükseldikçe yükselir. Güneş ışınları balmunu eritir. Tüyler dökülür, İkarus denize düşerek gözden kaybolur.

Tarihte, özellikle 16. yüzyılda insanların ağaçtan kirişleri bezle kaplayarak, kuşların kanatlarına benzer giyilebilir yapılar aracılığıyla uçma girişimleri olmuştur. Kuşların uçuş dinamikleriyle ilgili ilk bilimsel çalışmaları, filozof, ressam ve bir bilim adamı olan Leonardo Da Davinci yapmıştır. Kendisi, insanların kuşları taklit ederek uçabileceklerine inanmış, bunu gerçekleştirebilecek mekanizmalar üzerinde çalışmıştır.

Sıcak havanın soğuk havadan daha hafif olduğu bilimsel gerçeğini ilk hayata geçirenler ise Joseph ve Etienne Montgolfier kardeşler olmuştur. 18. Yüzyılın sonlarına doğru bezden yapılmış ve üzeri kağıt ile kaplanmış ilk sıcak hava balonunu uçurmayı başarmışlardır.

İskeleti aleminyum olan ve pamukla kaplanmış, üzerine ilave edilmiş iki adet motor marifetiyle hava içerisinde kontrol edilebilen bir araç imal eden alman Ferdinand Graf Von Zeppelin, havadan hafif gazlarla doldurulmuş cisimlerin hava içerisinde kontrol edilebilirliğini göstermiştir.

Wilbur ve Orville Wright kardeşler, çocukluklarından itibaren uçma konusu ile ilgilenmiş iki bisiklet tamircisi kardeştir. İlk defa havadan daha ağır bir cismin, hava içerisinde tutunması ve bu cismin hava içerisinde kontrol edilebilmesiyle ilgili temel çalışmaları yapmışlardır. Modern havacılık tarihinin bu kardeşlerin yapmış olduğu çalışmalarla başlamış olduğu kabul edilmektedir.

Hava araçlarını sınıflandırmak için birçok veri kullanılabilir. En genel geçer sınıflandırma yöntemi hava aracının havadan ağır mı? Yoksa hafif mi? olduğuyula ilgili olan sınıflandırmadır. Hava araçlarının sınıflandırmasına örnek teşkil edebilecek bir sınıflandırma Tablo 2.1’de verilmiştir.

Tablo 2.1. Hava araçları sınıflandırması (Durmus, 2020).

Uçuş Prensibine Göre	Kanat yapısına Göre	Güç Sisteminin varlığına Göre	Güç Sistemi Tipine Göre	Uçuş Hızına Göre	Kullanım Amacına Göre	İniş/Kalkış Yaptığı Yere Göre	Kontrol Tipine Göre
Havadan Ağır	Sabit kanatlı	Motorlu	Piston Motorlu	Subsonic	Askeri	Kara	İnsanlı
	Döner Kanatlı		Turbo Prop	Transsonic			
	Değişken Kanatlı	Motorsuz	Turbo Jet	Süpersonic	Sivil	Deniz	İnsansız
Havadan Hafif	Çırpın Kanatlı		Turbo Fan	Hipersonic	Hibrit	Amfibik	
	Hibrit		Elektrik Motorlu				
			Hibrit				

2.1 Uçuş Prensibine Göre Hava Araçları

2.1.1 Havadan Hafif Hava Araçları

Uluslararası Sivil Havacılık Teşkilatı, hava aracını atmosfer içinde tutunabilen ve yeryüzünden etkilenmeyen bir makine olarak tanımlar. Amerikan Federal Havacılık Dairesi ise hava aracını havada uçmak amacıyla kullanılan bir cihaz olarak tanımlar.

Türk Sivil Havacılık Mevzuatına göre ise hava aracı, havalanabilen ve havada seyredebilme yeteneğine sahip her türlü araç olarak tanımlanır. Bu tanımların tamamı da doğrudur, lakin hava aracını tanımlayan birinci ifade, hava aracının temel çalışma prensibini ortaya koyan bilimsel bir tanımdır.

Havadan hafif hava aracı havada tutunabilme prensibi olan aerostatik prensibi kullanarak yükselen ve havada kalabilen bir hava aracıdır. Bu prensip, kapalı hacmindeki yerini aldığı havadan daha hafif, ısıtılmış hava veya gaz kullanarak gerçekleşir. Havadan hafif hava aracı türleri arasında en yaygın olanlar balonlar ve hava gemileridir. Bu tür hava araçlarına aynı zamanda aerostat adı da verilmektedir.

2.1.1.1 Balon

Balonlar, motorsuz, batmazlık prensibinden yararlanarak havada tutunabilen havadan hafif gazlarla doldurulmuş hava araçlarıdır. Serbest ve bağlı olmak üzere iki gruba ayrılırlar. Serbest balonlar, içerisindeki sıcak havanın veya gazın yoğunluğuna bağlı olarak olabildiğince yükselebilirler ve rüzgârın etkisiyle kalkış noktalarından farklı noktalara serbestçe hareket ederler.

Bir sıcak hava balonunun üç ana elemanı vardır. Bunlar;

- Sıcak havanın muhafaza edildiği kubbe ki zarf olarak adlandırılır.
- Sepet; pilot, yolcular veya yükün taşınabilmesini sağlayan yapı.
- Kaldırma kuvvetinin oluşması için kubbe içerisine doldurulmuş havanın ısıtılmasını sağlayan yakıcıdır.

Bağlı balonlar ise yeryüzüne bir şekilde sabitlenmiş sıcak hava balonlarıdır. Bunlar sabitlendikleri için hava içerisinde rüzgârla birlikte rastgele şekilde hareket edemezler.

2.1.1.2 Hava Gemisi (Blimp-Zeplin)

Arşimed prensibi de denen batmazlık prensibinden yararlanarak havada tutunabilen hava araçları vardır. Suyu batırılan bir cisme, cismin kendi ağırlığını dengeleyen

yukarı yönlü bir kuvvet etki eder. Suyu batırılan bir cisim, kendi hacmine eşit miktarda suyu taşırır. Bu taşınan suyun bir ağırlığı vardır. Cismin ağırlığını dengeleyen kuvvetin şiddeti suya batırılan cismin taşıdığı suyun ağırlığına eşittir. Tüm deniz taşıtları da aynı prensipten yararlanarak suda yüzerler.

Havadan hafif hava araçları aerostatik prensibi kullanarak havada uçarlar. Bu prensip, hava için de su için geçerli olan prensip gibi çalışır. Aerodinamik, hava ve hava taşıtlarının hareketleri ve bu hareketlerin sonucu oluşan kuvvetlere odaklanan bir bilim dalıdır. Aerodinamik kuvvetler, hava aracının hızı, şekli ve yapısı gibi faktörlerle etkilenir ve hava aracının hareketini kontrol etmek için gereken kuvvetleri sağlar.

Hava gemileri, batmazlık prensibinden yararlanarak havada tutunabilen, motorları vasıtasıyla hava içinde yönlendirilebilen havadan hafif hava araçlarıdır. Hava gemilerinin; Esnek, yarı rijit ve tam rijit olmak üzere üç farklı türü vardır. Esnek hava gemilerinin içine doldurulan gaz zarfının, şekillendirilmesini sağlar. Yarı rijit hava gemilerinde zarfın alt tarafında bir iskelet yapı vardır. Bu yapı gondol adı verilen yolcu kabinin daha büyük yapılmasına ve motorların zarfa bağlanmasına imkân verir. Rijit hava gemilerinde zarfın tamamının iskeleti vardır. Şekil 2.1’de bir zeplin görülmektedir.



Şekil 2.1. Blimp-Zeplin (“Hava gemisi”, 2022).

2.1.2 Havadan Ağır Hava Araçları

Özel olarak tasarlanmış kanat kesitinden geçen havanın, kanat kesitinin üst ve altında meydana getirdiği basınç farkıyla kaldırma kuvveti oluşturarak havalanabilen araçlar havadan ağır hava araçları olarak tanımlanabilir. Bu araçların taşıma prensibi Bernoulli Prensibi etkisinin doğal sonucudur. Bu hava araçlarının yükselebilmesi için belirli bir hızda hareket etmeleri gerekir. Havada tutunmanın kaynağı hızdır. Hız olmasa havadan ağır hava araçları havada kalamazlar. Bu tür hava araçlarının havalanabilmesi için havada tutunmalarını sağlayacakları hıza ulaşınca kadar karada uzunca bir yola ihtiyaçları vardır.

2.2 Kanat Yapısına Göre Hava Araçları

2.2.1 Sabit Kanatlı Hava Araçları

Sabit kanatlı hava araçları; tasarlanmış kanat şeklinin yardımıyla ileri doğru hareket ederek elde edilen hava süratinin yarattığı kaldırma kuvveti ile havada hareket edebilen hava araçlarıdır. Bu bakımdan döner kanatlı hava aracından ayrılırlar. Uçak olarak adlandırılan hava araçlarının yapıları, sabit kanatlı hava araçlarını tam olarak tarif eder. Bu hava araçlarındaki kanatlar gövdeye farklı noktalardan sabitlenebilir. Sabit kanatların gövdeye bağlanma şekline ve gövdedeki sayısına bağlı olarak birçok farklı sabit kanatlı hava araçlarından bahsetmek mümkündür.

Kanatın şekline göre; dikdörtgen, paralelkenar, trapez, dik trapez, ters dik trapez, eliptik, üçgen, delta, kırlangıç, hiperbolik kanat olarak adlandırılan türleri mevcuttur. Uçaktaki üst üste kanat sayısına göre, tek kanat, çift kanat, üç kanatlı v.b. tipleri vardır. Kanadın uçak üzerindeki sabitlenme noktasına göre ise; üstten kanatlı, ortadan ve alttan kanatlı hava araçları olarak adlandırılan üç türü, günümüz hava araçlarında kullanılmaktadır.

2.2.2 Döner Kanatlı

Döner kanatlı hava aracı, rotor adı verilen kanat benzeri elemanlarla havada tutunabilme özelliğine sahip bir havadan ağır hava aracıdır. Bu kanat benzeri yapıların herbiri pal, tamamı ise pervane olarak adlandırılır. Pervanenin bağlandığı rotorlar, motor tarafından döndürülen bir şaftta yer alır. Döner kanatlı hava aracının büyüklüğüne göre kullanılan motor sayısı ve türü de değişkenlik gösterir. Helikopter, Autogyro (Otocayro) ve Cayrodin gibi türleri mevcuttur. Şekil 2.2’de bir otocayro görülmektedir.



Şekil 2.2. Autogyro (“Döner kanatlı hava aracı”, 2020).

2.2.2.1 Helikopter

Helikopter, döner kanatlı hava aracı olarak dünyada en yaygın olarak kullanılan türlerden biridir. Helikopter, Türk Sivil Havacılık Mevzuatına göre, belli bir piste ihtiyaç duymadan karada ve denizde bir noktaya inebilen, motor gücü ile seyreden, havadan ağır hava aracı olarak tanımlanmaktadır. Helikopterlerin, yerde hareket etme kabiliyetleri sayesinde çok esnek bir taşıma aracıdır ve özellikle, kara araçlarına erişimin zor olduğu bölgelerde çok fazla kullanılır. Bu tür hava araçları dikey olarak kalkış yapıp, dikey olarak iniş gerçekleştirebildikleri için Vertical TakeOff and Landing (VTOL) araçlar olarak adlandırılırlar. Helikopter, motor tarafından tahrik edilen rotorları sayesinde havada tutunabilen ve ileriye doğru hareket edebilen, piste

ihtiyaç duymadan kalkış ve iniş yapabilen döner kanatlı bir hava aracıdır. Gyrocopter, helikopter ve multikopter (Drone) olarak adlandırılan türleri en yaygın olarak bilinen türleridir.

2.2.2.2 Dron

Bir tür döner kanatlı hava aracı olup, aracın kontrol ve hareketi için çok sayıda kanat şaftı kullanan hava aracı türleridir. Aracın iniş/kalkışı ve hava içerisinde hareketi için pervaneler açışal olarak hareket ettirilir. Bu hava araçlarının 4, 6, 8, 12, 16 ve/veya daha çok sayıda pervane grubuna sahip olanları mevcuttur. Pervanelerin döndürülmesini sağlayan elektrik motorları için gerekli güç dron üzerinde taşınan elektrik bataryalarından sağlanır. Günümüzde geliştirmek için bilim insanlarının üzerinde en fazla zaman harcadığı hava aracı budur. Kontrol ve stabilizasyonları son on yılda büyük gelişme göstermiştir. Bu tür hava araçlarının Mikro ölçekte yapılanlarının yanı sıra, çok daha ağır yükleri taşıyabilecek büyüklükte imal edilenleri de mevcuttur.

Günümüzde sağlık, ticaret, lojistik, turizm, reklam, arama-kurtarma, haritacılık, madencilik, meteoroloji, ziraat gibi daha sayamayacağımız kadar çok alanda kullanımı mevcut olan dronlar, yakın bir gelecekte hayatımızın ayrılmaz parçası olacaklardır.

2.2.3 Çırpan Kanatlı Hava Araçları

Kuşları ve kanatlı böcekleri taklit ederek, geliştirilmiş hava araçlarıdır. Tıpkı onlar gibi uçabilmek için kanat çırpma hareketine ihtiyaç duyan hava araçlarıdır. Bu hareket sayesinde kaldırma kuvveti oluşturarak hava içerisinde hareket eedebilirler. İnsan kas gücüyle çalışanları olduğu gibi elektrik motoruyla çalışan türleri de mevcuttur. Daha çok deneysel ve hobi amaçlar için üretilmiş minyatür hava araçlarıdır.

2.3 Kullanılan Güç Sistemlerine Göre Hava Araçları

2.3.1 Motorsuz Hava Araçları

Planörler ve uçurtmalar havadan ağır ve motorsuz hava araçlarıdır. Planörlerin uçuşu, bir başka araç tarafından çekilmesiyle başlatılır veya kendilerine bağlı olan bir kabloyla çekilmesiyle havalandırılır. Havalandıktan sonra planörler, hava akımlarından yararlanarak yükselir. Uçurtma ise, insan yapımı en eski hava aracıdır, yüzeyinde oluşan tahrik kuvvetleri sayesinde havada kalabilir. Planörler ve uçurtmalar havada uçmak için motora ihtiyaç duymazlar, sadece hava akımlarından yararlanırlar.

2.3.2 Motorlu Hava Araçları

Hava aracının havada tutunmasını sağlamak için gerekli gücün bir motor aracılığıyla üretildiği hava araçları motorlu hava aracı olarak adlandırılabilir. Çok farklı tipte motor, hava araçlarında kullanılır. En bilineni ise pistonlu motorlardır. Pistonlu motor, kendisine bağlı bir pevane grubunu istenilen hızda dönderir. Bu sayede bir çekiş gücü üretililerek hava aracına hız kazandırılır. Kanat kesitinin sağladığı kaldırma kuvveti ile hava aracı hava içerisinde hareket ettirilir. Uçak olarak adlandırılan sabit kanatlı hava araçlarının ilk icadından günümüze kadar kullanılan motor türüdür. İkinci dünya savaşı yıllarında Jet motorlarının icadının ardından, sivil hava araçlarında ve savaş uçaklarında jet motor kullanımı yaygınlaşmıştır. Turboprop Motorlar, Turboshaft Motorlar, Turbojet Motorlar, Turbofan Motorlar, Termojet Motorlar günümüz hava araçlarında kullanılan farklı motor türleri olarak karşımıza çıkar. Batarya sistemlerindeki hızlı gelişme, elektrik motorlarının da hava araçlarında kullanımını arttırmıştır. Kısa mesafe uçan, düşük faydalı yük miktarına sahip hava araçlarında, kontrol kolaylığı ve bakım maliyetlerinin düşüklüğü sebebiyle tercih nedenidirler. Özellikle dron, insansız hava aracı (İHA) ve silahlı insansız hava aracı (SİHA)'larda kullanılırken, çok daha büyük gövdeli, taşıyabildiği faydalı yük miktarı yüksek olan hava araçlarında solar sistemlerle desteklenen elektrik motorlarının kullanımından da bahsetmemiz gerekir.

2.4 Tasarım Şekline Göre Hava Araçları

2.4.1 Hibrit

Tablo 2-1 de bahsedilmemiş olmasına rağmen hava araçlarının tasarım, kullanım, iniş/kalkış şekli, kanat tipi açısından da farklı hava aracı türlerinin birleştirilmesiyle imal edilmiş hibrit olarak adlandırabileceğimiz türleri mevcuttur. Hibrit hava araçlarını sınıflandırmada birkaç farklı bakış açısı sunmakta fayda vardır. Döner kanatlı hava araçlarının özelliklerinin sabit kanatlı hava araçlarına uygulanması, gaz tirübünlü motorlarla birlikte elektrik motorlarının hava aracında kullanılması, insanlı ve insansız hava aracı birleştirilmesi, hava aracının hem askeri hem sivil kullanıma uygun olması gibi farklı türden hava araçlarının en iyi niteliklerinin birleştirilmesiyle gerçekleştirilmiş birçok hava aracını, hibrit hava aracı kategorisinde saymamız mümkündür.

2.5 Kontrol Tipine Göre Hava Araçları

2.5.1 İnsanlı Hava Aracı

İnsanlı hava araçlarının kontrolü, hava aracı içerisinde bulunan bir veya birden fazla operatör tarafından gerçekleştirilir. Bu operatörlere pilot adı verilir. Hava aracının büyüklüğü pilot sayısını belirler.

2.5.2 İnsansız Hava Aracı (İHA)

İster sabit kanatlı isterse de döner kanatlı olsun hava araçlarının sevk ve idaresi için her zaman bir operatöre ihtiyaç vardır. Hava aracının sevk ve idaresi otonom olarak ya da uzaktan kontrol ile gerçekleştiriliyorsa, kontrolü bu şekilde gerçekleştirilen hava araçlarına İnsansız hava aracı adı verilir. Kontrolü uzaktan radyo frekans (RF) sinyalleri sayesinde gerçekleştirilir. İnsansız hava araçları bir görevi ifa etmek için tasarlanmış olup, bu görevin gerektirdiği ekipmanlarla donatılırlar. Bu

türden araçların askeri ve sivil kullanım için tasarlanmış olanları vardır. Yetenek ve kabiliyetleri ise birbirinden farklıdır. Günümüzde; keşif, gözetleme, film çekimi, haritalama, ziraat, çevre güvenliği ve gösteri amaçlı olarak kullanılanları çok yaygınlaştırmıştır.

3. KONUMLANDIRMA SİSTEMLERİ

Sensörler ile konum belirleme göreceli ve mutlak olmak üzere ikiye ayrılmaktadır (Borenstein ve diğ., 1997; Liu ve diğ., 2007). Göreceli sistemler robot üzerinde bulunan ivmeölçer, jiroskop, enkoder, kamera, mesafe ölçer gibi sensör veya sensör dizisi yardımıyla araç veya çevredeki nesnelere konumunun hesaplanması prensibine dayanır. Bu sistemler yalnızca kendi imkanları ile konumlandırma işlemini yapmaktadırlar. Göreceli sistemler kolay uygulanabilir ve düşük maliyetlidir ancak sadece kendi üzerindeki imkanları kullanıldığı için oluşan küçük hatalar zamanla birikir ve harici bir düzeltici olmadığı için uzun süreli çalışma durumunda konum hesaplamalarında büyük hata birikimine sebep olurlar. Bu sebeple göreceli sistemler tek başlarına uzun süreli işlerde ve hassas çalışmalarda tercih edilmemektedir. Mutlak sistemler ise referans noktalardan alınan bilgiler ile konum hesaplama prensibine dayanır. Göreceli sistemlerden farklı olarak mutlak sistemlerde harici bir konumlandırma altyapısı gerekmektedir. Mutlak sistemler de üçgenleştirme metotları ve model eşleme metotları olmak üzere ikiye ayrılır. Üçgenleştirme (Triangulation and Trilateration) metotlarında, konumu bilinen en az üç referans noktasından alınan açı ve mesafe bilgisi ile konum tahmin edilir. Bu sistemlerin en bilineni GPS'dir. Üçgenleştirme ile çalışan sistemlerde doğruluk yüksektir ve hata birikimi yoktur ancak altyapı kurulumu zahmetli, yüksek maliyetli ve taşınabilirliği düşüktür (ortam bağımlılığı). Özellikle radyo frekans teknikleri ile çalışan GPS gibi yaygın sistemler bile kapalı alanda sinyal zayıflaması ve yansımalar sebebiyle yanlış çalışmakta veya çalışmamaktadır. Model eşleme konumlandırma sistemleri arasında günümüzde en popüler, en gelişmiş ve aynı zamanda karmaşıktır. Model eşleme bazı kaynaklarda sahne analizi, desen eşleme veya fingerprinting olarak da anılmaktadır (Siciliano ve Khatib, 2008). Model eşleme iki bölümden oluşmaktadır: Offline ve Online. Geleneksel model eşleme sistemlerinde, Offline kısmında, çevreden özgün veriler toplanır. Bu veriye fingerprint de denir. Çünkü her konuma ait eşsiz bir yapıda olması gerekmektedir. Online kısımda ise bu fingerprint verisi bir merkeze veya karşı cihaza gönderilir. Fingerprint verisinin başka cihazda işlenmesi esnasında merkezin veri tabanında desen tanıma teknikleri yardımıyla eşleştirme yapılır ve konum bilgisi üretilir. Son olarak üretilen konum bilgisi araca cevap olarak gönderilir. Mevcut model eşleme sistemleri ağırlıklı olarak merkezi olup konumu hesaplanacak nokta sayısı arttığında merkezin hesaplama gücünün artması gerekmektedir. Ayrıca merkez

genellikle büyük bir bilgisayar olacağı için taşınabilirliği düşüktür. Bu da ortam bağımlılığı getirmektedir. Dağıtık olarak tanımlanan model eşleme sistemlerinde ise haberleşme ağının yükü cihaz sayısı arttıkça artmaktadır.

Robotik, otonom araçlar ve uzaktan kontrollü araçlar gibi sistemlerde görevlerin yerine getirilmesi esnasında ilgili aracın çevre ile etkileşime geçmesi kaçınılmazdır. Eğer görev içeriğinde hedef, engel, dost-düşman, yol izleme vb. gibi elemanlar varsa en önemli etkileşim problemi hem diğer araçların hem de çevredeki nesnelerin konumunun belirlenmesidir (Beard ve diğ., 2002; Borenstein ve diğ., 1997). Konumlandırma işlemleri kendi arasında, aracın konumlandırması ve nesne konumlandırma olarak ikiye ayrılır. Aracın kendi konumunun belirlenmesi, bir referans noktaya göre açı ve uzaklık bilgilerini kapsayacak şekilde nerede olduğunu tespit etmektir. Nesne konumunun algılanması ise robotun çevresindeki nesnelerin konumlarını araca göre belirlemesidir.

Dünya üzerinde hareket halinde veya hareketsiz halde duran her türlü nesnenin kesin olarak konumunun belirlenebilmesi için kullanılan konumlandırma sistemlerinde mesafe ölçer, radyo frekans sinyal ölçümü, görüntü/video işleme, 3D tarayıcılar, radar ve global positioning system, ya da takımyıldızlarını takip sistemleri gibi birçok teknik kullanılmaktadır. Konum hesaplanmasını sağlayan sistemler, karada, hareket halindeki bir araçta, bir hava aracında ya da deniz taşıtında bulunabilir.

Poz kestirimi ise kameranın bilinmeyen konumunu ve yönelimini bilinen bir sahneye göre belirlemek olarak tanımlanır (Winick ve Brandewie, 1970). Herhangi bir nesnenin konum ve yönelimli üç boyutlu pozunu, konumu bilinen üç boyutlu noktaların, iki boyutlu iz düşümlerinden belirlenebilir. Harici kalibrasyon olarak adlandırılan bu poz tahmininde kullanılan nokta sayısı, kullanılan yaklaşıma göre değişkenlik gösterir. Literatürde çözüm için doğrudan doğrusal dönüşüm (DLT), perspektif n nokta çözümü ve yinelemeli yöntemler bulunmaktadır.

3.1 Kapalı Alan ve Gps Engelli Durum Konumlandırma

Son yıllarda hava araçları, otonom araçlar ve uzaktan kumandalı araçlar gibi farklı işlevlerdeki pek çok araç için konumlandırma çalışması yapılmıştır. Bu

çalışmalar hedef alana göre farklılıklar göstermektedir. Günümüzde otonom araçlar, tarım, denizcilik, hava fotoğrafçılığı gibi açık havada yapılan ticari uygulamalarda konumlandırma için GPS tercih edilmektedir. GPS ile yapılan çalışmalarda enlem ve boylam olmak üzere iki boyutlu olarak üretilen koordinat verisi kullanılabilir. GPS ile yükseklik verisi de ölçülebilmektedir fakat çok kaba değerler ürettiği için tercih edilmemektedir. Bu sebeple koordinat verilerine barometre ve mesafe ölçer gibi sensörle alınan yükseklik verisi de eklenerek üç boyutta konumlandırma yapılabilmektedir. GPS ve yardımcı sensörler ile yapılan bu tip uygulamalarda quadrotor ve fixed-wing tipi hava araçları kullanılmıştır (Quintero ve diğ., 2013; Vásárhelyi ve diğ., 2014). Ancak GPS sistemi yansıma ve sinyal zayıflaması sıkıntılarında dolayı vadi, mağra, bina, tünel ve su altı gibi kapalı alanlarda kullanılamamaktadır. Kapalı alanda ve GPS engelli durumlarda konumlandırma yapan sistemler üzerine çok sayıda çalışma yapılmıştır (Balamurugan ve diğ., 2016; Liu ve diğ., 2007; Mautz, 2009, 2012; Scaramuzza ve diğ., 2014; Stirling ve diğ., 2012).

3.2 Kapalı Alan Mutlak Konumlandırma

Kapalı alanda ve GPS engelli durumlarda önerilen en popüler alternatif mutlak konumlandırma yöntemleri elektromanyetik ve ses sinyalleri yayan referans vericilerle konumlandırma yöntemleridir (Balamurugan ve diğ., 2016; Ijaz ve diğ., 2013; Scaramuzza ve diğ., 2014; Yazıcı ve diğ., 2011). Bu yöntemler de yine GPS’de olduğu gibi yansıma ve zayıflama problemleri barındırmaktadır. Fakat bu sistemler mevcut kapalı alanın yapısına göre haritalanarak model eşleme yapılmak sureti ile konumlar için eşsiz fingerprintler bulunması yoluna gidilmektedir. Sinyallerin malzemeler üzerinde emilmesi ve yansıması çeşitli koşullara bağlıdır ve kurulum yapılan ortamdaki canlı sayısı, canlıların hareketleri, diğer sinyal kaynakları, sıcaklık, nem, erozyon, yapının değişmesi gibi çeşitli değişiklikler mutlak referans sisteminin oluşturduğu deseni büyük ölçüde değiştirebilmektedir. Bu tür konumlandırma sistemleri günümüzde ancak makine öğrenmesi kullanılması ve uzun süreli-yoğun veri toplanması durumlarında oldukça yüksek doğrulukta sonuçlar üretebilmektedir. Radyo dalgaları kullanılarak yapılan navigasyon sistemleri aşağıdaki üç yöntemeye göre sınıflandırılabilir.

3.2.1 Radyo Alan Kuvvetini Kullanan Yöntemler

Bu sistemlerde, ölçüm için radyo dalgasının kullanılmasının konum tahmininde bir doğruluk sınırına sahip olduğu bilinmektedir. Ortamda kurulan iki veya daha fazla kablosuz baz istasyonunun konum bilgisinin bu yöntemde zaten bilindiği varsayılır ve nesne terminalinin konumu, radyo alanı kuvvetine ve baz istasyonlarından konum bilgisine göre tahmin edilir (Yamada ve diğ., 2007). Bu yöntemle konum tahmininde yüksek doğruluk elde etmek için, her baz istasyonundan kablosuz radyo dalgası keyfi bir yerde ölçülür ve baz istasyonları ile nesne terminali arasındaki bağıl konum ilişkisi ölçüm sonucu kullanılarak tahmin edilir. Ayrıca, ortamın konum tahmin doğruluğu ile orantılı olarak yeterli sayıda radyo baz istasyonu yerleştirilmelidir (Bahl ve Padmanabhan, 2000). Bununla birlikte, bir radyo dalgası durumu, çevredeki bir insanın yoğunluğunun çeşitli koşulları veya dinamik olarak çok fazla engelle değiştiği için, bu yöntemlerin doğruluğu artırmak için esasen zor olması yaygındır. Ayrıca, radyo baz istasyonları hareket ettirilirse, her seferinde radyo dalgası gücünü yeniden ölçerek düzeltmek gerekir.

3.2.2 Radyo Dalgası Varış Zamanı Gecikmesini Kullanan Yöntemler

Bu yöntemde konum, baz istasyonlarından gönderilen radyo dalgasının gelecekteki zamanındaki farka göre tahmin edilir (Mogi ve Ohtsuki, 2008). Bu yöntemi iç mekan ortamında konum tahmini amacıyla kullanmak için, bir çoklu yolla (bir duvarda üretilen doğrudan dalga dışındaki radyo dalgalarının parazititi, tavandan yansıma v.b.) ilgilenmek gerekir (Chan ve diğ., 2006). Buna ek olarak, daha önce de belirtildiği gibi, ortamdaki konum tahmin doğruluğu için gerekli sayıda radyo baz istasyonu ayarlanması gerektiğinden, büyük tesis ve ekipman yatırımı gereklidir. Ayrıca, terminalin yeterli zaman çözünürlüğü fonksiyonuna sahip bir alıcıya ihtiyacı olacaktır.

3.2.3 RFID Kullanan Yöntemler

RFID kullanarak konum tahmini gerçekleştirirken, birçok aktivite tipi RFID konum alanına düzenlenir ve konum, her bir RFID' nin bir nesne terminaline


gönderdiği konum bilgisi alınarak tahmin edilir (Yamashita ve diğ., 2002). RFID, genel radyo baz istasyonundan daha zayıf radyo dalgası gücüne sahip olduğundan ve bir RFID'nin kapsayabileceği alan küçük olduğu için, yüksek konum tahminini tahmin etmek için uzaya büyük miktarda RFID kurmak gerekir. Ek olarak, nesne terminal tarafında bile toplama cihazına, RFID liderine sahip olmak gerekir.

3.3 Kapalı Alan Görsel Mutlak Konumlandırma

Diğer bir alternatif mutlak konumlandırma sistemi ise görsel konumlandırmadır. Bu metotta harici kameralar izlenecek ortama sabit şekilde yerleştirilir ve hedef aracın konumlandırması yapılır. GRASP laboratuvarlarının Quadrotorlar ile yaptığı çalışmada konumlandırma işlemi için VICON hareket yakalama sistemi kullanılmıştır (Alitalishi ve diğ., 2020; Chan ve diğ., 2006; Michael ve diğ., 2010). VICON sistemi laboratuvar duvarlarına yerleştirilmiş kızıl ötesi kameralardan oluşan bir sistemdir. Bu sistem duvar gibi sabit yapılara monte edildiği için taşınabilirliği yoktur. Bunun yanında sistem hassas ve doğru sonuçlar üretmektedir. Swarmanoid çalışmasında hazırlanan sistem el, ayak ve göz robotlarından meydana gelmektedir (Dorigo ve diğ., 2013). Farklı tip robotlardan meydana gelen bu sistem heterojendir. Swarmanoid sistemi, eye robot tarafından toplanan verileri kullanarak konumlandırma gerçekleştirir. Bu sistem sadece iki boyutlu hareketler için tasarlanmıştır ve üç boyutlu hareketleri yönetemez. Ayrıca, sistemde eye robot kaldırıldığında, yerine hand veya foot robotların yerleştirilmesi mümkün değildir, bu nedenle sistem esnek de değildir. Bu sistemle yapılan bir diğer çalışmada ise sadece eye robotlar ile çalışılmış olup GRASP laboratuvarlarının çalışmasındaki VICON sistemine benzer bir sistem olan Leica TS30 takip sistemi kullanılmıştır (Leica TS30, t.y.; Stirling ve diğ., 2012). Bu konuda yapılan daha pratik çalışmalarda ise artırılmış gerçeklik etiketleri harici kameralar ile algılanarak araç konumlandırması yapılmıştır (Seçkin, 2020^a; Zakiev ve diğ., 2020).

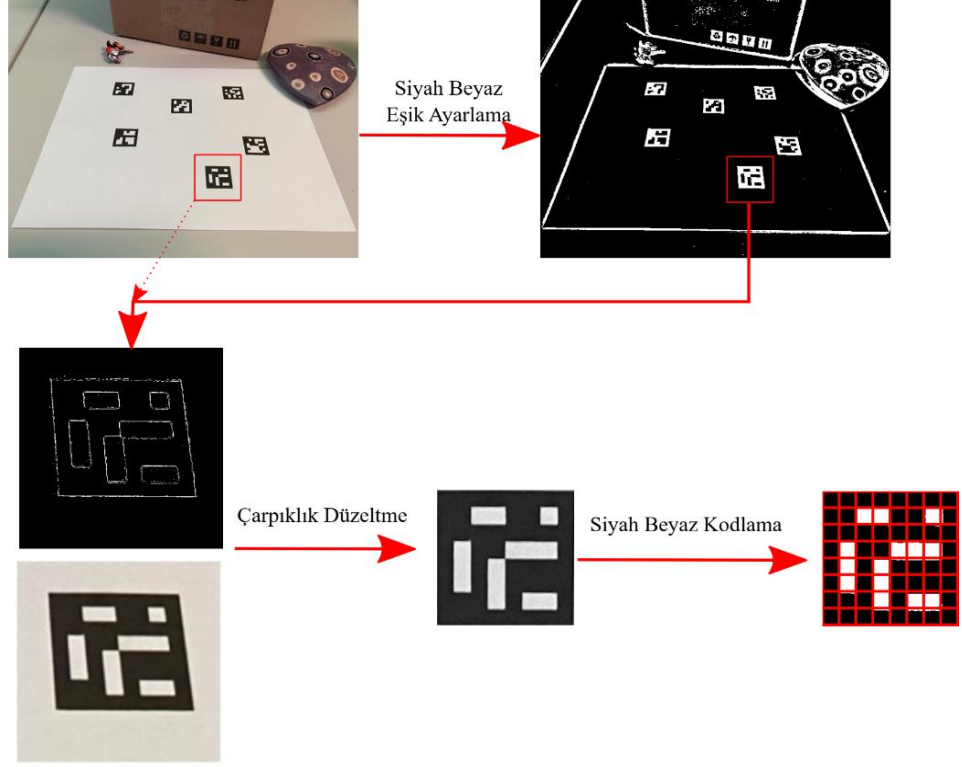
3.3.1 Arttırılmış Gerçeklik Etiketleri (ArUco Marker)

ArUco markerlar siyah bir zemin üzerine oturtulmuş (ki kolayca kameralar tarafından tespit edilebilsin diye bir siyah dörtgen çerçeve oluşturabilmek için) benzersiz beyaz kare kutucuklardan müteşekkıldür. Her bir ArUco marker bir binary koda karşılık gelen özel bir bilgi yığınına işaret eder. ArUco markerların fraktal, dairesel, kare türden olanlarına rastlamak mümkündür. Şayet özel olarak bir ArUco marker üretilmemişse en çok kare formda olana rastlanır. Genellikle ebatları 3x3, 4x4, 5x5, 6x6, 7x7 dir. En sık kullanılan ArUco marker türleri Şekil 3.1’de verilmiştir.



Şekil 3.1: Sık kullanılan ArUco Marker türleri (Garrido-Jurado ve diğ., 2014).

ArUco etiket bulma işlemi Şekil 3.2’de gösterilmiştir. Bu işlemde önce seçilen bir eşik değerine göre görüntü ikili değer haline getirilir. Seçilen eşik değeri Aruco markerler siyah zeminli olduğu için oldukça siyaha yakın değere yakındır. Sonuç, ikili bir görüntüdür. Kare şekilli bir Augmented Reality (AR) işaretçisi kullanılmış ise ikili görüntüde siyah kareler aranır. Daha sonra algılanan siyah kare, tam kare yapmak için döndürme, ölçekleme ve eğrilik için düzeltilir. Kare görüntüdeki ikili değerler aranan marker kodlama tipine göre ızgara halinde bölünür. Şekil 3.2’deki örnekte 8x8 ızgara kullanılmıştır. Her kareye gelen kod işaretçi kodu olarak atanır (Kato ve diğ., 2000). Kodlama sayesinde markerin yönü, oryantasyonu ve kodu (ayraç değeri) çıkarılabilmektedir.



Şekil 3.2: ArUco Etiket Algılama.

ArUco markerlar poz tahmini içinde kullanılabilirler ki bu durum mesafe ölçümü yapmayı da mümkün kılar. Ancak ArUco markerların poz tahmininde kullanılması sırasında karşılaşılan düşük algılama verimliliği ve algılanma oranı ölçüm sonucunu büyük oranda etkiler (Wang ve diğ., 2020).

Derinlik algılama/ölçme ve hedef tespiti ve endüstriyel otomasyon sistemlerinde büyük bir öneme sahiptir. 1960'lı yılların sonlarında ortaya çıkan monoküler görüş tabanlı görüntü işleme, basit ekipman gereksinimi, ucuz maliyet ve kolay çalışabilme özellikleriyle popüler olmuştur (Wang ve diğ., 2020).

Mesafeyi görüntü işleme teknikleri kullanarak tespit etmek için birçok bilim insanı perspektif görüntüleme tekniği üzerine çalışmıştır. Bu teknikte hedefin pozunu tahmin ederek mesafe ölçmek mümkün olmaktadır.

Yüksek tespit oranı ve düşük yanlış pozitif oranı elde etmek için Rafael Munoz ve Sergio Garrido (Garrido-Jurado ve diğ., 2014; Wang ve diğ., 2020), tarafından önerilen ArUco markerlar, markerlar arası mesafeyi ve bit geçişlerinin sayısını maksimize etmeyi amaçlar.

Poz tahmininde kullanılan markerların dört köşe noktası, düz çizgi uydurma ile elde edilen dörtkenarın kesişim noktasıdır. Köşe titreme sorunu vardır ve köşe koordinatlarının doğruluğu düz çizgi uydurma doğruluğundan büyük ölçüde etkilenir (Wang ve diğ., 2020).

ArUco markerlar AR uygulamalarında çok sık bir şekilde kullanılmaktadır. Son zamanlarda kapalı ortamlarda ve GPS sinyallerinin alınmadığı bölgelerde güvenli bir navigasyon yöntemi olması nedeniyle tercih edilmektedirler. Özellikle dron ve helikopterlerin (VTOL) iniş ve navigasyonu için araştırmacıların sıkça kullandığı bir yöntem haline gelmiştir. ArUco marker ve çeşitleri Şekil 3,1'de verilmiştir.

Bir ortamdaki hareketli nesneyi bulmak için kullanılabilen işaretli ve işaretsiz görüntü tabanlı iki teknik mevcuttur. Hedefin renkleri, desenleri ve özelliklerinin çıkartılarak resimler arasındaki farkın karşılaştırıldığı işaretsiz izleme yöntemine ilave olarak birde kameralarla donatılmış cihazlarda kullanılan işaretli izleme yöntemleri mevcuttur. İşaretli izleme yönteminde çıkarılan özelliklerin hiçbirinin önceden bilinme zarureti yoktur. Ancak özellik çıkarma ve eşleştirme işlemleri yüksek hesaplama gerektirmektedir. Buda bir hayli zaman alır. Bunun aksine işaretçilerle yapılan poz bilgisi hızlı ve doğru bir şekilde gerçekleştirilebilmektedir. Bu da işaretçilerin kullanıldığı uygulamalarda bir avantaj olarak karşımıza çıkar.

Fiducial Markerlar, yapar görme sistemleri tarafından kullanılmak üzere ortaya çıkarılmış bir tür grafik işaretçidir. Bu grafik işaretçiler düz bir zemin üzerinde kullanılmak üzere geliştirilmişlerdir. Her bir işaretçinin kendine has bir kimliği ve bu kimliğe karşılık gelen, bilgisayarlı görme algoritmaları tarafından tanınan bir grafik gösterimi vardır. Bunlar arttırılmış gerçeklik, robotik, tıp havacılık, meteoroloji, fizik gibi alanlarda kullanılmaktadır (Zakiev ve diğ., 2020).

Günümüz robotik araştırmalarında zorlu görevlerin yerine getirilebilmesinde birçok yapay görme yöntemleri kullanılmaktadır (Zakiev ve diğ., 2020). Kullanılan yöntemlerde, sistem çıktılarından donanım ve ölçüm gürültüsünü elimine etmek için genellikle Kalman Filtresi kullanılmaktadır. Kalman filtresi 1960 yılında RE Kalman tarafından gerçekleştirilmiştir (Kalman, 1960). Geleneksel Kalman filtresi lineer sistemlere uygulanır. Günümüzde ise geliştirilmiş kalman filtresi (EKF) her türlü

sisteme uygulanabilmektedir. Bu filtreler çok sık kullanılmasına rağmen veri ilişkilendirme gibi önemli bir probleme çözüm getirememektedirler. Bunun yanı sıra bu filtrelerde yapay sınır duvarlarına ihtiyaç duyulur ve gürültü tipi gauss olmak zorundadır. Eğer ki başlangıçta robotun pozisyonunda kayma olmadıysa harita gerçeğe uygun çıkmaktadır, aksi takdirde istenilen sonuç elde edilememektedir (Ankişhan ve Efe, 2010). Bu gibi kısıtlarla birlikte otonom hava robotlarında eş zamanlı konumlama ve haritalandırma, robotların havadaki hareketinin stabil olmaması nedeniyle zor, güncel araştırma konularındandır.

3.4 Kapalı Alan Göreceli Konumlandırma

Kapalı alanda ve GPS engelli durumlarda önerilen alternatif göreceli konumlandırma yöntemlerinin ilki ivme, jiroskop, pusula ve enkoder gibi sistemler ile kör hesaplamadır (deadreckoning) (Jimenez ve diğ., 2009; Kalman, 1960). Bu hesaplamalar esnasında sürtünme, gürültü ve hatalı ölçümler sebebiyle hata birikimi meydana gelmektedir bu sebeple günümüzde bu yöntemlerin tek başına kullanılması zorunlu durumlar haricinde terk edilmiştir. Günümüzde kapalı alanda ve GPS engelli durumlarda konumlandırma için en popüler yöntem görsel ve/veya mesafe ölçüm sistemleri ile çalışan eşzamanlı konumlandırma ve haritalama sistemleridir simultaneous localization and mapping (SLAM). Bu metotlar bir bakıma mutlak sistemler gibi çalışmaktadır fakat tamamen araç üzerindeki donanım ile çalıştıkları için göreceli sistem kategorisindedir. SLAM sistemlerindeki konumlandırma buldukları çevrenin örnek bir haritasını çıkarmaları ve hafızalarındaki haritalarla karşılaştırarak konumlarını yüksek doğrulukta hesaplayabilmeleridir. Bu sistemlerden günümüzde en popülerleri Light Detection and Ranging (LIDAR)'dır. Bu sistem bir lazer mesafe ölçerin belirli bir alanı veya hacmi taraması sonucu oluşturduğu nokta kümesinin bir harita haline getirilmesi ve haritaların eşleştirilerek konum hesabına dayanmaktadır. Günümüzde evimizde kullanımı yaygınlaşan robot süpürgeler ve fabrikalarda kullanılan pek çok otonom kılavuzlu araç bu sistemi kullanmaktadır (Brossard ve diğ., 2020; Do ve diğ., 2016; Hess ve diğ., 2016; Quan ve Chen, 2019). LIDAR sistemleri ayna veya parlak yansıtıcı yüzeylerde yanlış haritalar oluşturmaktadır ve düz duvar veya tekrarlayan yapılar harita eşlemede yanıltıcı olabilmektedir. Bu sebeple doğal

yapılarda sorun yaşanma olasılığı düşüktür fakat bina içi kullanımda mimari detaylara dikkat edilmesi gerekmektedir.

3.5 Kapalı Alan Göreceli Görsel Konumlandırma

Kapalı alan göreceli konumlandırmada kullanılan alternatif yöntemlerden biri de Görsel SLAM'dir (V-SLAM). V-SLAM tek (mono), ikili (stereo), olay ve çok yönlü (omnidirectional) kamera gibi tekniklerini kapsayan görüntü öznitelik çıkarma, eşleme ve konum hesaplama işlem akışıyla çalışmaktadır (Davison, 2003; Se ve diğ., 2002; Seçkin, 2021; Veerannapeta, 2019). Öznitelik algılama ve tanımlama algoritmaları görüntü işlemede sıklıkla kullanılan algoritmalar ve özellikle robotikte kullanılmaktadır. Bu sistemler yüksek hesaplama gücü gerektirmektedir. Görüntü üzerinde çeşitli algoritmalar kullanılarak çıkarılan anahtar veya özetleyici noktalara öznitelik denilmektedir. Features From Accelerated Segment Test (FAST) Center Surround Extremas for Realtime Feature Detection and Matching (CENSURE), ve Efficient Maximally Stable Extremal Region (MSER) algoritmaları başlıca öznitelik algılama algoritmalarıdır (Karlsson ve diğ., 2005; Rosten ve diğ., 2010; Rosten ve Drummond, 2006; Steder ve diğ., 2008). İki görüntü arasında benzer bölgeler belirlemek için, kaynak görüntüdeki özniteliklerin hedef görüntüdeki özniteliklerle eşleştiği noktaları tespit etmek gerekir. Bu iş için ise öznitelik tanımlama algoritmaları kullanılır. Başlıca öznitelik tanımlama algoritmaları Binary Robust Independent Elementary Features (BRISK), Binary Robust Invariant Scalable Keypoints (BRISK) ve Fast Retina Keypoint (FREAK)'dir (Agrawal ve diğ., 2008; Calonder ve diğ., 2010; Donoser ve Bischof, 2006). Mevcut algoritmalarda öznitelik algılama ve tanımlama işlemi bazen birlikte yapılmaktadır. Scale Invariant Feature Transform (SIFT), Speed Up Robust Features (SURF) ve Oriented FAST and Rotated BRIEF (ORB) bu tip algoritmalarındandır (Alahi ve diğ., 2012; Leutenegger ve diğ., 2011; Lowe, 2004). SIFT ve SURF, görüntü dikme uygulamalarında çok sık kullanılan patentli algoritmalar. ORB tek başına algılama veya tanımlama olarak kullanılabilirdiği gibi her ikisi yerine de kullanılabilir. Öznitelik algılama ve tanımlama algoritmaları, tespit edilen noktaların sayısı, koordinatları ve tanımlarını içeren bir veri seti (data set) oluşturur. Noktaların tanımları

ve koordinatlarından oluşan bu veri setine, Random Sample Consensus (RANSAC) algoritmasıyla regresyon uygulanarak, homography matrisi olarak adlandırılan bir matris elde edilir.

4. KONUMLANDIRMA YÖNTEMLERİ VE SENSÖR TİPLERİ

Konulandırma için kullanılan yöntemleri dört başlık altında toplamamız mümkündür.

- Harita Okuma: Harita kullanarak, arazi şekillerini takip etmek suretiyle yapılan seyrüsefer yöntemidir.
- Dead-Reckoning (Hesabi Seyrüsefer): Hiçbir yardımcı seyrüsefer cihazı kullanmadan, mesafeyi, uçuş istikametini, havada geçen zamanı ve yer hızını hesaplayarak hava aracının pozisyonunun bulunmasının sağlandığı yöntemdir.
- Celestial Navigation (Yıldızlarla seyrüsefer): Güneş, ay, gezegenler (venüs, Jupiter, satürn) ve özel olarak seçilmiş 57 yıldızdan faydalanılarak yapılan seyrüsefer yöntemidir.
- Radyo Seyrüsefer: Çeşitli tipte radio seyrüsefer yardımcı cihazları (VOR, NDB) kullanılarak yapılan seyrüsefer yöntemidir.

4.1 Manuel Hesaplama

Ölü hesaplama, bir geminin veya uçağın konumunun göksel seyrüsefer yardımı olmaksızın gidilen veya uçulan rotaların kaydından, yapılan mesafenin (hızdan tahmin edilebilir), bilinen başlangıç noktasının ve bilinen veya tahmin edilen sürüklenme.

Bazı deniz seyrüsefercileri arasında ayırım yapar. Yönlendirilen rotayı kullandıkları ölü hesap konumu ve sudaki tahmini hızları ve Akım, rüzgar ve diğer faktörlerin etkileri için düzeltilmiş ölü hesap konumu olan tahmini konum. Ölü hesaplaşmanın belirsizliği zamanla ve belki de mesafeyle arttığından, yeni bir ölü hesaplaşmanın başladığı daha güvenilir bir konum (düzeltme olarak adlandırılır) belirlemek için aralıklı olarak gök gözlemleri yapılır. Ölü hesaplaşma da gömülüdür Navigatörün mevcut konumu, hızı, konum açıları vb. hakkında en iyi tahmini elde etmek için bir dizi navigasyon çözümünü matematiksel olarak birleştiren Kalman filtreleme teknikleri.

4.2 Yıldızlara Bakarak – Sekstant

En büyük alternatif olarak, yıldız referans sistemi olarak adlandırılan (Göksel, Astro-Navigasyon) ataletli navigasyon sistemleri ortaya çıkar. Yıldızlar en temel ve doğru atalet navigasyon sistemidir. Ancak, yıldız referanslı navigasyon sisteminin, en azından denizciler ve karacılar için, bulutlar ve kötü hava koşulları gibi handikapları vardır. Bu nedenle, askeri birlikler kapalı havalarda, yıldızlardan bir hayli fazla zaman ayrı kalmak mecburiyetinde olabilirler.

Otomatik yıldız izleyicileri ile ataletli navigasyon sistemlerini birleştirmek özellikle sinerjik bir eşleşme olarak görülebilir. Ataletli ve göksel navigasyon sistemleri birbirlerini tamamlayıcı özelliklere sahiptir. Ve yapılan konumsal hata miktarını oldukça azaltmak için bir avantaj sunar. INS sistemi, fırlatma veya uçuşun başlamasından sonra tamamen kendi kendine yeten ve herhangi bir dış referans sistemine veya bağlantıya ihtiyaç duymayan bir sistemdir. Göksel navigasyon sistemi ise en temel atalet referans sistemi olan yıldızlara doğrudan bağlantı kurmamızı sağlar. Her ikisinin birlikte çalışması iyi sonuçlar üretir.

4.3 Mesafe Sensörleri

4.3.1 Ses Sensörleri

Çok sık kullanım alanı bulan akustik sensörler, frekans, doğruluk ve menzille karakterize edilebilen ultrasonik telemetrelerdir. Ultrasonik sensörler, sesin gidiş geliş süresinin hesaplanması prensibine göre çalışırlar. $0.5 \times C \times t$, burada C sesin hızı, t ise zamandır. Ses hızı havanın sıcaklık, basınç ve nem değerlerinden etkilenir. Özellikle sıcaklık ses hızının değişimde büyük bir etkiye sahiptir. Doğru mesafe ölçümü elde etmek için bu değişkenleri her zaman hesabı katmak gerekir.

4.3.2 Duyulabilir Ses – Mikrofon/Mikrofonlar

Duyulabilir ses frekansında üretilen sesin, önceden hazırlanmış ve belirli mesafelere yerleştirilmiş alıcılara ulaşma zamanına bakılarak yapılan konumlandırma türüdür. Günümüzde konumlandırma için kullanılan alternatif mutlak konumlandırma yöntemlerinden biridir. Bu sistemlerin bileşenleri ise bir ses kaynağı ve sesi elektriksel sinyale dönüştüren mikrofon/mikrofonlardır.

4.3.3 Ultrasonik Sensörler

En yaygın olarak kullanılan mesafe ölçüm sensörü ultrasonik sensördür. Bazen sonar sensör olarak da adlandırılan bu sensör, yüksek frekanslı ses dalgalarını kullanarak nesnelere iletişim kurar. Bu sensörler, hedef nesneye doğru ses dalgalarını yayarlar, hedef nesne ile çarpıştıktan sonra geri dönen ses dalgalarını algırlar. Gönderilen ses dalgalarının geri dönüşü için harcanan zaman aralığını kullanarak cismin sensöre olan mesafesini hesaplarlar.

Ultrasonik sensörler, sınırlı bir algılama aralığına sahiptir. Aynı zamanda yavaş yenileme hızı ve düşük çözünürlük nedeniyle hızla hareket eden hedeflerin tespitinde uygun değildir. Ayrıca, aşırı yüzey ve dokulu nesnelere mesafesinin ölçümünde de kullanışsızdır. Bu nedenle, daha gelişmiş versiyonların kullanılması daha avantajlı bir seçim olacaktır.

4.3.4 Kapasitif Sensörler

Otomasyon sistemlerinde kullanım alanlarına göre birçok sensör bulunmaktadır. Bu sensörlerden bir tanesi olan kapasitif sensörler, çevre şartlarından en az etkilenerek ve malzeme ayrımı yapmadan iletken ve iletken olmayan malzemelerin konumunu ve mesafesini algılamak için kullanılan sensörlerdir. Bir diğer adı ise yaklaşım (proximity) sensörleri olarak piyasada adlandırılmaktadır. Bu sensörler pozisyon ölçümü ve algılama, dinamik hareket, kalınlık ölçümü, dokunmatik algılama, sıvı seviyesi algılama, hassas ölçüm, araç ve personel algılama gibi çok geniş bir alanda kullanılmaktadır.

4.3.5 Endüktif Sensörler

“İndüksiyon/Endüksiyon” kelimesi, “içeri yönlendirme” anlamına gelen latince “inducere” fiilinden gelir. Endüktif sensörler, metal bir cisim veya metal içeren bir cihazın yerini veya varlığını temassız olarak tespit etmek için elektromanyetik indüksiyon prensibini kullanır. Otomasyon süreçleri için vazgeçilmez olan sensörler, ayrıca endüstri dışında, sıvı seviyelerini izlemek için de kullanılabilir. Bu çok yönlülük, onları endüstriyel ve diğer makine için değerli bir araç haline getirir.

Endüktif sensörler, Osilasyon, Genişlik Ölçüm ve Çıkış Devresi olmak üzere 3 ana birimden oluşur. Bu devreler şu şekilde işler:

- Osilasyon Devresi (Oscillation Circuit): Sabit bir frekans üreterek, manyetik alan yayar. Bu frekans, ortama giren bir metal cisim tarafından etkilenmediği sürece sürekli devam eder. Ancak metal cisim ortama girdiğinde, bobin tarafından yayılan manyetik alan etkilenir ve gönderilen sinyal genliği değişir.
- Genişlik Ölçüm Devresi (Oscillation State Sensing Circuit): u bölümde, osilasyon devresinden gelen sinyal genliği kontrol edilir. Bu işlem sürekli olarak gerçekleştirilir ve genlik değişimleri çıkış devresine bildirilir. Eğer genlikte bir farklılık algılanırsa, sinyal boyutu arttırılır.
- Çıkış Devresi (Output Circuit): Bu kısımda ise genişlik ölçüm devresinden gelen sinyal değişimiyle beraber çıkıştaki transistörü tetikler. Transistörün çıkışı sensörün çıkışına bağlıdır. Bu sebeple tetiklemeden sonra sensör çıkışında giriş voltajı seviyesinde bir voltaj okunur. Sonrasında ise sinyal gerekli çıkış birimine gönderilir.

4.3.6 Manyetik Sensörler

Manyetik transdüserler, ortamdaki manyetik değişiklikleri algılayarak çıkışında gerilim üretebilen elemanlardır. Aynı zamanda "Alan Etkili Transdüser" olarak da adlandırılır. Manyetik transdüserler endüktif ve yarı iletken olmak üzere iki farklı eleman kullanılarak yapılır.

Bobin, endüktif bir elemandır ve manyetik alan deęişimine maruz kaldığında uçlarında gerilim üretir. Ancak, bobinin uçlarındaki gerilimin sürekli olması için sürekli deęişen bir manyetik alan içinde bulunması gerekir. Yani mıknatıs ya da bobinin sürekli hareket etmesi gerekir. Hareket sürekli deęilse, bobin pasif olarak kalır. Bobin içindeki nüvenin konumu, bobinin endüktans deęerini etkiler. Bu sayede uygulanan gerilime göre, bobin uçlarına düşen voltaj deęişir.

Manyetik transdüserler, elektriksel bağlantısı olmayan veya algılanacak cisimlerin birbirini gözlemlemedięi durumlarda kullanılır. Örneęin, motor ve benzeri cihazların çektięi akımların ölçülmesinde, hareket eden sistemlerin hızlarının ve hareket yönlerinin tespitinde, güvenlik ve metal detektörlerinde kullanılabilir. Sanayide ise, kumanda ve kontrol sistemlerinde, tıp elektroniklerinde, fabrikalarda ve otomatik kumanda kontrol uygulamalarında, yer deęişimlerinin hassas olarak ölçülmesinde kullanılabilir.

4.3.7 RFID Proximity Sensörler

RFID (Radio Frequency Identification) radyo frekansı kullanarak verileri okuma ve yazma teknolojisidir. RFID etiketlerinde veya akıllı etiketlerde kodlanmış dijital veriler, radyo dalgaları aracılığıyla bir okuyucu tarafından alınır. RFID, barkod okuma sistemlerine göre daha esnek ve çok yönlüdür. Örneęin, RFID etiketleri görüş alanı dışında okunabilirken, barkodlar sadece optik tarayıcılar ile okunabilir. Bu nedenle RFID, varlık izleme, stok yönetimi, güvenlik ve dięer alanlarda önemli avantajlar sağlar.

RFID, Otomatik Tanımlama ve Veri Yakalama (AIDC) olarak adlandırılan bir teknoloji grubuna aittir. AIDC yöntemleri nesnelere otomatik olarak tanımlar, bunlarla ilgili verileri toplar ve bu verileri çok az insan müdahalesi ile veya hiç müdahale olmadan doğrudan bilgisayar sistemlerine girer. Bu teknoloji, verilerin RFID etiketlerinde veya akıllı etiketlerde kodlanmış dijital verilerin radyo dalgaları aracılığıyla bir okuyucu tarafından yakalanmasını sağlar. RFID sistemleri, bir RFID etiketi, RFID okuyucusu ve anten içermektedir. RFID etiketleri, verileri okuyucuya iletmek için kullanılan bir entegre devre ve anten içerir. Okuyucu, radyo dalgalarını

kullanarak etiketlerden toplanan bilgileri daha kullanılabilir bir veri biçimine dönüştürür ve bu veriler daha sonra bir veritabanına kaydedilir ve analiz edilir.

4.3.8 RF Radar

Gönderilen radyo dalgalarının bir cisme çarparak yansması prensibinden hareketle geliştirilmiş sistemlerdir. Cisimden yansıyan dalganın alıcı antene gelme süresine bakarak, cismin antene uzaklığının ve yönünün tespit edilmesi sağlanır. Ayrıca cismin hızı da tespit edilir.

4.3.9 Mikrodalga–UWB

Ultra Geniş Bantlı radar (UWB radar) konvansiyonel radarlara göre çok daha geniş bir spectruma sahip manyetik dalgaları daha küçük pulse gücü kullanarak gönderir. Yayılan işaretlerin gücü okadar azdır ki evlerde kullanılan indüktif bir cihazın parazit gücü seviyesindedir. Pulse üreticilerinin ürettiği pulsler genellikle 1 ns den daha kısa süreli pulslerdir.

Ultra Geniş Bantlı radarından gönderilen işaretinin bant genişliği gönderilen işaretin merkez frekansının en az %25'i kadardır. Ultra geniş bantlı radarda büyük bant genişliklerinin kullanılabilmesi için çok özel devrelere ihtiyaç vardır. Doğal olarak kullanılan antenlerin de bant genişliklerinin büyük olması gerekir. Bu yüzden farklı frekans bantlarına sahip antenler birbirlerine paralel olarak bağlanırlar.

Düşük görev döngüsüyle 1 ns nin altında ultra kısa darbeler gönderme prensibine dayalı olarak çalışan UWB, radio frekans spektrumunun geniş bir alanında çalışabilir. Bu özellikleriyle RFID sistemlerinden ayrılırlar. Genellikle 3,1 ila 10,6 GHz arasında aynı anda birden fazla frekans bandı üzerinden sinyal iletir. Ve bu sinyaller RFID sinyallerinden çok daha kısa bir sürede iletilir. Buna rağmen onlardan daha az enerji tüketirler. UWB sinyalleri, duvarlardan ve engellerden rahatlıkla geçebilir. Fakat sıvı ve metal malzemeler, UWB sinyallerinde girişime neden olur. Çok sayıda UWB okuyucusu ve planlamayla iyi konumlandırılmış okuyucu yerleştirme bu sorunun önüne geçilmesine yardımcı olur (Noureldin ve diğ., 2012).


4.3.10 Lidar (Light Detection and Ranging)

SLAM sistemlerindeki konumlandırma buldukları çevrenin örnek bir haritasını çıkarmaları ve hafızalarındaki haritalarla karşılaştırarak konumlarını yüksek doğrulukta hesaplayabilmeleridir. Bu sistemlerden günümüzde en popüler LIDAR'dır. Bu sistem bir lazer mesafe ölçerini belirli bir alanı veya hacmi taraması sonucu oluşturduğu nokta kümesinin bir harita haline getirilmesi ve haritaların eşleştirilerek konum hesabına dayanmaktadır. Günümüzde evimizde kullanımı yaygınlaşan robot süpürgeler ve fabrikalarda kullanılan pek çok otonom kılavuzlu araç bu sistemi kullanmaktadır (Hess ve diğ., 2016; Quan ve Chen, 2019; Seçkin, 2021; Veerannapeta, 2019). LIDAR sistemleri ayna veya parlak yansıtıcı yüzeylerde yanlış haritalar oluşturmaktadır ve düz duvar veya tekrarlayan yapılar harita eşlemede yanıltıcı olabilmektedir. Bu sebeple doğal yapılarda sorun yaşanma olasılığı düşüktür fakat bina içi kullanımda mimari detaylara dikkat edilmesi gerekmektedir.

4.4 Eylemsizlik (Atalet) Sensörleri

4.4.1 İvmeölçer (Akselerometre)

Şekil 4.1'de bir accelerometer'in içyapısı görülmektedir (Noureldin ve diğ., 2013^b). Sabit bir yapı içerisinde iki adet esnek yay ile tutturulmuş bir m kütlesi yapıyı oluşturur. Şekil 4.1^a'da, bir kuvvete maruz kalmayan yapının denge halindeki pozisyonu görülmektedir. Şekil 4.1^b'de ise sağa doğru yapının hareket etmesi sonucu, m kütlesi, bu hareket esnasında maruz kaldığı kuvvet kadar geride kalır. m kütlesinin pozisyonu ölçeklendirilmiş bir sıkalaya aktarılır. Böylece pozitif bir ivme elde edilir.



Şekil 4.1: **a)** Bir kuvvete maruz kalmamış accelerometer, **b)** Bir kuvvete maruz kalmış accelerometer (Noureldin ve diğ., 2013^b).

Şayet accelerometer dikey ekseninde kullanılacak ise bu durumda m kütesine bir “ g ” yerçekimi ivmesi etki eder. Bu durumda m kütesine etki eden kuvvet (4.1) eşitliğiyle hesaplanabilir.

$$F = a - g \quad (4.1)$$

Eğer pozisyon vektörü “ r ” ile gösterilecek olursa ivme; (4.2) eşitliğinde olduğu gibi pozisyon vektörünün ikinci dereceden türevi alınarak bulunabilir.

$$a = d^2r/dt^2 \quad (4.2)$$

Yer çekimi alan vektörü “ \bar{g} ”, yer çekimi vektörü “ g ” cinsinden eşitlik (4.3)’de gösterildiği şekilde yazılabilir.


$$\bar{g} = g + \Omega_{ie}\Omega_{ier} \quad (4.3)$$

Ω_{ie} : Eylemsizlik çerçevesinde dünyanın dönüşünü temsil eden karmaşık matrisi ifade eder.


a ve \bar{g} eşitlikleri (4.1) eşitliğinde yerine yazılacak olursa, (4.5) eşitliğindeki yeni ifade elde edilir.

$$f = d^2r/dt^2 - g - \Omega_{ie}\Omega_{ier} \quad (4.5)$$

Şekil 4.2’de üç eksene yerleştirilmiş accelerometer’ların denge halindeki durumu görsel olarak görülebilirken Şekil 4.3’de ise X ve Y ekseninde bir ivmelenme durumunda accelerometerların aldığı yeni pozisyon bilgisine karşılık üretilmiş olan ivme miktarının düzlemsel gösterimi ifade edilmeye çalışılmıştır (Noureldin ve diğ., 2013^b).



Şekil 4.2: Üç eksende ivme ölçme mantığı (Noureldin ve diğ., 2013^b).



Şekil 4.3: X ve Y eksenlerinde meydana gelen ivmenin ölçülmesi (Noureldin ve diğ., 2013^b).


İvmeölçerlerin farklı yöntemler kullanarak çalışması mümkündür. En sık karşılaşılanları kapasitif ve piezoelektrik ivmeölçerlerdir. Kapasitif ivmeölçerler,

karşılıklı yerleştirilmiş iki iletken yüzey arasında bir kapasitif etkinin oluşması prensibine dayanarak çalışırlar. Aralarında bir kapasitans oluşur. Hareketli levhaya bir kuvvet etki ettiğinde, hareketli levha ile sabit levha arasındaki mesafede değişiklik olur. Bu da levhalar arasında oluşan kapasitans değerinde değişime sebebiyet verir. Değişim miktarının ölçülmesiyle hareketli levhanın yer değişim miktarına karşılık gelen bir ivme değeri elde edilir. Piezoelektrik ivmeölçerler ise piezokristallerine uygulanan kuvvete bağlı olarak bir elektrik gerilimi üretirler. Elde edilen elektrik gerilimi önceden belirlenmiş basınç değerlerine karşılık gelen elektrik değerleri ile mukayese edilir. Böylece önceden belirlenmiş elektriksel değere karşılık gelen ivme değeri, çıkış değeri olarak kullanılır.


4.5 Açısal Sapma Ölçüm Sensörleri

4.5.1 Jiroskop- Gyroscope-Gyro

Gyroscope' un temel çalışma prensibi; yüksek hızlarda dönen bir rotor, dönüş hızını koruduğu sürece uzayda dönü hareketine başladığı ilk pozisyonunu koruma eğilimindedir. Bu rotora bir kuvvet etki ederse rotor kuvvet etkisi altında pozisyonunu değiştirir. Kuvvet ortadan kalkınca rotor ilk pozisyonuna geri döner. Kuvvet altında iken rotorda meydana gelen sapma miktarı sens edilerek rotorun açısal sapma miktarı böylece sensörün bağlandığı platformun açısal miktarı tespit edilir. Genel olarak kullanılan "Gyro" kısaltması gyroscope'u ifade eder. Şekil 4.4'de açısal sapmalar görsel olarak gösterilmeye çalışılmıştır (Noureldin ve diğ., 2013^b).



Şekil 4.4: Dünyaya göre bir platformun gyrolar aracılığıyla açısal sapma miktarının sens edilmesi (Noureldin ve diğ., 2013^b).



Şekil 4.5: Açısal sapmaya maruz kalmış accelerometerların durumu (Noureldin ve diğ., 2013^b).

4.5.2 Pusula-Manyetometre

Eski çağlardan beri yaygın bir biçimde kullanılan ve en bilinen açısal sapma cihazı pusuladır. Yer kürenin manyetik alan çizgilerine tabi olan bir mıknatısın, yer kürenin manyetik alan çizgilerine paralel olarak pozisyonlanması prensibiyle çalışır.


Serbestce hareket edebilen bir mıknatıs (pusula iğnesi), hep dünyanın kuzey-güney doğrultusunda pozisyonlanır.

Bir diğer adı gauss metre olan manyetometre, manyetik alanın gücünü ve yönünü ölçmek için kullanılır. Manyetik alan vektörel bir büyüklüktür. Dolayısıyla bir manyetik alan vektörel olarak gücü ve yönü ile tarif edilebilir. Manyetik alanın vektörel olarak yönünün belirlenmesiyle, açısal sapma değeri belirlenmiş olur.

4.6 Kameralar

4.6.1 Tek ve Çift (Mono ve Stereo) Kamera Sistemleri


Otonom bir aracın çevre algılama girdisini sağlamak için bir görüntü sensörü kullanıldığında, çoğu araştırmacı tek bir kamera sistemi kullanmaktadır. Bu sistemler çeşitli çözünürlük ve spektrum özelliklerine sahip tek kamera bulunduran çalışmalardır. Kameradan alınan bir görüntüden sınıflandırma, segmentasyon, nesne algılama yapılabildiği gibi görüntü dizisinden veya videolardan faydalanılarak da görüntü farkları alınarak akış ve odometry çalışmaları yapılabilmektedir. Şekil 4.6'da görüldüğü üzere araç üzerindeki kamera hareket ettiğinde aynı P noktasını gösteren X_n piksel koordinatı X_{n+1} olarak değişmektedir. İki imaj arasındaki birden çok noktanın yer değiştirmesi hesaplanabilmektedir.



Şekil 4.6: Monocular Odometry (Fanani ve Mester, 2018).

İkili görü veya çok kameralı görü için ise iki veya daha fazla kamera kullanılmaktadır. İkili görmede daha çok insan görmesi gibi çalışma hedeflenmektedir.


Yan yana sabitlenmiş iki veya daha çok kamera aynı sahneye bakmakta gördükleri alandaki nesnelerin derinlik haritasını (disparity map) çıkarma işlemi yapılmaktadır. İki kalibre edilmiş ve sabitlenmiş kameradan Şekil 4.7’de görüldüğü üzere bir nesnenin görüntüsü alındığında bulunduğu konum sebebiyle iki resim arasında farklı noktalara tekabül ettiği görülmektedir. İki resim üzerinde öznitelik çıkarma ve eşleme ile Şekil 4.8’de görülen görüntülerden, Şekil 4.9’da görülen derinlik haritaları meydana getirilebilmektedir.



Şekil 4.7: İkili Görme (Hariyama ve diğ., 2008).




Şekil 4.8: Derinlik Haritası I (OpenCV: Depth Map from Stereo Images, t.y.).




Şekil 4.9: Derinlik Haritası II (Luxato, 2018).

4.6.2 Çok Yönlü (Omnidirectional) Kamera Sistemleri

Çok yönlü kameralar normal kameralardan farklı olarak belirli bir açı yerine genellikle yatayda 360 derece görüntü almaya yarayan aynalı veya çok kameralı sistemlerdir. Bu sistemlerin bazı örnekleri Şekil 4.10'da sunulmuştur. Bu tür kamera sistemlerinden en yaygın olanları konik veya küresel aynaya bakan kameralardır. Bu tür sistemlerden alınan görüntülerin anlaşılabilir hale getirilmesi için görüntü üzerinde Şekil 4.11'de görüldüğü üzere düzeltme yapılması gerekmektedir. Bu tür kameralar piyasada yaygın olarak satılmamaktadır ve genellikle el yapımı olarak çalışmalarda görülmektedir (Campos ve diğ., 2018; Hori ve diğ., 2011; Le ve diğ., 2012).



Şekil 4.10: Çok Yönlü Kamera Sistemleri (Sen, t.y.).



Şekil 4.11: Aynalı Çok Yönlü Kamera Görüntüsü (Scaramuzza, 2014).

4.6.3 Olay Kamera Sistemleri

Event kameralar geleneksel kameraların aksine görüntüdeki her bir pikseldeki ışık şiddetindeki değişimi algırlar. Yani görüntüyü oluşturan her bir pikseldeki parlaklık değişimlerini algırlar. Robotik görme sistemlerinin ihtiyaç duyduğu geniş dinamik aralık, yüksek çekim hızı, düşük gecikme süresi gibi özellikleri karşılayabilecek yetenekleriyle dikkat çekerler (Gallego ve diğ., 2020). Bu sensörlerin sıra dışı çıktılarını işlemek için birçok yöntem üzerinde çalışılmaktadır.

Event kameralar/silikon retina kameralar insan gözündeki retinaya benzer bir algılama yöntemiyle çalışabilen kameralardır. Görüntüyü oluşturacak her bir pikseli belirlemek yerine, her bir pikseldeki parlaklık değişimini algılama yeteneğine sahiptirler (Sarmadi ve diğ., 2021). Piksel başına parlaklık değişim miktarı, bir sınır değer ile karşılaştırılarak, parlaklık değişim miktarının bu sınır değerinin altında mı, yoksa üstünde mi olduğu belirlenir. Sınır değerden büyük parlaklık değişim miktarı için o piksel adına bir olay üretilir (So called on event, So called off event) (Sarmadi ve diğ., 2021).

Kameralar senkron olmayan yapılarından dolayı, 1ms ye gibi kısa sürelerde olay akışı üretebilirler. Bu kameraların asenkron çalışma özelliği, başka türden görüntü sensörlerine göre daha az enerji tüketmelerine neden olur. Daha düşük enerji harcamalarına karşın zorlu ışık şartları altında bile yüksek bir dinamik aralığa sahiptirler (Sarmadi ve diğ., 2021).


Event kameralar, robotik uygulamalar ve artırılmış gerçeklik uygulamalarında en çok tercih edilen kamera türüdür. Özellikle ikili kare referans işaretçilerinin poz tahmini için araştırmacıların hemen hemen ilk tercihidir. IGD, Matrix, binARyID, ARToolKitPlus, ARTag gibi birçok örneği olan ArUco işaretçileri artırılmış gerçeklik, robotik, tıp, haritalandırma ve daha birçok alanda kullanımlarıyla sıklıkla karşılaşırız (Sarmadi ve diğ., 2021). ArUco markerlar ortam haritalaması, Slam ve kameraların kalibrasyonlarının yapılmasında da kullanılmaktadır.

4.7 Ataletsel Seyrüsefer

4.7.1 INS (Inertial Navigation System)

INS (Inertial Navigation System-Ataletsel seyrüsefer Sistemi)' in çalışabilmesi için herhangi bir yer istasyonu ya da dünya atmosferi dışında bulunan bir uzay istasyonu ile haberleşmesine veya referans almasına ihtiyacı yoktur. Navigasyon için radyo sinyallerinin kullanımına gerek olmadan münferit çalışabilen tek uzun menzilli seyrüsefer sistemidir.

INS (Inertial Navigation System), bilinen konvansiyonel navigasyon sistemlerinin tamamen dışında platform üzerinde kendi kendine hava aracının kinematiğini kullanarak navigasyonun gerçekleştirilmesini sağlayan bir yöntemdir. Bunun için hava aracının her üç ekseninde ivmelenmesini sens eden 3 adet accelerometer ve yine her üç ekseninde sapma miktarını sens eden 3 adet gyroscopedan faydalanılır (Noureldin ve diğ., 2013^a). Herhangi bir eksenindeki ivme miktarı bulunduktan sonra bir integral alıcı devre aracılığıyla hız, hız elde edildikten sonra ikinci bir integral alıcı devre aracılığıyla kat edilen yol bulunabilir. Bir elektronik toplayıcı sistem tüm hesaplamalar sonucunda kat edilen yola bağlı olarak rotayı çizebilir. Şekil 4.12'de Strapdown INS blok yapısı görülmektedir.



Şekil 4.12: Strapdown Inertial Navigation System Blok yapısı (Fundamentals of Strapdown Inertial and GPS-Aided Navigation - ppt video online download, t.y.).

Dışarıdan her türlü müdahaleye kapalı olan INS sistemin en büyük sorunu ivmenin yeterince hassas sens edilememesidir. Zaman içerisinde ivme sensinden kaynaklı hatalar üst üste binerek büyür (Noureldin ve diğ., 2013^a). Böylece gerçek rotadan çok farklı bir istikamet sorunu ortaya çıkar. Özellikle hava aracının çok yüksek hızlara çıkması durumunda bu sapma miktarı da aynı oranda artar. Bu hatayı ortadan kaldırmak için INS sistemleri belirli zaman aralıklarıyla kendilerini doğrulamak için GPS navigasyon bilgilerini kullanırlar (Noureldin ve diğ., 2012).

Temel bir INS sistemi; IMU (Inertial Measurement Unit), dahili ya da harici bir GNSS ve bir hesaplama bilgisayarından oluşur. IMU olarak adlandırılan ünite, her üç eksendeki ivmelenmeyi sens eden 3 adet accelerometer ve yine her üç ekseninde sapma miktarını sens eden 3 adet laser gyroscopedan müteşekkildir. Zaman içerisinde oluşabilecek hataları telafi edebilmek için ihtiyaç duyulan düzeltme bilgisi belirli peryotlarla GNSS den alınır. Anlık rota, hesaplanmış hız, irtifa ve bulunulan pozisyon bilgisini ise sisteme entegre edilmiş bir bilgisayar tarafından hesaplanır ki genellikle seyirüsefer bilgisayarı olarak adlandırılır. Üç temel gyroscope vardır. Bunlar mekanik, optik ve mikro elektro-mekanik gyroscoplardır (Lawrence, 2012).

Herhangi bir eksendeki ivme miktarı bulunduktan sonra bir integral alıcı devre aracılığıyla hız, hız elde edildikten sonra ikinci bir integral alıcı devre aracılığıyla kat edilen yol bulunabilir. Bir elektronik toplayıcı sistem tüm hesaplamalar sonucunda kat edilen yola bağlı olarak rotayı çizebilir. Yani kinematik teorisine göre hareket halindeki bir cismin tüm hareket parametreleri, zamanın her anındaki ivmesi, ilk pozisyonu ve hızı bilindiği takdirde kolaylıkla hesaplanabilir.

Bu durum Newton'un ikinci hareket kanununa göre eşitlik (4.6)'da verilmiştir;

$$F=m.a \quad (4.6)$$

Burada;

F: Cisme uygulanan kuvvet.

m: Cismin kütlesi.

a: Kütlesi m olan cismin, uygulanan f kuvvetine karşın kazandıđı ivme miktarıdır.

Bir cismin ivmelenme miktarı bilinebilirse; buna bađlı olarak, cismin hızı ve yer deđiştirme miktarı kolaylıkla hesaplanabilir. Bu matematiksel ifadeler eşitlik (4.7), (4.8), (4.9) ve (4.10)'da verilmiştir.

$$V=ds/dt \quad (4.7)$$

$$a=dv/dt=d^2s/dt^2 \quad (4.8)$$

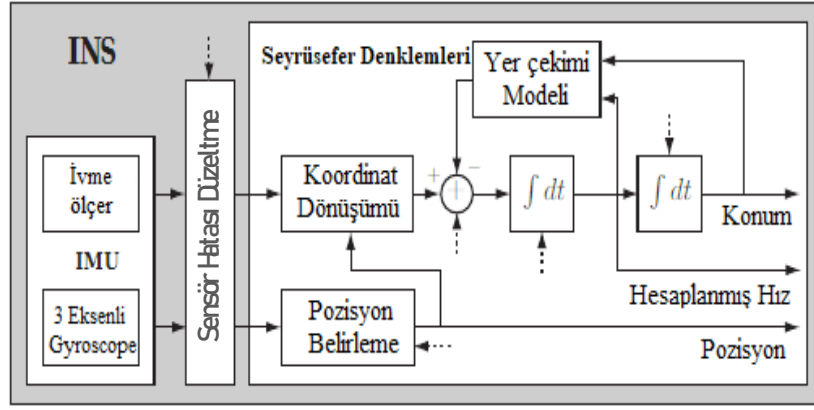
Dolayısıyla hız eşitlik (4.9)'daki gibi ifade kullanılarak bulunur.

$$V=\int a dt \quad (4.9)$$

Yol ise eşitlik (4.10) ifadesiyle elde edilir.

$$s=\int v dt = \iint a dt dt \quad (4.10)$$

Cisim hareket ettikçe cismin enlem ve boylam bilgisi, yani pozisyon deđişimi, cismin havadaki konumu, her üç eksenindeki ivme ve hızlar seyrüsefer bilgisayarına aktarılır. İtalet ölçme ünitesi, her bir eksenindeki cisim hareketini ve ivmelenmesini ölçen accelerometer ve açısal sapma miktarını hesaplayan gyroscopedan alınan bilgiler, seyrüsefer bilgisayarına verilir. Seyrüsefer bilgisayarını ise sürekli hesaplama sonucu, cismin anlık bulunduğu nokta, yer hızı, hava hızı, varış noktasının yönü ve varış noktasına olan mesafe gibi bilgileri kayıt altına alabilir, gösterge veya başka ünitelere iletebilir. Şekil 4.13'de bir INS'nin blok şeması gösterilmiştir (Skog ve Handel, 2009).




Şekil 4.13: INS Blok Şeması (Fundamentals of Strapdown Inertial and GPS-Aided Navigation - ppt video online download, t.y.).

4.7.1.1 Gimbaled Ins ve Strapdown Ins.

İki tür INS den bahsedebiliriz ki bunlardan birincisi klasik gimbaled INS (GINS) ve diğeri ise strapdown INS dir (SINS).

Gimbaled INS; iki eksenle hareket edebilen dengeleme sistemine bağlanmış INS'in, hareketi ölçülecek platforma sabitlenmesi temel montaj yöntemidir. Dengeleme halkaları (şekil 4.14^a) gyroscope sisteminden gelen açısal sapma miktarları kadar hareket ettirilmek üzere birer elektrik motoru tarafından sürülür. Bu sayede ivmeölçerlerin çıkışı, hareketli cismin hız ve konum bilgisini hesaplamak üzere doğrudan sisteme entegre edilmiş olur. Bu tür INS lerin yapısal sistemleri oldukça karmaşık, bakım maliyetleri yüksektir. Bu yüzden sınırlı uygulamalarda kullanım alanı bulurlar. Ancak kararlı çalışmaları ile dikkat çekici bir performansları vardır.

Strapdown INS ise elektronik teknolojinin gelişmesi ve yeni elektronik sensörlerin keşfedilmesi sayesinde hızla kullanım alanı bulmuş bir sistemdir. Bu sistemde hareketli dengeleme halkaları sistemden çıkarılmış ve bu sayede sistem hacimsel olarak küçültülmüştür. Strapdown INS'in yapısı Şekil 14.4b'de görülmektedir. Ayrıca yüksek bakım maliyetleri ortadan kalkmıştır. Bu sistemin gyroscope bilgileri ise mekanik gyroscope'ların yerine geliştirilen RLG (Ring Laser Gyroscope) lardan alınmaktadır. Sistemin arkasında, sistem bilgilerini sürekli olarak kontrol eden ve hızlıca, hız ve anlık pozisyon bilgileri hesaplayan güçlü mikroşlemciler bulunmaktadır.



Şekil 4.14: a) Gimbaled INS, b) Strapdown INS (Noureldin ve diğ., 2013^b).

Her iki INS sisteminin karşılaştırması Tablo 4.1’de verilmiştir.

Tablo 4.1: SINS ve GINS’in karşılaştırılması (Noureldin ve diğ., 2013^b).

Karakteristik	Strapdown INS	Gimbaled INS
Boyut	Görece küçük	Daha büyük
Ağırlık	Görece daha hafif	Ağır
Performans	Yüksek doğruluk	Çok yüksek performans
Sağlamlık	Son derece güvenilir, Şoklara ve vibrasyona karşı bağışık	Son derece güvenilir, Şoklara ve vibrasyona karşı düşük bağışıklık

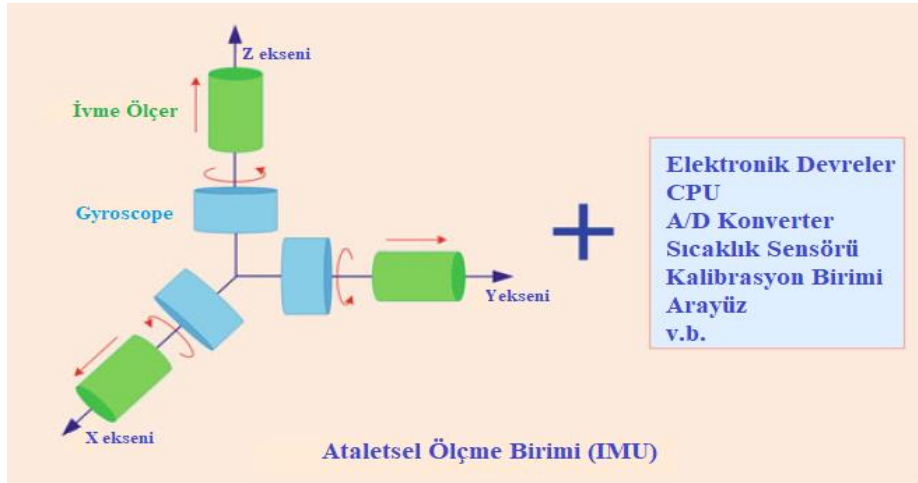
Temel yapısı itibari ile bir INS’in üç ana kısımdan oluştuğu düşünülebilir. Bunlar;

- IMU (Inertial Measurement Unit)
- Ön işlem birimi (Pre-Processing Unit)
- Hesaplama Birimi (Mechanization Unit)

4.7.1.2 Imu (Inertial Measurement Unit)

Şekil 4.15’te Tipik bir IMU’nun temel bileşenleri görülmektedir (Noureldin ve diğ., 2013^b). Burada da görüldüğü gibi sistemi birbirine dik olarak yerleştirilmiş ve karşılıklı çalışan 3 adet accelerometer ve 3 adet gyroscope oluşturmaktadır. Her biri, bir çift halinde sistem yapısına monte edilmiştir. Her bir atalet sensör çifti bir adet gyroscope ve bir adet accelerometer’dan oluşur. Ve bunlar birbirlerine dik üç eksen oluşturacak şekilde yerleştirilerek hareketli platformun üzerine sabitlenir. Sistem;

bünyesinde bir adet self test ünitesi de bulundurur ki başlangıç şartlarının oluşturması esnasında sensörlerin kalibrasyonunu yapar.



Şekil 4.15: Tipi Bir IMU' nun Bileşenleri (Noureldin ve diğ., 2013^b).

4.8 Görsel Odometri

4.8.1 Görüntü ve Görüntü İşleme

Görüntüler, birçok küçük parçadan oluşur ve her parça bir piksel olarak adlandırılır. Aslında her bir görüntü iki boyutlu pikseller düzlemidir. Pikseller, görüntünün çözünürlüğünü belirler ve her piksel, kırmızı, yeşil ve mavi renklerin (RGB) yoğunluğu ayarlanmasıyla oluşturulan farklı renkleri içerir. Bu sayede, çeşitli görüntüler elde edilir ve bilgisayarlar tarafından anlaşılabilir hale getirilir. Yani '0' ve '1' lere dönüştürülür. Kameralarda, 1280 x 720 veya 1920 x 1080 gibi sayılarla ifade edilen değerler çözünürlük değerleri olarak adlandırılır ve görüntünün yatay ve dikey uzunluklarındaki piksel sayısını ifade eder.

Bir başka ifadeyle görüntü: 3 Boyutlu nesnelerin 2 Boyutlu yüzey üzerine düşürülmüş haritası olarak tanımlanabilir. Bu haritalamada her noktanın konum bilgisi $f(x,y)$ ve renk bilgisi tutulur. Bu resimlerin insan gözünün görebileceği şekilde gösterilmesine ise İmaj diyebiliriz.

Öznelik algılama ve tanımlama algoritmaları görüntü işlemede sıklıkla kullanılan algoritmalar ve özellikle robotikte görsel eşzamanlı yer belirleme ve haritalama (VSLAM) “Simultaneous localization and mapping” amacıyla kullanılmaktadır (Se ve diğ., 2002; Steder ve diğ., 2008). Bu sistemler yüksek işlem gücü gerektirmektedir.

Evet, son yıllarda Uzaktan Algılama ve Fotogrametri alanlarında meydana gelen gelişmeler; yüksek konumsal, spektral, radyometrik ve zamansal çözünürlüklü çok boyutlu dijital görüntü verilerinin daha yoğun ve kapsamlı şekilde elde edilebilmesine olanak tanımıştır. Bu artış veri yoğunluğu, çeşitli temel işlemlerin otomatikleştirilmesini gerektirmiştir. Görüntü çakıştırma, en önemli uygulamalardan biridir ve çevresel izleme, değişim analizi, görüntü kaynaştırma gibi askeri veya sivil amaçlı faaliyetlerin önemli bir bölümünde gerçekleştirilmektedir.

Görüntü çakıştırma, aynı alana ait iki veya daha fazla sayıda, farklı görüş noktalarından, aynı veya farklı sensörlerle, aynı veya farklı zamanlarda kaydedilmiş görüntü verilerinin birbirleriyle eşleştirilmesi olarak tanımlanabilir. Bu işlem, özellikle ortamın değişimini takip etmek, yapıların 3 boyutlu modellenmesini oluşturmak veya hareketli nesnelerin izlenmesi gibi uygulamalar için gereklidir. Görüntü çakıştırma, birçok faktörden etkilenebilir ve çeşitli yöntemler kullanılabilir. Bu yöntemler arasında, manuel çakıştırma, temel özellik tabanlı çakıştırma, korrelasyon tabanlı çakıştırma ve yapay zeka tabanlı çakıştırma gibi yöntemler sayılabilir (Fonseca ve Manjunath, 1996). Literatürde dijital görüntülerin otomatik çakıştırılması probleminin çözümüne yönelik olarak birçok farklı yaklaşım geliştirilmiştir. Ancak, uydu/hava görüntüleri söz konusu olduğunda bu işlem önerilen metotlar ile yeterli doğruluk düzeyine ulaşılamayabilir. Bu, görüntüler arasındaki değişimlerin büyüklüğü, hareketli nesneler, yansıma veya gölgeler gibi faktörlerin etkisi gibi nedenlerden kaynaklanabilir. Bu nedenlerle çoğu zaman uydu/hava görüntüleri için çakıştırma işlemi manuel olarak gerçekleştirilmektedir. Manuel çakıştırma, görüntüler arasındaki benzerlikleri belirlemek için kullanılan bir yöntemdir. Bu yöntem, özellikle uydu/hava görüntülerinde çok sayıda görüntü verisi içerdiğinden, yüksek doğruluk ve hassasiyet sağlamaktadır. Ancak, manuel çakıştırma, çok zaman alıcı ve yorucu bir işlem olabilir. Bu nedenle, uydu/hava görüntülerinde çakıştırma işlemi için otomatikleştirilmiş yöntemlerin geliştirilmiştir (Gonçalves ve diğ., 2011; Zitová ve Flusser, 2003).

Uzaktan algılanmış görüntüler genellikle geniş alanlarda, çok çeşitli geometrik ve spektral karakteristiklere sahip yüzeylere ilişkin bilgi içeren veri setleridir. Görüntüler arasındaki değişimler nedeniyle karşılaştırma işlemi zorlaşmaktadır. Bu değişimler yüzey geometrisinden kaynaklanan rölyef etkileri, farklı alım noktası konumlarından oluşan geometrik deformasyonlar, alım zamanındaki farklı aydınlatma koşulları, görüntü radyometrisinde meydana gelen farklılıklar ve farklı sensör kullanımından kaynaklanan distorsiyon etkileri gibi nedenlerden kaynaklanmaktadır. Bu nedenlerden dolayı, uzaktan algılanmış görüntülerin otomatik karşılaştırılması işlemi, genellikle oldukça kapsamlı ve zorlu bir işlemdir (Yang ve diğ., 2017). Ayrıca, karşılaştırma sonucunda elde edilen doğruluk düzeyinin artırılması için, çeşitli yapay zekâ ve öğrenme algoritmalarının kullanımı önerilmektedir.

Uzaktan algılanmış görüntülerin otomatik karşılaştırma süreci genellikle aşağıdaki aşamalardan oluşur:

1. Özellik çıkarma: İlk olarak, görüntülerdeki özellikler çıkarılır. Bu, genellikle görüntülerdeki nesnelere konumları, şekilleri, yönleri veya renkleri gibi özellikleri içermektedir.
2. Özellik eşleştirme: İkinci olarak, çıkarılan özellikler arasında eşleştirme yapılır. Bu, genellikle özelliklerin konumları veya benzerlikleri gibi faktörlere dayanır.
3. Geometrik dönüşüm: Eşleştirilen özellikler arasında, görüntüler arasındaki geometrik farkları kapsayan bir dönüşüm bulunur. Bu dönüşüm, genellikle iki görüntü arasındaki farklı perspektif, yerçekimi veya hareket gibi faktörleri düzeltmek için kullanılır.
4. Yeniden örnekleme: Son olarak, görüntüler arasındaki geometrik dönüşüm kullanılarak yeniden örnekleme yapılır. Bu, görüntüleri birbirlerine eşleştirmek için kullanılan ölçek, açı veya konum gibi faktörleri içermektedir.

Uzaktan algılanmış görüntülerin otomatik karşılaştırması işlemi literatürde iki ana kategoriye ayrılır (Brown, 1992) : Alan tabanlı ve Özellik tabanlı.

1. Alan Tabanlı Karşılaştırma: Bu yaklaşım, görüntülerdeki nesnelere veya yüzeylerin konumlarına, şekillerine veya boyutlarına dayanır. Bu yaklaşım, görüntülerdeki nesnelere veya yüzeylerin konumlarını veya şekillerini belirli bir algoritma kullanarak tahmin etmeye çalışır. Bu tür yaklaşımlar, basit görüntüler için kullanılabilir olmalarına rağmen, daha zorlu görüntüler için çalışmakta zorluklar yaşayabilirler. Özellikle, yeterli ayırt edici detay

barındırmayan, monoton örüntüler içeren, gürültü oranı yüksek, karmaşık distorsiyon etkileri altında olan ve aralarında ciddi radyometrik farklılıklar bulunan görüntü çiftleri için, bu yaklaşımlar çakıştırma işlemi için uygun olmayabilir. Bu gibi durumlarda, görüntü çiftleri arasındaki farklılıkları azaltmak amacıyla pre-processing işlemleri veya daha sofistike özellik çıkarma ve eşleştirme algoritmaları kullanılabilir. Ayrıca, arama uzayının genişletilmesiyle dönüşüm hesaplamalarının kompleks ve zaman alıcı bir hale gelmesi de sözkonusudur. Bu nedenle, bu tür görüntülerin çakıştırılması için daha sofistike yöntemlerin kullanılması gerekebilir (Li ve diğ., 2009).

2. **Özellik Tabanlı Çakıştırma:** Bu yaklaşım, görüntülerdeki özellikleri kullanarak çakıştırma işlemi gerçekleştirir. Bu özellikler, görüntülerdeki nesnelere veya yüzeylerin renkleri, doğal görünümleri veya textürleri gibi özellikler olabilir. Bu yaklaşım, özellikleri kullanarak görüntüler arasında eşleştirme yapmaya çalışır. Özellik tabanlı yaklaşımlar, görüntüler içinde belirli özellikleri (kenar, köşe, eğri, spesifik bölge merkezleri gibi) çıkarmak için kullanılan algoritmalarla başlar. Daha sonra, bu özellikler arasındaki korelasyon düzeyi veya eşleştirme derecesi kullanılarak görüntüler arasındaki dönüşüm oranı bulunur. Bu aşamada elde edilen dönüşüm oranının doğruluğu genellikle optimization algoritması ile optimum seviyede çıkarılmak istenir. Bu algoritmaların performansı genellikle özelliklerin çıkarılması ve eşleştirme işlemlerinde kullanılan algoritmalara ve çıkarılacak özelliklerin niteliğine göre değişebilir (Acar ve diğ., 2017; Li ve diğ., 2009).

Aynı anahtar noktaları içeren iki görüntüdeki benzer bölgeleri belirlemek için kaynak görüntüdeki özneliğin, hedef görüntüdeki özneliklerden hangisine karşılık geldiğini bulmak gereklidir. Bu iş için ise öznelik tanımlama algoritmaları kullanılır. Başlıca öznelik tanımlama algoritmaları Binary Robust Independent Elementary Features (BRIFE), Binary Robust Invariant Scalable Keypoints (BRISK) ve Fast Retina Keypoint (FREAK)'dir (Alahi ve diğ., 2012; Calonder ve diğ., 2010). Hiç şüphesiz bu tür yaklaşımların özellik çıkarma aşamasında kullanılan; Harris (Harris ve Stephens, 1988), SUSAN (Smallest Univalued Segment Assimilating Nucleus) (Smith ve Brady, 1997), FAST (Features from Accelerated Segment Test) (Rosten ve Drummond, 2006), SIFT (Scale Invariant Feature Transform) (Lowe, 2004), SURF

(Bay ve diğ., 2008), vb. algoritmalar dönüşüm doğruluğu üzerinde önemli oranda etkili olabilmektedir.

Aynı anahtar noktaları içeren iki görüntüdeki benzer bölgeleri belirlemek için kaynak görüntüdeki özniteliğin, hedef görüntüdeki özniteliklerden hangisine karşılık geldiğini bulmak gereklidir. Bu iş için ise öznitelik tanımlama algoritmaları kullanılır. Başlıca öznitelik tanımlama algoritmaları Binary Robust Independent Elementary Features (BRIEF), Binary Robust Invariant Scalable Keypoints (BRISK) ve Fast Retina Keypoint (FREAK)'dir.

Uzaktan algılanmış görüntüler arasında değişkenlik gösteren, dönüklük, öteleme ve ölçek gibi konumsal dönüşüm parametrelerinden bağımsız, konum değişiklikleri ve aydınlatma şiddetinden kısmen bağımsız çalışabilmesi sebebiyle SIFT algoritması yaygın olarak kullanılmaktadır.(Ma ve diğ., 2017). SIFT algoritması, görüntülerdeki anahtar noktaları tespit etmek ve bu noktaları tanımlamak için kullanılan bir yöntemdir. Algoritma, her bir tespit edilen nokta için 128 boyutlu bir özellik vektörü oluşturur. Bu vektörler, noktanın etrafındaki piksel değerleri ve bu değerlerin değişimleri gibi görüntü içeriği ile ilgili bilgileri içerir. Ancak, SIFT algoritmasının en önemli dezavantajı oluşturduğu 128 boyutlu özellik vektörlerini kullanarak yapılan eşleştirme işlemlerinin zaman alıcı olmasıdır. Bu nedenle, SIFT yerine daha hızlı çalışan benzer algoritmalar kullanılabilir, ancak bu algoritmaların SIFT kadar güçlü olması beklenmeyebilir. Bu nedenle aynı koşullar altında eşlenik görüntüler üzerinde en az SIFT algoritması kadar iyi performans elde edebilmek ve işlem süresini önemli oranda azaltabilmek amacıyla (Bay ve diğ., 2008) tarafından SURF algoritması geliştirilmiştir.

Feature detection and description algoritmaları işlerini tamamladığında tespit edilen nokta sayısı, noktaların koordinatları ve noktaları tanımlayan bir veri kümesi (data set) elde edilir. Nokta koordinatları ve nokta tanımlarından oluşan veri seti Random Sample Consensus (RANSAC) algoritması ile regresyona sokularak homography matrisi olarak adlandırılan bir matris elde edilmektedir (Seçkin, 2017).

4.8.1.1 RANSAC ile Homografi Hesaplanması

RANSAC yöntemi ilk olarak 1981 yılında Fischler ve Bolles tarafından ortaya atılmıştır (Fischler ve Bolles, 1981). RANSAC algoritması ile iki görüntü arasındaki ilişkiyi belirlemek için kullanılan 3x3 homografi matrisi, dönme, ötelenme ve bozulma gibi değişkenleri tespit etmek için kullanılabilir. Algoritma, model olarak bir çizgi için 2 nokta eşlemesi veya model olarak bir homografi matrisi için 4 nokta eşlemesi kullanır. Bu matris, 2 boyutlu görüntüler arasındaki izdüşüm dönüşümünü ifade eder (Page, 2005).

RANSAC metodu, veri içinde gürültü içeren veya hata içeren noktaları ayıklamak için kullanılan bir yöntemdir. Metod, veri kümesinden rastgele seçilen alt kümelerin kullanılmasını ve bu alt kümelerin model oluşturulmasını içerir. Bu model, veri kümesindeki diğer noktalarla eşleştirilir ve modeli oluşturan noktalarla eşleşen noktalar "doğru" olarak kabul edilir. Bu işlem tekrar edilerek, iteratif olarak en yüksek "doğru" nokta oranına sahip model seçilir (Fischler ve Bolles, 1981). RANSAC, uzaktan algılanmış görüntülerin otomatik çakıştırılması sürecinde özellik çıkarma ve eşleştirme aşamaları sonucunda üretilen eşlenik noktalar arasında zayıf olanların elemine edilmesinde kullanılan bir yöntemdir (Page, 2005). Bu yöntem, homografi hesaplamak için gerekli olan eşleştirilmiş noktalar arasındaki zayıf eşlenikleri ve gürültüleri elemeye yarar. Çok-bakışlı eşlenik görüntüler arasında geometrik ilişki homografi yardımıyla kurulabilmektedir. Sonuç olarak, RANSAC, homografi hesaplaması için en yüksek doğruluk düzeyini elde etmek için kullanılan bir metottur.

Homografi matrisi, iki görüntü arasındaki geometrik dönüşümü ifade etmek için kullanılan bir matristir. Bu matris, görüntüdeki her bir noktanın ilişkisini tanımlar ve iki görüntü arasındaki benzerlik, afin, projektif veya diğer geometrik dönüşümleri ifade eder. Matematiksel olarak bu durum eşitlikde (4.11) verilmiştir.

$$x' = Hx \quad (4.11)$$

Projektif dönüşümler, bir görüntüdeki noktaların yerlerini değiştirmek için kullanılan geometrik dönüşümlerdir. Bu dönüşümler 8 serbestlik derecesine sahiptir ve dolayısıyla, homografi matrisi için 8 elemanı mevcuttur. En az 4 veya daha fazla sayıda eşlenik nokta çifti kullanılarak, homografi matrisinin elemanlarını hesaplamak

mümkündür. Bu eşlenik nokta çiftleri, her iki görüntüdeki aynı noktaları temsil eder ve dolayısıyla, görüntüdeki herhangi bir noktanın karşılığını bulmak için kullanılabilir. Bu eşlenik nokta çiftleri kullanılarak, homografi matrisinin elemanlarını hesaplamak için birçok farklı yöntem kullanılabilir. Örneğin, en küçük kareler yöntemi veya kullanılmış minimum kareler yöntemi gibi optimizasyon teknikleri kullanılabilir. Bu teknikler, homografi matrisinin en iyi uyumlu olduğu eşlenik nokta çiftlerini bulmak için kullanılır. Homografi matrisi eşitlikde (4.12) verilmiştir.

$$H = \begin{pmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{pmatrix} \quad (4.12)$$

Şeklinde tanımlanabilir. Buradaki değerlerden h_{11} , h_{12} , h_{21} ve h_{22} iki resim arasındaki ölçek farkı ve yön farkından kaynaklanan scale ve rotation matrislerinin çarpımıyla elde edilmektedir. h_{13} ve h_{23} değerleri ise iki resim arasındaki yer değiştirmeyle alakalıdır ve sırasıyla x ile y eksenlerindeki yer değiştirmenin piksel cinsinden değeridir.

RANSAC optimizasyon sonucunda, veri kümesi içindeki noktalar arasında eşleşme düzeyi yüksek olan güçlü noktalar kullanılır. Bu güçlü noktalar kullanılarak, homografi matrisi elemanları dengelemeli olarak hesaplanabilir. Bu hesaplamalar iki görüntü arasındaki projektif dönüşüm için gerekli olan tüm parametreleri elde etmek için kullanılır. Bu, homografi matrisi elemanlarının, veri kümesindeki en doğru ve en güvenilir noktalar arasındaki eşleşmeye dayandırılmasını sağlar, böylece daha iyi sonuçlar elde edilir.

Üç önemli parametrenin RANSAC yönteminde belirlenmesi gerekmektedir. Bunlardan birincisi (t) mesafe eşik değeridir. Bu hesaplama modelden alınan uyumlu verilerin mesafeleri için olasılık dağılımı gerektirir. Deneysel olarak bulunan bu değer genelde uygulamaya ve veri kümesine bağlıdır. Ancak, eğer ölçüm hatası, standart sapması (σ) ve ortalaması sıfır olan Gauss olarak varsayılırsa (t) uzaklık eşik değeri bulunabilmektedir. dI^2 , nokta mesafesinin karesi, kare Gauss değişkenlerinin toplamıdır. Modelin eşboyutunun (codimension) m'e eşit olduğu yerdeki m serbestlik derecesi için dağılımı aşağıda gösterilmiştir. Çizgi için eş boyutluluk (çizgiye dik mesafe ölçülmekte)'dir. $(X_m)^2$ rastgele değişkeninin değeri (cumulative chi-squared

distribution) kümülatif ki kare dağılımında verilen k^2 'den küçük olma olasılığı (4.13) eşitliğiyle ifade edilebilir.

$$F_m(k^2) = \int_0^{k^2} x_m^2(\zeta) d(\zeta) \quad (4.13)$$

Benzeşen veri ve benzeşmeyen veri ifadeleri sırasıyla eşitlik (4.14) ve (4.15) verilmiştir.

$$dl^2 < t^2 \quad (4.14)$$

$$dl^2 \geq t^2 \quad (4.15)$$

Bu durumda t^2 ifadesi ise eşitlik (4.16)'deki gibi yazılabilir.

$$t^2 = F_m^{-1}(\alpha) (\sigma)^2 \quad (4.16)$$

İkinci önemli parametre P , rastgele seçilen s alt kümelerinden en az birinin tüm verilerinin uyumlu veri olma olasılığı olsun. Bu değer genellikle $P = 0,99$ olarak seçilmektedir. ω seçilen herhangi bir verinin uyumlu veri olma olasılığı olsun. Bu durumda seçilen herhangi bir verinin uyumsuz veri olma olasılığı eşitlik (4.17)'deki gibi ifade edilebilir (Bahl ve Padmanabhan, 2000).

$$\epsilon = 1 - \omega \quad (4.17)$$

Böylece eşitlik (4.18) ifadesi elde edilir.

$$(1-P) = (1 - \omega^s)^N \quad (4.18)$$

Eşitlik (4.18)'deki N değerini bulmak için ise eşitlik (4.19) kullanılır.

$$N = \frac{\text{Log}(1-P)}{\text{Log}(1-(1-\epsilon)^s)} \quad (4.19)$$

Üçüncü önemli parametre ise T eşik değeridir. Bu değer uygulamaya ve veri kümesine bağlı olarak deneysel olarak belirlenmektedir. n veri noktası için T eşik değeri eşitlik (4.20)'de verilmiştir.

$$T = (1-\epsilon)n \quad (\text{Hartley ve Zisserman, 2003}). \quad (4.20)$$

RANSAC algoritması, veri kümesinden (D) rastgele seçilen 4 nokta eşlemesi kullanarak homografi matrisi (H) parametrelerini tahmin etmek için kullanılır. İlk olarak, homografi matrisi için gerekli olan parametreler belirlenir. Daha sonra, veri kümesinden rastgele seçilen 4 nokta eşlemesi kullanılarak homografi matrisi parametreleri hesaplanır. Bu homografi matrisi kullanılarak iki ayrı düzlemdeki noktalar aynı düzleme getirilir. Bu noktaların koordinatları "consensus set" (C) olarak adlandırılır. Eğer bu C "consensus set"teki noktalar ile diğer düzlemdeki noktalar arasındaki fark modele uygun olarak seçilen bir eşik değerinden büyükse, bu "consensus set"i oluşturan eşlemeler yeniden kullanılarak homografi matrisi parametreleri hesaplanır. Eğer bu fark eşik değerinden küçükse, veri kümesinden rastgele seçilen başka 4 nokta eşlemesi kullanılarak işlem tekrar edilir. Bu işlem N kere tekrar edildikten sonra, en çok doğru eşleme içeren "consensus set" seçilir ve bu setten M model parametreleri tekrar hesaplanır (Hartley ve Zisserman, 2003).

RANSAC algoritmasının bir dezavantajı, her problem için ayrı bir eşik değeri belirlenmesi ve sürekli hesaplama yapmasıdır. Ancak, yöntemin avantajı çok sayıda uyumsuz ölçü içeren veri kümelerinden istenen model parametrelerinin yüksek doğrulukla belirlenmesidir (Hartley ve Zisserman, 2003).

4.8.2 Optik Akış (Optical Flow)

Optik akış; görüntü üzerindeki kenar, yüzey gibi tanımlayıcılar kullanılarak nesnelerin belirli bir gözlem düzlemine göre hareketinin hesaplanması sonucu ortaya çıkan bilgidir. Optik akış sayesinde platformda yer alan kamera aracılığıyla alınan görüntüler kullanılarak görüntüde yer alan objelerin hareketi ve platformun piksel uzayındaki hareketi kestirilebilir. Optik akış temelde birbirine yakın zamanlarda kaydedilen iki görüntünün aynı parlaklık değerinde olduğunu kabul ederek iki görüntü arasındaki hareketi hesaplar. Optik akış ile bir noktanın ardışık görüntülerde benzer görünümde olacağı ve çevresindeki noktalarla benzer hareket edeceği varsayılarak hareket tespit edilir. Optik akış sayesinde platformun piksel uzayındaki hareketi kestirilebildiğinden dolayı optik akışın navigasyon amaçlı kullanımı mümkündür. Fakat optik akış hesaplanırken zorlu ve karmaşık ortamların tümünde kullanılacak, aynı başarımla çalışabilecek sensör seti olmadığı için mevcut duruma uygun seçilen

sensör setlerinin optimum başarı için entegre edilmesi önem kazanmaktadır. Navigasyon sensörlerini entegre etmenin klasik yöntemi Kalman filtresidir. Kalman ve türevi filtreler ile çok sayıda farklı sensör entegre edilebilir. IMU ve yükseklik verisinin, optik akış sonuçlarıyla birleştirilmesi ile otonom hava araçlarının anlık pozisyon ve yönünü kestirmek mümkündür.

Lucas ve Kanade 1981 yılında 3x3 piksellik bir bölgede birbirine komşu olan piksellerin parlaklık değerlerinin birbirine eşit olduğu varsayımını kullanarak optik akışı hesaplamış ve bu alandaki çalışmaların öncüsü olmuştur (Lucas ve Kanade, 1981). Bouguet (Bouguet, 2001) tüm görüntü üzerindeki pikseller için optik akış hesaplamak yerine görüntü üzerindeki bazı öznitelikleri kullanarak optik akış hesaplamayı önermektedir. Bu algoritma Shi ve Tomasi (Shi ve Tomasi, 1994) tarafından sunulan köşe noktalarını bulmakta ve bu köşe noktalar üzerinden optik akış hesaplamaktadır. Bu yaklaşıma seyrek optik akış (sparse optical flow) denilmektedir. Optik akış örnekleri Şekil 4.16, 4.17 ve 4.18’de verilmiştir.


Değişimsiz özellik dönüşümü; yerel öznitelikleri çıkarmak için en çok kullanılan yöntemlerden biridir. Bu işlemde öncelikle görüntü üzerinde hangi ölçekte çalışılacağı bulunmaktadır. Daha sonra anahtar noktaların yeri tespit edilir. Son aşamada ise oryantasyon belirlenir ve anahtar nokta tanımlayıcıları çıkarılır. Anahtar nokta tanımlayıcıları anahtar nokta etrafından toplamda 128 tane vektör hesaplamaktadır (Lowe, 1999).



Şekil 4.16: Optik akış örneği I.



Şekil 4.17: Optik akış örneği II.



Şekil 4.18: Gerçek zamanlı Optical Flow (Schuster ve diğ., 2018).

4.8.2.1 Pearson Korelasyon Katsayısı (r)

En az eşit aralıklı ölçek düzeyinde ölçülen iki sürekli değişken arasındaki doğrusal ilişkinin derecesinin belirlenmesinde kullanılan Pearson korelasyon katsayısı, A ve B değişkenleri arasında manidar bir ilişki var mı sorusunun cevabını arar. Pearson korelasyon katsayısı -1 ila $+1$ arasında değerler alır. $r=-1$ ise negatif lineer bir ilişki vardır. $r=+1$ ise pozitif lineer bir ilişki vardır. $r=0$ ise değişkenler arasında bir ilişki yoktur.

5. YÖNTEM

Bu çalışmada simülasyon üzerinde öncelikle bir depo ortamı hazırlanmıştır. Hazırlanan simülasyon üzerinden rastgele rotalar izlenerek veri toplama işlemi gerçekleştirilmiştir. Dronun üç ekseninde hareketine ek olarak aynı zamanda sapma ve yunuslama (yaw ve pitch) hareketlerini de yapması sağlanmıştır. Simulasyon üzerinde gezinim sırasında, dron herhangi bir yönde her seferinde 5 cm'lik adımlarla hareket ettirilmiş, her hareket esnasında dron üzerindeki kameranın da en az bir kamera görüntüsü alması sağlanmıştır. Alınan görüntüde bulunan ArUco etiketinin varlığı tespit edilmiş ve etiket ID'sine göre etiketin var olup olmadığı, etiketin kameradaki piksel cinsinden koordinatları ve etiketin alanı hesaplanmıştır. Hava aracının gerçek konum bilgisi ise makine öğrenmesi tahminlemede çıkış değeri olarak kullanılmak üzere alınmaktadır. Her konum verisi için bir regresyon modeli oluşturulmuştur. Regresyon modelleri ile hava aracının kamerasının AR etiketleri gördüğü her yerde anlık konum ve poz tahmini üretilmiş ve hata değeri hesaplanmıştır. Gerçek konumu simülasyon sistemi sayesinde bilinen dron için toplanan Sanal Referans İşaretçi (Virtual Fiducial Marker-VFM) verileri makine öğrenmesi üzerinde kullanılmış ve konum tahminlemesi gerçekleştirilmiştir. Bu işlem için toplam 11703 noktadan veri toplanmıştır. Bu veriler test ve eğitim verisi olarak bölünmüştür. 8778 veri eğitim, 2925 veri test verisi olarak kullanılmış, verilen bir rota üzerinde konum tahmini gerçekleştirilerek sistemin çalışması sınanmıştır.

5.1 Kullanılan Simülasyon Programı CoppeliaSim

Eskiden V-REP olarak bilinen CoppeliaSim, endüstride, eğitimde ve araştırmada kullanılan bir robot simülatörüdür. Entegre geliştirme ortamına sahip robot simülatörü CoppeliaSim, dağıtılmış bir kontrol mimarisine dayanmaktadır: Her nesne/model, gömülü bir komut dosyası, bir eklenti, bir ROS veya BlueZero düğümü, bir uzak API istemcisi veya özel bir çözüm aracılığıyla ayrı ayrı kontrol edilebilir. Bu, CoppeliaSim'i çok yönlü ve çok robotlu uygulamalar için ideal kılar. Kontrolörler C/C++, Python, Java, Lua, Matlab veya Octave ile yazılabilir.

CoppeliaSim, hızlı algoritma geliştirme, fabrika otomasyon simülasyonları, hızlı prototip oluşturma ve doğrulama, robotik ile ilgili eğitim, uzaktan izleme, güvenlik çift kontrolü, dijital ikiz olarak ve çok daha fazlası için kullanılır (CoppeliaSim Features - Coppelia Robotics, t.y.).


- CoppeliaSim, robot simülatörleri arasında tam bir "İsviçre çakısı"dır; daha fazla fonksiyon içeren, daha özellikli ve birçok özel API içeren bir simülatördür.
- Çapraz platform (Windows, MacOS, Linux),
- 6 programlama yaklaşımı (gömülü script'ler, plugin'ler, add-on'lar, ROS node'lar, uzak API ,BlueZero node'lar),
- 6 programlama dili (C/C++, Python, Java, Lua, Matlab ve Octave),
- 400'den fazla farklı API fonksiyonu,
- 4 fizik motoru (ODE, Bullet, Vortex, Newton),
- Integrated ray-tracer (POV-Ray),
- Tam kinematik çözücü (Herhangi bir mekanizma için Ters Kinematik ve İleri Kinematik),
- Sayısal ağlar arası girişim tespiti (meshes, OC trees and point clouds),
- Sayısal ağlar arası en kısa mesafe tespiti (meshes, OC trees and point clouds),
- Güzergâh planlama (2-6 boyutta holonomik, taşıt benzeri yapılar için holonomik olmayan),
- Entegre görüntü işleme özelliğine sahip (tamamen genişletilebilir) görüntü sensörleri,
- Gerçekçi mesafe sensörleri (algılama hacmi içerisinde en kısa mesafe hesaplaması),
- Entegre özelleştirilmiş kullanıcı arayüzleri,
- Tamamen entegre Reflexxes Hareket Kütüphanesi tip 2 + RRS-1 interface specifications,
- Veri kaydetme ve görselleştirme (zaman grafiği, X/Y grafiği veya 3B eğriler),
- Entegre şekil düzenleme modları,
- Su ve hava jeti simülasyonları için dinamik partiküller,
- Sürükle-bırak fonksiyonuna sahip Model Listeleyici (simülasyon esnasında da aktif),

Çoklu geri al/yinele, video kaydedici, boyama simülasyonu, detaylı dokümantasyon, vb. özellikleri ile kayda değer bir simülatör olduğu tartışma götürmezdir.

5.2 Simülasyon Ortamı ve Veri Toplama

Kapalı alan simülasyonu olarak bir depo alanı tasarlanmıştır. CopelliaSim simülasyon programında sistemin çalışmasını simüle edebilmek için 10mx15m ebatlarında kapalı alan depo simülasyon ortamı hazırlanmıştır. Depo alanının ortasına ve etrafına 6 gözlü, bir dizi toplamda 27 adet raf konumlandırılmıştır. Raflar depo alanının iki köşesinde 90⁰'lik açı oluşturacak şekilde kalan diğer iki köşede ise 135⁰'lik açı oluşturacak şekilde yerleştirilmiştir. Her bir rafa, farklı sayı, renk ve ebatta kutular eklenmiştir. Depo alanında bulunan toplam 303 kutunun her birine bir barkod etiketi ilave edilmiştir. Barkod etiketleri her bir kutunun sağ üst köşesine yapıştırılmıştır. Ayrıca simülasyonda kullanılan toplam 27 rafın her biri 6x6'lık ArUco tipi etiket kullanılarak etiketlenmiştir. ArUco etiketlerinin konumları her rafın sağ üst köşesi olarak ayarlanmıştır ve saat yönünün tersi yönde numaralama yapılmıştır. Hazırlanan simülasyon ortamı Şekil 5.1(a, b)'de gösterilmiştir. Simülasyon ortamında her üç ekseninde hareket ettirilmesi planlanan dronun, her seferinde tek bir ekseninde 5 cm'lik adımlarla hareket etmesi sağlanmıştır. Dronun her bir adımdaki yaw açısı da 5⁰ olarak belirlenmiştir. Yani 360⁰'lik tam bir dönüşü 72 adımda gerçekleştirmektedir. Dronun uçuşu sırasında, gerçek dinamiklerinde olduğu gibi salınım yapmasına müsaade edilmiştir. Simülasyon ortamında hareket esnasında hava aracının konum, IMU ve dron kamera bilgileri alınmaktadır. Herhangi bir ekseninde ve rotasyonda hareket eden dronun her bir adımında bir kare kamera görüntüsü alması sağlanmıştır. Kameradan alınan görüntüden Artırılmış Gerçeklik (Augmented Reality-AR) etiketleri okunmakta ve etiket ID'sine göre etiketin var olup olmadığı, etiketin kameradaki piksel cinsinden koordinatları ve etiketin alanı bulunmaktadır. Kamera görüntüsünden, raflarda bulunan kutular üzerindeki barkodlar da okutulmuştur. Alınan barkod verisi stok kontrolü ve depo alanı doluluk oranı tespiti için kullanılmıştır. Bu verilere ek olarak hava aracının pusula bilgisi de alınmıştır. Hava aracının gerçek konum bilgisi ise makine öğrenmesi tahminlemesinde çıkış değeri olarak kullanılmak üzere alınmaktadır. Her konum verisi için bir regresyon modeli oluşturulmuştur. Regresyon

modelleri ile hava aracının AR etiketleri gördüğü her bölgede anlık konum ve poz tahmini gerçekleştirilerek, hata değeri hesaplanmıştır.




Şekil 5.1: Kapalı alan simülasyon ortam görüntüleri.

5.3 Referans İşaretçilerinin Algılanması ve Simülasyon Ortamına Yerleştirilmesi

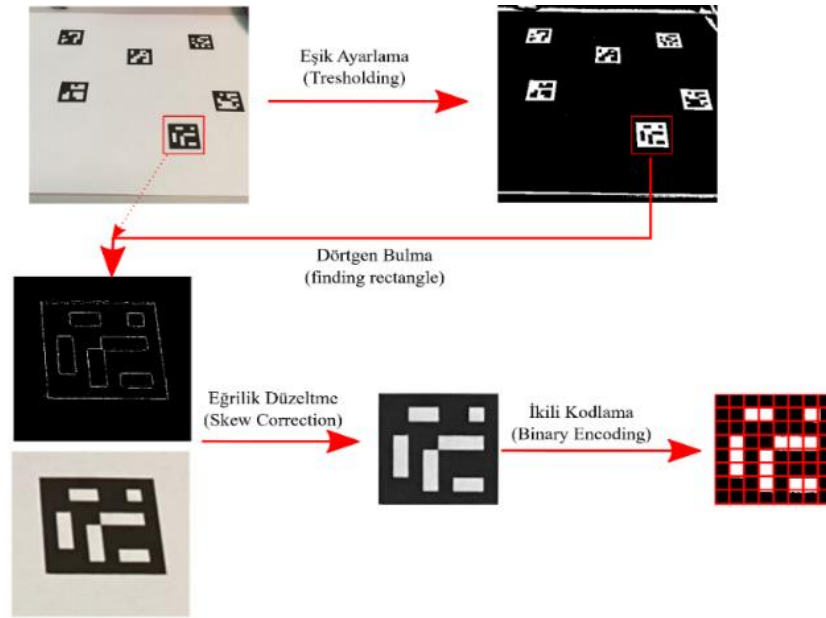
Bir ortamdaki hareketli nesneyi bulmak için kullanılabilen işaretli ve işaretsiz görüntü tabanlı iki teknik mevcuttur. Hedefin renkleri, desenleri ve özelliklerinin çıkartılarak resimler arasındaki farkın karşılaştırıldığı işaretsiz izleme yöntemine ilave olarak bir de kameralarla donatılmış cihazlarda kullanılan işaretli izleme yöntemleri mevcuttur. İşaretli izleme yönteminde çıkarılan özelliklerin hiçbirinin önceden bilinme zarureti yoktur. Ancak özellik çıkarma ve eşleştirme işlemleri yüksek hesaplama gerektirmektedir. Bu hesaplama işlemi ise bir hayli zaman alır. Bunun aksine işaretçilerle yapılan poz bilgisi hızlı ve doğru bir şekilde gerçekleştirilebilmektedir. Bu durum işaretçilerin kullanıldığı uygulamalarda bir avantaj olarak karşımıza çıkar.

Görsel Referans İşaretçileri (Virtual Fiducial Marker-VFM), yapay görme sistemleri tarafından kullanılmak üzere ortaya çıkarılmış bir tür grafik işaretçidir. İşaretçinin konum ve pozlarının yüksek doğrulukta ve hassasiyette en hızlı şekilde algılanabilmesi bu işaretçilerin ana amacıdır. Bu grafik işaretçiler düz bir zemin üzerinde kullanılmak üzere geliştirilmişlerdir. Her bir işaretçinin kendine has bir kimliği ve bu kimliğe karşılık gelen, bilgisayarlı görme algoritmaları tarafından tanınan bir grafik gösterimi vardır. Bunlar arttırılmış gerçeklik, robotik, tıp, havacılık, meteoroloji, fizik gibi alanlarda kullanılmaktadır (Zakiev ve diğ., 2020). Yapılan çalışmalarda çok farklı türden VFM çeşidiyle karşılaşılabilir. İstenirse her türden ve biçimde kendi VFM etiketlerimizi oluşturmakta mümkündür. En yaygın kullanılanlardan çeşitlerinden birkaç örnek ikincikez Şekil 5.2'de verilmiştir.



Şekil 5.2: Sık kullanılan ArUco Marker türleri (Garrido-Jurado ve diğ., 2014).

ArUco etiketleri görüntü işleme tekniklerinde kullanılan en yaygın görsel VFM türüdür. ArUco işaretçileri, birbirine benzemeyen beyaz kare kutucuklardan oluşur. Bu beyaz kutucuklar, diğer objelerden ayırt edilebilir ve kameralar tarafından daha kolay tespit edilebilirler diye siyah bir zemin üzerine yerleştirilmiştir. Her bir ArUco marker bir ikili (binary) koda karşılık gelen özel bir bilgi yığınına işaret eder. ArUco markerların fraktal, dairesel, kare türden olanlarına daha sık rastlanmaktadır (Nogar, 2020). Şayet özel olarak bir ArUco marker üretilmemişse en çok kare formda olanına rastlanır. Genellikle ebatları 3x3, 4x4, 5x5, 6x6, 7x7 dir. ArUco etiket bulma işlemi Şekil 5.3’de gösterilmiştir. Bu işlemde önce seçilen bir eşik değerine göre görüntü ikili değer haline getirilir. Seçilen eşik değeri Aruco markerler siyah zeminli olduğu için oldukça siyaha yakın bir değere sahiptir. Sonuç, ikili bir görüntüdür. Kare şekilli bir AR işaretçisi kullanılmış ise ikili görüntüde siyah kareler aranır. Daha sonra algılanan siyah kare, tam kare yapmak için döndürme, ölçekleme ve eğrilik için düzeltilir. Kare görüntüdeki ikili değerler aranan marker kodlama tipine göre ızgara halinde bölünür. Şekil 5.3’deki örnekte 8x8 ızgara kullanılmıştır. Her kareye gelen kod işaretçi kodu olarak atanır (Kato ve diğ., 2000). Kodlama sayesinde markerin yönü, oryantasyonu ve kodu (ayraç değeri) çıkarılabilmektedir.



Şekil 5.3: ArUco etiket algılama.

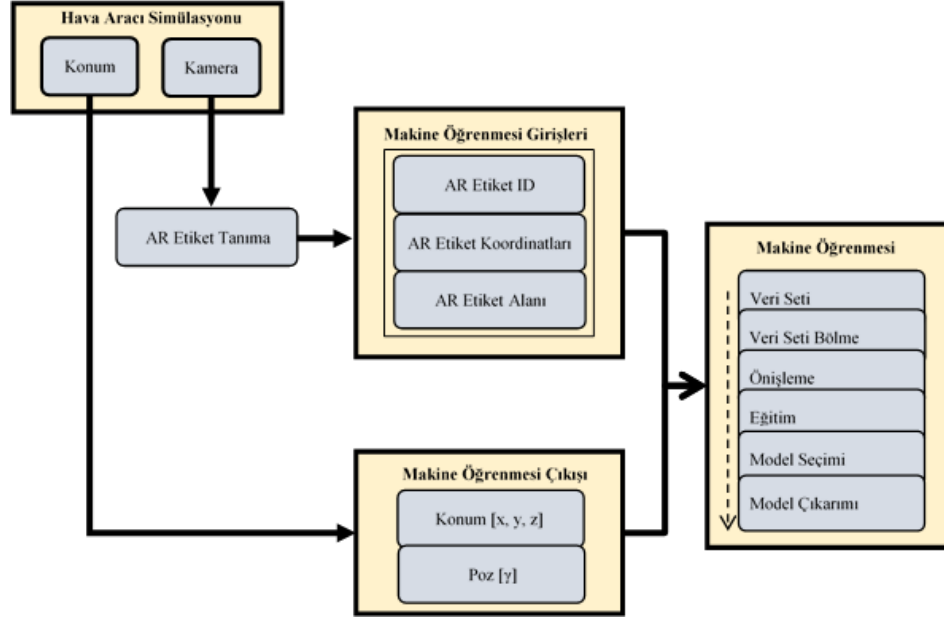
ArUco markerlar poz tahmini içinde kullanılabilirler ki bu durum mesafe ölçümü yapmayı da mümkün kılar. Ancak ArUco markerların poz tahmininde kullanılması sırasında karşılaşılan düşük algılama verimliliği ve algılanma oranı,

ölçüm sonucunu büyük oranda etkiler (Wang ve diğ., 2020). Derinlik algılama/ölçme ve hedef tespiti endüstriyel otomasyon sistemlerinde büyük bir öneme sahiptir. 1960'lı yılların sonlarında ortaya çıkan monoküler görüş tabanlı görüntü işleme, basit ekipman gereksinimi, ucuz maliyet ve kolay çalışabilme özellikleriyle popüler olmuştur (Wang ve diğ., 2020). Mesafeyi görüntü işleme teknikleri kullanarak tespit etmek için birçok bilim insanı perspektif görüntüleme tekniği üzerine çalışmıştır. Bu teknikte hedefin pozunu tahmin ederek mesafe ölçmek mümkün olmaktadır. Yüksek tespit oranı ve düşük yanlış pozitif oranı elde etmek için Rafael Munoz ve Sergio Garrido (Garrido-Jurado ve diğ., 2014; Wang ve diğ., 2020), tarafından önerilen ArUco markerlar, markerlar arası mesafeyi ve bit geçişlerinin sayısını maksimize etmeyi amaçlar. Poz tahmininde kullanılan markerların dört köşe noktası, düz çizgi uydurma ile elde edilen dört kenarın kesişim noktasıdır. Köşe titreme sorunu vardır ve köşe koordinatlarının doğruluğu düz çizgi uydurma doğruluğundan büyük ölçüde etkilenir (Wang ve diğ., 2020). ArUco markerlar AR uygulamalarında çok sık bir şekilde kullanılmaktadır. Son zamanlarda kapalı ortamlarda ve GPS sinyallerinin alınmadığı bölgelerde güvenli bir navigasyon yöntemi olması nedeniyle tercih edilmektedirler. Özellikle dron ve helikopterlerin (Vertical TakeOff and Landing-VTOL) iniş ve navigasyonu için araştırmacıların sıkça kullandığı bir yöntem haline gelmiştir.

5.4 Makine Öğrenmesi Algoritmaları ve Regresyon

Sistemde hava aracının anlık topladığı görüntülere dayalı konumlandırma yapabilmesi amaçlanmıştır. Tasarlanan sistemin nasıl çalıştığını gösteren blok diyagram Şekil 5.4'te gösterilmiştir. Sistemin makine öğrenmesi aşamasında denetimli öğrenme ile regresyon kullanıldığı için, veri toplama işleminde giriş ve çıkışların öncelikle tanımlanması gerekmektedir. Sistemde giriş olarak VFM etiket numaraları (AR Etiket ID), etiketin kameradaki piksel cinsinden x ve y eksen koordinatları (AR Etiket Koordinatları) ve etiketin kameradaki piksel cinsinden alanı (AR Etiket Alanı) kullanılmıştır. Regresyon çıkışı olarak aracın simülatördeki gerçek konumu x, y, z ve z eksenindeki dönmeyi ifade eden poz açısı (yaw) γ kullanılmıştır. Veri seti %75 eğitim %25 test olacak şekilde bölünmüştür. Veri bölme ardından eğitim verileri üzerinde standartlaştırma yapılmıştır. Eğitim aşamasında sonraki kısımda belirtilen

öğrenme algoritmaları kullanılmış ve algoritmalarından elde edilen regresyon metriklerine göre en yüksek performans gösteren algoritma model olarak seçilmiştir.



Şekil 5.4: Makine öğrenmesi ve görsel referans işaretleyiciler ile anlık konumlandırma sistemi.

5.5 Regresyon Algoritmaları

5.5.1 K En Yakın Komşular

K En Yakın Komşu (K-Nearest Neighbors, KNN) algoritması, en yakın k-komşunun değerlerine göre çalışan bir öğrenme algoritmasıdır. KNN algoritması, hem sınıflandırma ve hem de regresyon için parametrik olmayan bir yöntemdir (Altman, 1992). İlk olarak haber makalelerinin sınıflandırılması için uygulanmıştır (Masand ve diğ., 1992). KNN algoritması ile öğrenme yapılırken incelenen veri setinde öncelikle her bir verinin diğerine olan uzaklığı hesaplanır. Bu uzunluk hesabı Öklid, Manhattan veya Hamming uzaklık fonksiyonu ile yapılır. Daha sonra her bir veri için en yakın K komşunun ortalaması hesaplanır. K değeri, KNN algoritmasının tek hiper parametresidir. K değerine karar verirken, K değeri çok düşükse sınırlar titreşecek ve fazla sığma durumu, K değeri çok yüksekse ayırım sınırları daha düzgün olacak ve

eksik sığma durumu ortaya çıkacaktır. KNN algoritmasının dezavantajı, veri miktarı arttıkça işlem yükünü arttırdığı için mesafe hesaplama işlemidir.

5.5.2 Adaptive Boosting

Adaptive Boosting (AdaBoost) algoritması, bir tür topluluk yöntemi adı verilen bir Makine Öğrenimi yöntemidir. Bu yöntemin amacı, zayıf öğrenenleri kullanarak daha güçlü bir öğrenme yapısı oluşturmaktır. AdaBoost, herhangi bir makine öğrenimi algoritmasının performansını artırmak için kullanılabilir. Ancak, bu yöntem genellikle zayıf öğrenen bir algoritma olarak tek seviyeli bir karar ağacı algoritması kullanır; çünkü süreç yükü diğer temel öğrenme algoritmalarından çok daha düşüktür. AdaBoost algoritması dört temel adımdan oluşur. İlk adımda N adet zayıf algoritma çalıştırılır ve veri seti öğrenilir. Bu N adet zayıf öğrenme algoritmasının her birine $1/N$ ağırlık değeri atanır. İkinci adımda, her öğrenen algoritmanın hata değerleri hesaplanır. Üçüncü adımda, yüksek miktarda hata içeren öğrenme algoritmasının ağırlık değeri artırılır. Dördüncü adımda, öğrenme algoritmaları ağırlıklarla toplanır ve istenen metrik sınıra ulaşırsa toplam algoritma çıktısı alınır, aksi takdirde ikinci adıma geri dönülür (Freund ve Schapire, 1996, 1997; Bertoni ve diğ., 1997). Bu algoritmada öğrenen sayısı arttıkça süreç yükü ve öğrenme performansı artmaktadır.

5.5.3 Rastgele Orman (Random Forest)

RF yöntemi, birçok DT'den oluşan bir orman şeklinde tasarlanmıştır. Ormandaki her bir karar ağacı, önyükleme tekniği ile orijinal veri setinden örneklem seçilerek ve her bir karar düğümündeki tüm değişkenlerin rastgele sayısı seçilerek oluşturulur. RF algoritması dört temel adımdan oluşur. Her şeyden önce, toplam m özellikten rastgele n özellik seçilir. İkinci adım için, n özellik arasından en iyi ayırma noktasını belirlenerek d düğümünü hesaplanır. Üçüncü adımda hedefe ulaşılan son (yaprak) düğüm sayısının kontrol edilmesi gereklidir. Eğer birinci adıma geçilmiyorsa bir sonraki adıma geçilir. Son adım için, n (ormandaki ağaç sayısı) kez için birden üçe kadar olan adımları tekrarlayarak orman oluşturulur (Breiman, 2001; Liaw ve Wiener, 2002; Akman ve diğ., 2011).

5.5.4 XGBoost (Extreme Gradient Boosting)

2016 yılında, Tianqi Chen ve Carlos Guestrin tarafından Washington Üniversitesi'nde yayınlanan “A Scalable Tree Boosting System” adlı makale ile duyurulan XGBoost algoritması, Gradient Boosting algoritmasının optimize edilmiş daha performanslı halidir. Aşırı gradyan artırma algoritması olarak da adlandırılan XGBoost algoritması, hem doğrusal model hem de karar ağacı topluluklarından oluşan hız ve kalite için tasarlanmış gradyan artırma yönteminin geliştirilmiş bir uygulamasıdır (Adithya ve Deepak, 2021). Karar ağacı tabanlı olan bu makine öğrenme algoritması, boş verilerle çalışabilmesi, aşırı öğrenmeyi engelleyebilmesi ve yüksek tahmin gücüne sahip olması gibi özellikleriyle, karar ağacı tabanlı makine öğrenme algoritmaları içerisinde en başarılılarından biri sayılabilir. Bu algoritma diğer tüm makine öğrenme algoritmalarından çok daha hızlı çalışabilir. Sınıflandırma ve regresyon problemlerinin çözümünde kullanılabilir.

5.5.5 Yapay Sinir Ağları-Çok Katmanlı Algılayıcı (Multilayer Perceptron)

Yapay sinir ağları, canlıların sinir sisteminden ilham alan hesaplamalı modellerdir. Bilgi edinme ve sürdürme yeteneğine sahiptirler (bilgiye dayalı-information based) ve vektörler ve sinaptik ağırlık matrisleri tarafından uygulanan birçok ara bağlantıyla (yapay sinapslar- artificial synapses) birbirine bağlanan yapay nöronlar tarafından temsil edilen bir dizi işlem birimi olarak tanımlanabilirler. Yapay sinir ağları; evrensel eğri uydurma, proses kontrolü, örüntü tanıma ve sınıflandırma, veri kümeleme, sistem optimizasyonu gibi birçok alanda sıklıkla kullanılmaktadır. Çok katmanlı yapay sinir ağları ise, tek katmanlı olanların aksine bir veya daha fazla gizli sinir katmanından oluşur. Örüntü sınıflandırması, sistem tanımlaması, süreç kontrolü, optimizasyon, robotik vb. gibi alanlarda çeşitli problemlerin çözümünde kullanılırlar (da Silva ve diğ., 2017). Çok Katmanlı Algılayıcı (MultiLayer Perceptron-MLP) ağı, girdi katmanı ile ilgili çıktı katmanı arasına yerleştirilen en az bir ara (gizli) sinir katmanına sahiptir. Sonuç olarak, MLP ağları en az iki sinir katmanına sahiptir ve nöronları ara ve çıkış katmanları arasında dağıtılır. MLP ağları ayrıca farklı bilgi alanlarından çeşitli problemlerde geniş uygulama alanları ile bilinir ve ayrıca uygulanabilirlik açısından en çok yönlü mimarilerden biri olarak kabul edilir. Bu

potansiyel alanlar arasında en önemlileri şunlardır: Eğri uydurma, desen tanıma, proses tanımlama ve kontrol, zaman serisi tahmini (tahmin), sistem optimizasyonu. MLP ağları, eğitimi denetimli bir süreçle gerçekleştirilen çok katmanlı ileri beslemeli mimariye sahiptir. Ağ içindeki bilgi akışı girdi katmanında başlar, ara katmanlardan geçer ve çıktı sinir katmanıyla biter. Ayrıca, geleneksel MLP ağları, çıktı sinir katmanı veya ara sinir katmanları tarafından üretilen herhangi bir değer geri beslemesine sahip değildir (da Silva ve diğ., 2017). Doğrusal olmayan (non-linear) sistemlerde başarılı sonuçlar üreten Çok katmanlı algılayıcı (Multilayer Perceptron) algoritmasının, geri fazında ağırlık güncellerken hidden katmanındaki ağırlıklar ve output katmanındaki ağırlıklar ayrı ayrı güncellenir. Algoritmanın genelleştirilmesi için momentum kat sayısı kullanılır. Veri setindeki değerlerin ise normalize edilmesi gerekmektedir.

5.6 Performans Değerlendirme ve Model Seçimi

Bir dizi model değerlendirme tekniği vardır, ancak en iyi bilinenlerden bazıları yüzde bölme ve çapraz doğrulamadır. Değerlendirme süreçlerinde eğitim ve test veri seti kullanılması esastır. Yüzde bölme en temel yöntemdir. Bu yöntemde tüm veriler eğitim olarak bölünür ve manuel olarak test edilir. Öğrenme süreci için eğitim veri seti, performans değerlendirmesi için test veri seti kullanılmaktadır. Ancak veri setindeki eğitim ve test verilerinin seçiminde aynı dağılımın olmaması, aykırı değerlerin eşit dağılmaması vb. nedenlerle değerlendirme sonuçları güvenilir olmayabilir. Bu nedenle Çapraz Doğrulama yöntemi geliştirilmiştir. Bu yöntemde eğitim ve test verileri entegre edilerek tek bir veri setine dönüştürülür. Tüm veriler K eşit büyüklükte alt kümelere bölünmüştür. Kat sayısı olarak da adlandırılan K değeri kullanıcı tarafından belirlenir. Ardından, K alt kümelerinin her biri için öğrenme ve test yapılır; burada alt kümelerden biri test edilecek, diğeri ise eğitim veri seti olacaktır. Sonuç olarak, her bir alt küme için performans metrikleri elde edilir. Performans metriklerinin ortalaması, K-Fold Çapraz Doğrulamanın performans metriği olarak kabul edilir. K-Fold Cross Validation yönteminin diğeri yöntemlere göre daha güvenilir sonuçlar ürettiği bilinmektedir. Ancak her alt küme için öğrenme ve test etme, tüm alt kümeler için ayrı ayrı yapıldığından toplam süre diğeri yöntemlere göre daha uzundur (Alpaydın, 2009). Performans değerlendirmesi ve model seçimi için kullanılan ana kriterlere metrik denir. En sık kullanılan regresyon metrikleri, Ortalama Kare Hatası (Mean Square

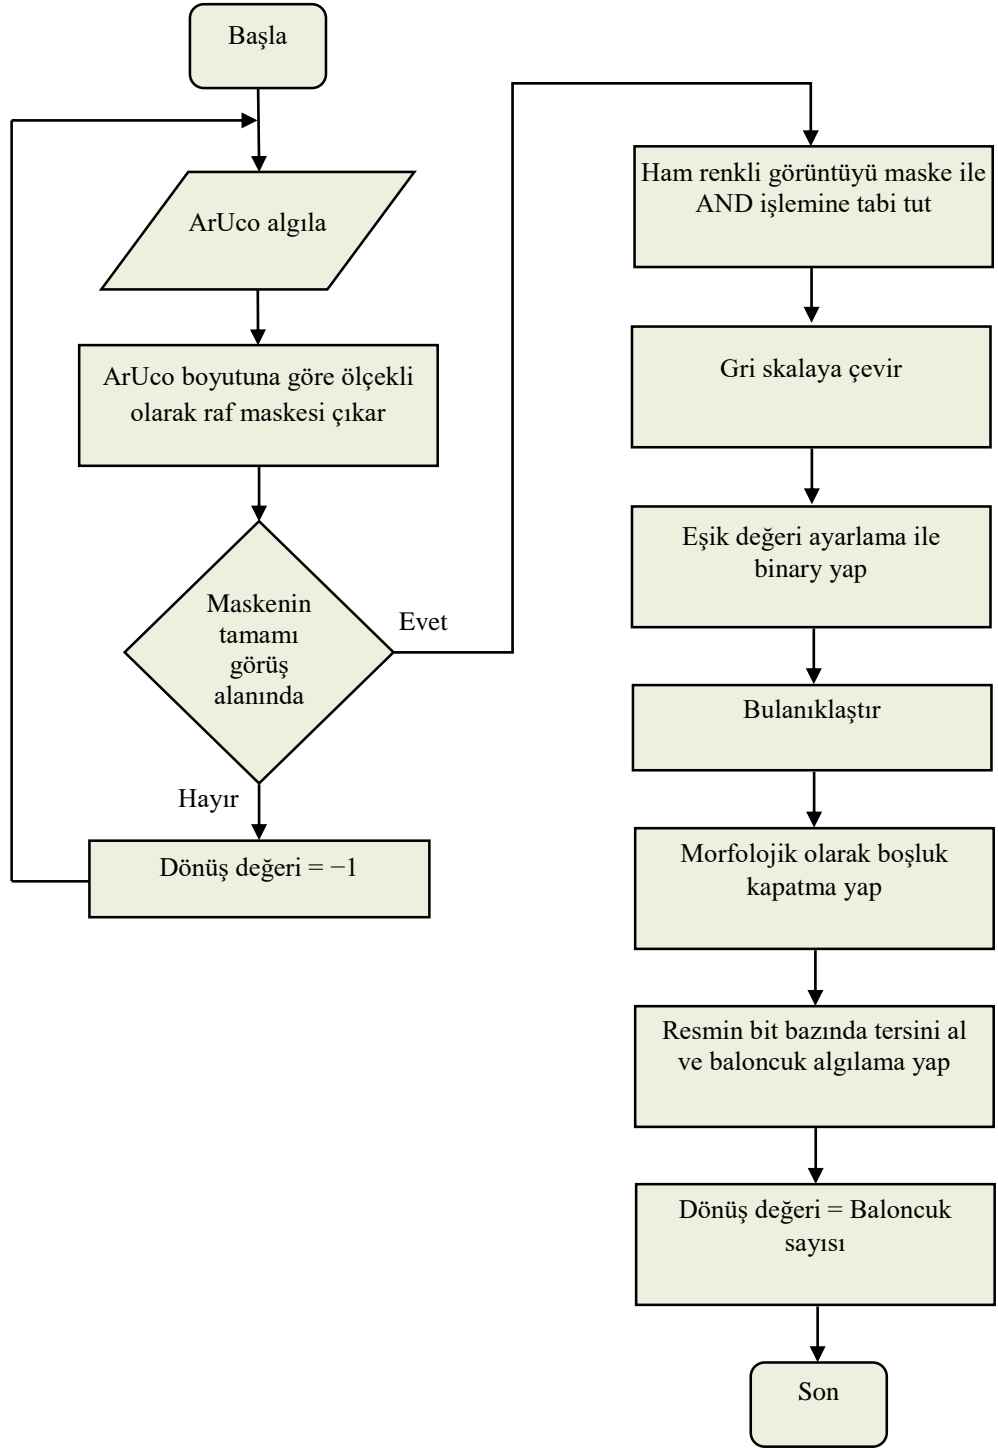
Error, MSE), Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Belirleme Katsayısı'dır (Coefficient of determination, R^2). Regresyon performans değerlendirmesinde kullanılan, MAE ve R^2 metrikleri Tablo 5.1'de verilmiştir (Alpaydın, 2009; Moriasi ve diğ., 2007; Willmott, 1982). Tablo 5.1'deki denklemler için \hat{y}_j tahmin edilen değer, y_j gözlemlenen değer ve \bar{y} ise gözlemlenen değerlerin ortalamasıdır.

Tablo 5.1: Regresyon için performans metrikleri.

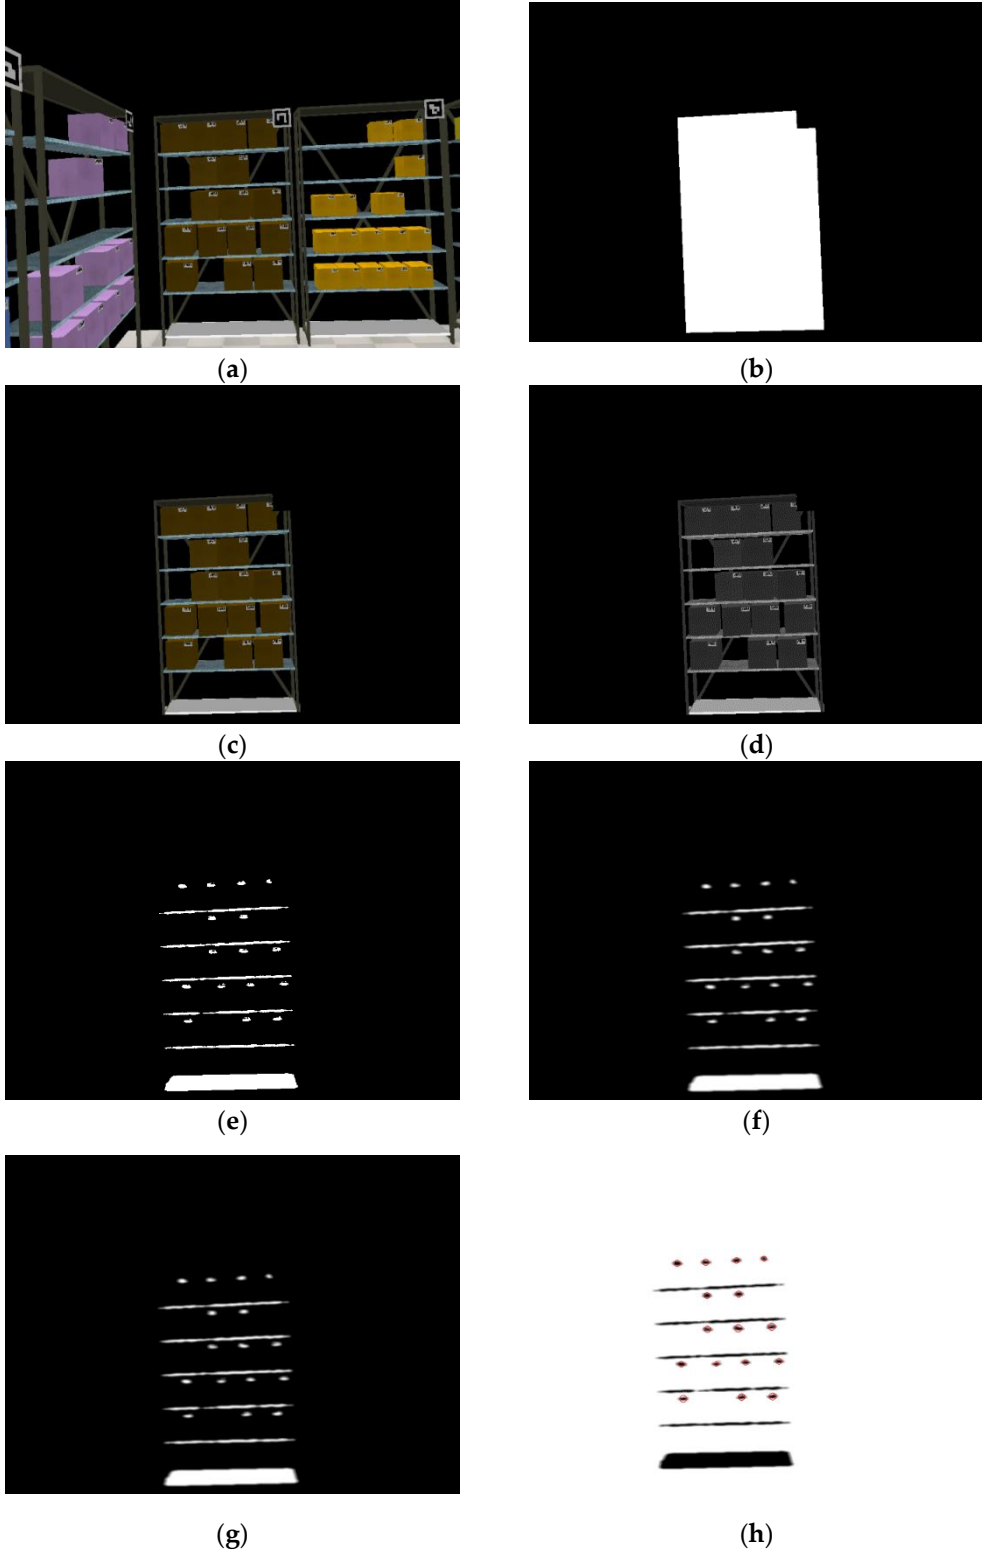
Metrik	Denklem
Ortalama Mutlak Hata (MAE)	$MAE = \frac{1}{n} \sum_{j=1}^n y_j - \hat{y}_j $
R Belirleme Katsayısı (R-Kare, R^2)	$R^2 = 1 - \frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{\sum_{j=1}^n (y_j - \bar{y})^2}$

5.7 Depo Gezme ve Raf Doluluk Algılama Algoritması

AR etiketleri yardımıyla gerçekleştirdiğimiz konumlandırma çalışmamızı yaptığımız kapalı alan depo simülasyon ortamında, depo envanter sayımının yapılmıştır. Barkod etiketleri bulunan kolilerle doldurulmuş depo ortamında hareket eden dron AR etiketleri gördüğü yerde konumlandırma yaparken, yine aynı görüntüde bulunan barkod etiketlerini okuyarak, envanter sayımı gerçekleştirilmiştir. Envanter sayımı yapılabilmesi için kullandığımız programın akış şeması Şekil 5.5'te, envanter sayımı esnasında yapılan işlemlerin ekran görüntüleri Şekil 5.6 (a. Depo alanı içerisinde ArUco algılanması, b. ArUco boyutuna göre ölçekli olarak raf maskesi çıkarma, c. Ham renkli görüntünün maske ile AND işlemine sokulması, d. Görüntünün Gri sklaya çevrilmesi, e. Eşik ayarlama ile görüntünün binary yapılması, f. Görüntünün bulanıklaştırılması, g. Morfolojik olarak boşluk kapatma, h. Resmin bit bazında tersinin alınması ve baloncuk algılama yapılması)'de verilmiştir.



Şekil 5.5: Envanter sayım programı akış şeması.



Şekil 5.6: Envanter sayımı işlem adımları ekran görüntüleri a) Depo alanı içerisinde ArUco algılanması, b) ArUco boyutuna göre ölçekli olarak raf maskesi çıkarma, c) Ham renkli görüntünün maske ile AND işlemine sokulması, d) Görüntünün Gri sklaya çevrilmesi, e) Eşik ayarlaması ile görüntünün binary yapılması, f) Görüntünün bulanıklaştırılması, g) Morfolojik olarak boşluk kapatma, h) Resmin bit bazında tersinin alınması ve baloncuk algılama yapılması.

6. BULGULAR


6.1 Veri Toplama Bulguları ve Kanıtları

6.1.1 X Ekseninde Konumlandırma

X eksenini çıkış alınarak yapılan tahminleme işlemi sonucu elde edilen bulgular Tablo 6.1’de sunulmuştur. Bu tabloya göre, en yüksek ilişkili ve düşük hata ile tahminleme yapan öğrenme algoritması AdaBoost’tur. AdaBoost algoritması ile yapılan tahminlerin ortalama mutlak hata (MAE) değeri 0,105’tir. Gerçek X eksen değerlerine karşılık AdaBoost algoritmasının tahminleri Şekil 6.1’de gösterilmiştir. Görüldüğü üzere tahminlemede çok büyük oranda çakışma olduğu için regresyon çizgisinin eğimi 1,08 olarak belirlenmiştir. Kapalı alanda gezinen ve görev alanı 25 m² olan bir dronun laboratuvar ortamında UWB konumlandırma hatası 4 cm düzeyinin altında kalmıştır (Gümüşboğa, 2022). AR işaretçiler ve stereo kamera kullanılan bir çalışmada ise uzun süreli sürüşlerde rota noktaları için yapılan hataların genel ortalaması 0,895 cm, x ekseninde yapılan ortalama hata miktarı 0,696 cm ve y ekseninde yapılan ortalama hata miktarı 0,540 cm olarak bulunmuştur (Seçkin, 2020^b).

Tablo 6.1: X eksenini AdaBoost makine öğrenme performansı.

Model	Zaman [s]		Regresyon Metriği	
	Train	Test	MAE	R ²
AdaBoost for PX	20,441	0,258	0,105	0,991
MLP for PX	31,193	0,080	0,230	0,983
kNN for PX	0,105	0,632	0,237	0,976
RF for PX	1,420	0,044	0,239	0,974
xgboost for PX	1,325	0,027	0,383	0,966



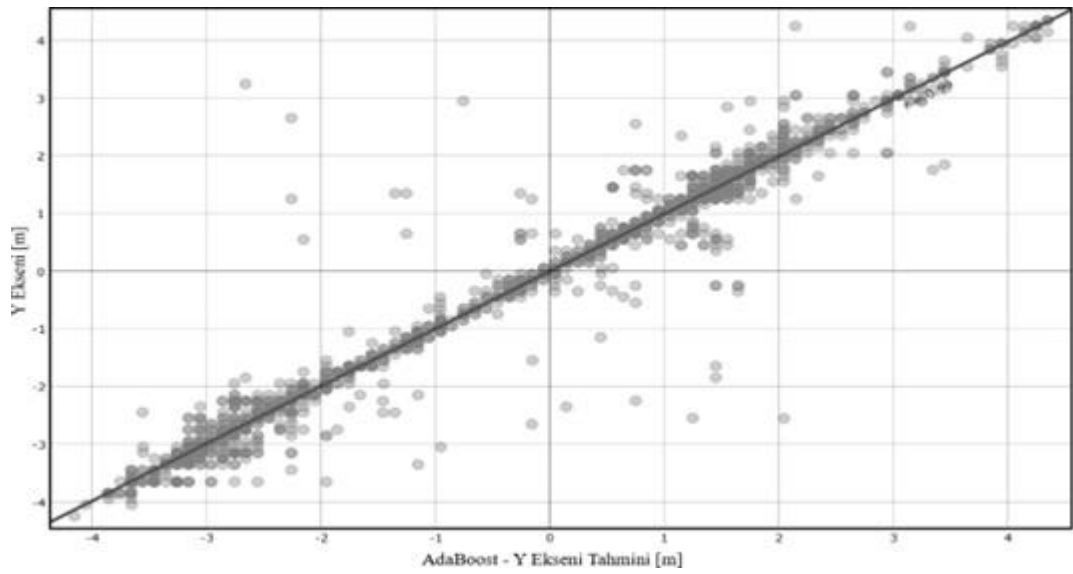
Şekil 6.1: X Eksenini AdaBoost makine öğrenme algoritması tahminlemesi.

6.1.2 Y Ekseninde Konumlandırma

Y eksenini çıkış alınarak yapılan tahminleme işlemi sonucu elde edilen bulgular Tablo 6.2’de sunulmuştur. Bu tabloya göre en yüksek ilişkili ve düşük hata ile tahminleme yapan öğrenme algoritması AdaBoost’tur. AdaBoost algoritması ile yapılan tahminlerin ortalama mutlak hata (MAE) değeri 0,109’tir. Gerçek Y eksen değerlerine karşılık AdaBoost algoritmasının tahminleri Şekil 6.2’de gösterilmiştir. Görüldüğü üzere tahminlemede çok büyük oranda çakışma olduğu için regresyon çizgisinin eğimi 0,99 olarak belirlenmiştir. Dron hareket yarıçapının 4 m olduğu ve dairesel yol takibi yapılan Time difference of arrival (TDoA-Variş zamanı farkı) tekniği kullanılan bir çalışmada, yol boyunca gerçek mesafe farkı 7,53 m olmuştur (Khalaf-Allah, 2020). Wi-Fi Trilaterasyon yöntemiyle iç mekanda yapılan navigasyon çalışmasında ise önerilen sistemin doğruluğu 0,43 ile 1,93 m arasında değişmekte olup, ortalama doğruluk 1,11 m olmuştur (Marasigan ve diğ., 2020).

Tablo 6.2: Y eksenli Adaboost makine öğrenme performansı.

Model	Zaman [s]		Regresyon Metriği	
	Train	Test	MAE	R ²
AdaBoost for PY	20,402	0,252	0,109	0,976
MLP for PY	50,223	0,073	0,200	0,973
kNN for PY	0,102	0,606	0,232	0,953
RF for PY	1,455	0,035	0,234	0,956
xgboost for PY	1,293	0,020	0,328	0,946




Şekil 6.2: Y Eksenli Adaboost makine öğrenme algoritması tahminlemesi.

6.1.3 Z Ekseninde Konumlandırma

Z eksenli çıkış alınarak yapılan tahminleme işlemi sonucu elde edilen bulgular Tablo 6.3’de sunulmuştur. Bu tabloya göre en yüksek ilişkili ve düşük hata ile tahminleme yapan öğrenme algoritması AdaBoost’tur. AdaBoost algoritması ile yapılan tahminlerin ortalama mutlak hata (MAE) değeri 0,014’tir. Gerçek Z eksen değerlerine karşılık AdaBoost algoritmasının tahminleri Şekil 6.3’te gösterilmiştir. Görüldüğü üzere tahminlemede çok büyük oranda çakışma olduğu için regresyon çizgisinin eğimi 0,99 olarak belirlenmiştir. Laser ve görsel odometrinin kullanıldığı bir çalışmada ise gerçek konumla tahmini konum arasında %11 hata yapılmıştır (Magree ve Johnson, 2014).

Tablo 6.3: Z eksenli AdaBoost makine öğrenme performansı.

Model	Zaman [s]		Regresyon Metriği	
	Train	Test	MAE	R ²
AdaBoost for PZ	23,724	0,253	0,014	0,979
MLP for PZ	33,042	0,066	0,062	0,968
xgboost for PZ	1,306	0,019	0,047	0,966
RF for PZ	3,654	0,093	0,038	0,964
kNN for PZ	0,105	0,650	0,096	0,795



Şekil 6.3: Z Eksenli AdaBoost makine öğrenme algoritması tahminlemesi.


6.1.4 Theta Poz Tahmini (YAW Açısı)

YAW açısı çıkış alınarak yapılan tahminleme işlemi sonucu elde edilen bulgular Tablo 6.4’de sunulmuştur. Bu tabloya göre en yüksek ilişkili ve düşük hata ile tahminleme yapan öğrenme algoritması AdaBoost’tur. AdaBoost algoritması ile yapılan tahminlerin ortalama mutlak hata (MAE) değeri 14,956’dır. Gerçek YAW açısı değerlerine karşılık AdaBoost algoritmasının tahminleri Şekil 6.4’de gösterilmiştir. Görüldüğü üzere tahminlemede büyük oranda çakışma olduğu için

regresyon çizgisinin eğimi 0,91 olarak belirlenmiştir. Yapılan literatür incelemesinde, dronun theta sapma açısıyla ilgili bir çalışmaya rastlanmamıştır.

Tablo 6.4: Theta poz tahmini AdaBoost makine öğrenme performansı.

Model	Zaman [s]		Regresyon Metriği	
	Train	Test	MAE	R ²
AdaBoost for yaw	15,605	0,214	14,956	0,816
RF for yaw	01,281	0,035	19,616	0,814
xgboost for yaw	01,427	0,020	22,731	0,810
MLP for yaw	39,649	0,067	22,642	0,783
kNN for yaw	00,112	0,593	22,213	0,762



Şekil 6.4: Theta poz AdaBoost makine öğrenme algoritması tahminlemesi.

6.2 Mevcut Sistemler ile Karşılaştırma

Çalışmamızda bir dronun kapalı alan olarak tasarlanan depo alanında rastgele rotalarda dolaşması sağlanmıştır. Depo alanına yerleştirilen ArUco markerların dron üzerinde bulunan kamera tarafından tespit edilmesi sağlanmış, kameranın ArUco etiketleri gördüğü her yerde konum ve poz tahmini yapılmış hata miktarı hesaplanmıştır. Dronun gerçek konum bilgisi ise makine öğrenme algoritmaları çıkış


değeri olarak kullanılmıştır. Çalışmamızla tasarladığımız sistemin; dronun hareket alanına bağlı olarak konum tahminlemede yaptığı hata miktarı açısından diğer sistemlerle karşılaştırıldığında daha iyi performans sergilediği görülmüştür. Sistemimizin hareket alanına bağlı olarak yaptığı hata miktarının diğer sistemlerle olan karşılaştırması Tablo 6.5’te verilmiştir.

Tablo 6.5: Sistemlerin dron hareket alanına bağlı olarak yaptıkları hata miktarı.

Referans	Görev Boyutları (m)	Hata (cm)	Hata/Görev Boyutu
(Seçkin, 2020 ^b)	0,8x1	0,89	1,113
(Gümüşboğa, 2022)	4,75x4,36x2,66	0,26-1,13	0,020
(Khalaf-Allah, 2020)	10 x10x10	11-26	0,026
(Marasigan ve diğ., 2020)	15,24x 15,24	43-193	0,831
(Tiemann ve Wietfeld, 2017)	2,4x 4,8	16-36	3,125
(Magree ve Johnson, 2014)	3,65x3,65	30	2,252
Önerilen Metot	10x15x5	15,2	0,020

6.3 Depo Gezinti ve Raf Doluluk Algılama

Bu çalışmamızda görüntü işleme ve bu tekniği kullanarak otonom sistemlerde navigasyon yapma işlemi gerçekleştirildi. Çalışmamızda, simülasyon ortamında kullandığımız tekniğin ne derece başarılı olduğunu test ederek, yüksek oranda başarımlık sağladık. X, Y, Z, Theta açısı başarımlık oranlar yukarıda verilmiştir. Genel olarak konumlandırma sistemlerinde görsel referans işaretlerinin kullanılmasıyla, simülasyon ortamında yaptığımız navigasyon sistemimizi doğrulama/başarımlık ortamı oluşturup gerekli parametreleri toplamayı başardık. Bunun için kullandığımız kapalı ortam ArUco marker tespit ve data toplama aşamasındaki bilgisayar görüntüleri ise Şekil 6.5 (a, b, c, d)’te verilmiştir.



Şekil 6.5: ArUco Marker'in kamera tarafından tespit edilmesi ve dronun konumlandırılması için gerekli dataların alınması a) X ekseninde ilerlerken dron kamerasından ArUco tespiti, b) Y ekseninde ilerlerken dron kamerasından ArUco tespiti, c) Z ekseninde ilerlerken dron kamerasından ArUco tespiti, d) Theta sapma açısına sahip dronun kamerasından ArUco tespiti.

Görsel tabanlı navigasyonun yapılabilmesi için CoppeliaSim adlı simülasyon programı üzerinde bir simülasyon ortamı hazırlanmıştır. Simülasyon ortamında hareket esnasında hava aracının konum, IMU ve kamera bilgileri alınmaktadır. Kameradan alınan görüntüden artırılmış gerçeklik (Augmented Reality-AR) etiketler okunmakta ve etiket ID'sine göre etiketin var olup olmadığı, etiketin kameradaki piksel cinsinden koordinatları ve etiketin alanı alınmaktadır. Bu veriye ek olarak hava aracının pusula bilgisi alınmaktadır. Hava aracının gerçek konum bilgisi ise makine öğrenmesi tahminlemesinde çıkış değeri olarak kullanılmak üzere alınmaktadır. Her konum verisi için bir regresyon modeli oluşturulmaktadır. Regresyon modelleri ile hava aracının AR etiketleri gördüğü her bölgede anlık konum ve poz tahmini gerçekleştirilmekte ve hata değeri hesaplanmaktadır.

Hava aracının konum bilgileri olan x, y, z ve poz bilgisi olan γ açısı regresyon tahminleri ile gerçek değerlerin ilişkisi hakkında bilgi veren R^2 performans değerleri Tablo 6.1, Tablo 6.2, Tablo 6.3 ve Tablo 6.4'de sunulmuştur. Kullanılan öğrenme algoritmaları için scikit-learn kütüphanesinden faydalanılmış olup varsayılan alt parametreler kullanılmıştır. Uygulanan algoritmalar arasında konumlandırma için en yüksek x değeri tahmininde 0,991 ile AdaBoost, en yüksek y değeri tahmininde 0,976

ile Adaboost, en yüksek z deęeri tahmininde 0,979 ile AdaBoost ve en yüksek Theta deęeri tahmininde ise 0,816 deęeri ile AdaBoost algoritması vermiřtir. Mevcut konumlandırma ve poz tahmininde elde edilen R^2 metrięine gore AdaBoost algoritması ile tahmin sonuclarının daha yuksek olduęu gorlmektedir. Ancak bu deęerin daha doęru ve hassas olması iin yukseltilmesi gerektięini deęerlendirmekteyiz. Sonucların gerek deęerlere daha uyumlu olması iin poz bilgisinin tahmin sonuclarının IMU destekli tahminle gerekleřtirilmesinin daha yuksek bir oranda tahminleme saęlayacaęı düşnldęnden, bir sonraki alıřmamızda IMU destekli bir sistem iin alıřılacaktır. Aynı zamanda yeni algoritmaların eklenmesi ve optimizasyonu iin alıřmalar devam ettirilecektir.

7. SONUÇ VE ÖNERİLER

Otonom robotik sistemler sadece açık alanlarda değil kapalı alanlarda da her geçen gün daha fazla kullanım alanı bulmaktadır. Bu nedenle açık alanlarda olduğu gibi kapalı mekanlarda da kati konum belirleme ihtiyacı, teknolojik gelişmelerle birlikte bir zorunluluk halini almaya başlamıştır. Kapalı alanlarda kati konum belirleme ya da otonom robotik cihazlara navigasyon yaptırmak için günümüzde çeşitli teknikler kullanılmaktadır. Bizim bu çalışmamızda kapalı alan olarak tasarlanan bir depo ortamında, bir dronun görsel odometri kullanarak konumlandırılması ve doğru navigasyon yapabilmesi için görsel referans işaretçilerinin kullanılabilirliği için bir tasarım sunulmuştur. Amacımız her geçen gün gelişen iç mekanlarda kullanılan konum belirleme sistemlerinden birisi olan görsel odometri yönteminde daha doğru ve daha düşük maliyetli konumlandırma ve navigasyonu, daha hızlı yapabilmek amacıyla makine öğrenmesi algoritmalarının verimliliği değerlendirmiştir. Hazırlanan simülasyon ortamında çeşitli rotalar izlenerek veri toplanmış ve toplanan veri makine öğrenmesi algoritmalarına tabi tutularak K-En Yakın Komşular, Adaptive Boosting, Rastgele Orman, Destek Vektör Makinesi, Yapay Sinir Ağları-Multilayer Perceptron algoritmalarının başarımları kıyaslanmıştır. Algoritmalarından en başarılı olanını seçmek için, izlenen rotaya ne kadar uyumlu tahmin gerçekleştirdiği hakkında bilgi verebilecek olan R^2 metriğinden faydalanılmıştır. Kullanılan makine öğrenmesi algoritmalarından AdaBoost x ekseninde en yüksek R^2 değerini 0,991, y ekseninde en yüksek R^2 değerini 0,976, z ekseninde en yüksek R^2 değerini 0,979, theta açısında en yüksek R^2 değerini 0,816 olarak vermiştir. Bu değerlerden de anlaşılacağı üzere yüksek seviyede ilişkili tahminler gerçekleştirilmekte olup aracın işaretçilerden bir veya birkaçını görmesi sayesinde kapalı alanda konum tahmini yapılabilmektedir. İlişki katsayısı yüksek olan AdaBoost algoritmasının x eksenindeki MAE değeri 0,105, y eksenindeki MAE değeri 0,109, z eksenindeki MAE değeri 0,014, teta açısındaki MAE değeri 14,956 dır. Bu değerler cm cinsindedir. Önerilen sistem ile yüksek ilişkili ve düşük hata değerli bir konumlandırma ve navigasyon işleminin yapılabildiği görülmüştür. Ayrıca önerilen sistem, benzer ve rakip alternatiflerine göre düşük maliyetli ve daha az altyapı kurulum ihtiyacı olması sebebiyle önemli bir alternatif sunmaktadır. Elbette ki kapalı alanlarda kullanılan diğer konumlandırma sistemleri de her geçen gün daha doğru ve daha hızlı konumlandırma yapabilmek için gelişmeye devam edecektir. Bununla birlikte makine öğrenmesi algoritmalarının

kullanılmasının, iç mekanlarda yapılan navigasyonun doğruluğunu güvenilir seviyelere çıkardığı görülmektedir. Ticari kullanım amacına göre hangi makine öğrenmesi algoritmasının ve hangi iç mekân konumlandırma sisteminin seçilmesi gerekliliği tartışmaya açık kalacaktır. Gelecek çalışmalarda gerçek ortam modeli çıkarılması ve görsel işaretçilerin bu modele uygulanarak gerçek bir dron ile uçuş yapılarak konumlandırma yapılması hedeflenmektedir. Sonuçların gerçek değerlere daha uyumlu olması için poz bilgisinin tahmin sonuçlarının IMU destekli tahminle gerçekleştirilmesinin daha yüksek bir oranda tahminleme sağlayacağı düşünüldüğünden, bir sonraki çalışmamızda IMU destekli bir sistem için çalışılacaktır. Aynı zamanda yeni makine öğrenmesi algoritmaların eklenmesi ve optimizasyonu için çalışmalar devam ettirilecektir. Yaptığımız çalışmanın Theta poz açısıyla ilgili daha fazla çalışma yapılmasına da katkı sağlayacağı değerlendirilmektedir.

8. KAYNAKLAR

Durmus, S., Uçuş Teorisi ve Temel Uçak Bilgisi- Flight Theory and Basic Aeronautical Knowledge, Nobel Akademik Yayıncılık, (2020).

Bekir, E., Introduction To Modern Navigation Systems, World Scientific, (2007).

Noureldin, A., Karamat, T. B. and Georgy, J., Fundamentals of Inertial Navigation, Satellite-based Positioning and their Integration. Springer Science & Business Media, (2012).

Güner, D. R. L., "Inertial navigation system improvement using ground station data, Yer istasyonu verisi kullanılarak ataletsel navigasyon sistemlerinin başarımının artırılması[online]", (27 Eylül 2022), <https://open.metu.edu.tr/handle/11511/22043>, (2012).

Winick A. B. and Brandewie, D. M., "VOR/DME system improvements", Proceedings of the IEEE, 58(3), 430-437, doi: 10.1109/PROC.1970.7650, (1970).

Noureldin, A., Karamat, T. B. and Georgy, J., "INS/GPS Integration", içinde Fundamentals of Inertial Navigation, Satellite-based Positioning and their Integration, Noureldin, A. Karamat, T. B. and Georgy, J. Ed. Berlin, Heidelberg: Springer, 247-271. doi: 10.1007/978-3-642-30466-8_8, (2013).

Noureldin, A., Karamat, T. B. and Georgy, J. Fundamentals of Inertial Navigation, Satellite-based Positioning and their Integration. Berlin, Heidelberg: Springer Berlin Heidelberg, doi: 10.1007/978-3-642-30466-8, (2013).

Urban, Indoor and Subterranean Navigation Sensors and Systems (Capteurs et systemes de navigation urbains, interieurs et souterrains), NATO Research And Technology Organization Neuilly-Sur-Seine (France) [online], (27 Eylül 2022), <https://apps.dtic.mil/sti/citations/ADA542231>, (2010).

Yumpu.com, "Basic Guide to Advanced Navigation- NATO Research ...", yumpu.com. (27 Mayıs 2022),

<https://www.yumpu.com/en/document/read/50114033/basic-guide-to-advanced-navigation-nato-research->, (2003).

Güner, L., Özgören, M. K. ve Platın, B. “Küresel Konumlama Sistemlerinin Kullanılmadığı Durumlarda Ataletsel Navigasyon Sistemlerinin Başarımının Korunması- Preserving Accuracy of Inertial Navigation Systems in GNSS-Denied Environments”, EMO Bilimsel Dergi, 3 (5), (2013).

Ekütekin, V., “Navigation and control studies on cruise missiles, Seyir füzeleri üzerine seyrüsefer ve denetim çalışmaları [online]”, (27 Eylül 2022), <https://open.metu.edu.tr/handle/11511/17090>, (2007).

Siouris, G. M. Missile Guidance and Control Systems. Springer Science & Business Media, (2004).

Bahl, P. and Padmanabhan, V. N. “RADAR: an in-building RF-based user location and tracking system”, içinde Proceedings IEEE INFOCOM 2000. Conference on Computer Communications. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies (Cat. No.00CH37064), 2, 775-784, doi: 10.1109/INFCOM.2000.832252, (2000).

Yamada, I., Ohtsuki, T., Hisanaga, T. and Zheng, L. “An indoor position estimation method by maximum likelihood algorithm using RSS”, içinde SICE Annual Conference, 2927-2930, doi: 10.1109/SICE.2007.4421491, (2007).

Mogi T. and Ohtsuki, T. “TOA localization using RSS weight with path loss exponents estimation in NLOS environments”, içinde 2008 14th Asia-Pacific Conference on Communications, 1-5, (2008).

Yamashita, J., Hiyama, A., Amemiya, T., Kobayashi, I., Hirota, K. and Hirose, M., “Establishing the out-of-door experiment environment for the wearable and mobile computers”, Human Interface Society, 20, (2002).

Borenstein, J., Everett, H. R., Feng, L. and Wehe, D. “Mobile robot positioning-sensors and techniques [online]”, DTIC Document, (01 Eylül 2022),

<http://oai.dtic.mil/oai/oai?verb=getRecord&metadataPrefix=html&identifier=ADA422844>, (2007).

Liu, H., Darabi, H., Banerjee, P., and Liu, J. "Survey of wireless indoor positioning techniques and systems", *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, 37(6), 1067-1080, (2007).

Siciliano, B. and Khatib, O. Ed., *Springer handbook of robotics*. Berlin: Springer, (2008).

Beard, R. W., McLain, T. W., Goodrich, M. A. and Anderson, E. P. "Coordinated target assignment and intercept for unmanned air vehicles", *Robotics and Automation, IEEE Transactions on*, 18(6), 911-922, (2002).

Chen Y.C. and Wang, Y.T. "Obstacle avoidance and role assignment algorithms for robot formation control", içinde "Intelligent Robots and Systems, IROS 2007. IEEE/RSJ International Conference on, 4201-4206, [online]", (23 Ağustos 2022), http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4399188, (2007).

Toner J. and Tu, Y. "Flocks, herds, and schools: A quantitative theory of flocking", *Physical review E*, 58(4), 4828, (1998).

Parker, L. E. "Path planning and motion coordination in multiple mobile robot teams", *Encyclopedia of complexity and system science*, 5783-5800, (2009).

Güner, L., Özgören, M.K. and Platin, B. "Küresel Konumlama Sistemlerinin Kullanılmadığı Durumlarda Ataletsel Navigasyon Sistemlerinin Başarımının Korunması- Preserving Accuracy of Inertial Navigation Systems in GNSS-Denied Environments", *EMO Bilimsel Dergi*, 3(5), (2013).

Vásárhelyi G., et al., "Outdoor flocking and formation flight with autonomous aerial robots", içinde *Intelligent Robots and Systems (IROS 2014)*, 2014 IEEE/RSJ International Conference on, 3866-3873 [online], (28 Kasım 2022), http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6943105, (2014).

Quintero, S., Collins, G. E., Hespanha, J. P. and Others, "Flocking with fixed-wing UAVs for distributed sensing: A stochastic optimal control approach", içinde

American Control Conference (ACC), [online]", 2025-2031 (01 Aralık 2022)
http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6580133, (2013)

Mautz, R. "Overview of current indoor positioning systems", *Geodezija ir kartografija*, 35(1), 18-22, (2009).

Mautz, R. "Indoor positioning technologies", (2012).

Stirling, T. Roberts, J. Zufferey, J.C. and Floreano, D. "Indoor navigation with a swarm of flying robots", içinde *Robotics and Automation (ICRA)*, 2012 IEEE International Conference on [online], 4641-4647, (28 Ağustos 2022), http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6224987, (2012).

Scaramuzza D. et al., "Vision-controlled micro flying robots: from system design to autonomous navigation and mapping in GPS-denied environments", *IEEE Robotics & Automation Magazine*, 21 (3), 26-40, (2014).

Balamurugan, G. Valarmathi, J. and Naidu, V. P. S. "Survey on UAV navigation in GPS denied environments", içinde 2016 International conference on signal processing, communication, power and embedded system (SCOPEs), 198-204, (2016).

Yazici, A. Yayan, U. and Yücel, H. "An ultrasonic based indoor positioning system", içinde 2011 International Symposium on Innovations in Intelligent Systems and Applications, 585-589, (2011).

Ijaz, F., Yang, H. K., Ahmad, A. W. and Lee, C. "Indoor positioning: A review of indoor ultrasonic positioning systems", içinde 2013 15th International Conference on Advanced Communications Technology (ICACT), 1146-1150, (2016).

Seçkin, A. Ç. ve Coşkun, A. "Hierarchical Fusion of Machine Learning Algorithms in Indoor Positioning and Localization", *Applied Sciences*, 9(18), 3665, (2019).

Alitaleshi, A., Jazayeriy, H., Kazemitabar, S. J. "WiFi Fingerprinting based Floor Detection with Hierarchical Extreme Learning Machine", içinde 2020 10th

International Conference on Computer and Knowledge Engineering (ICCKE), 113-117 (2020).

Chan, Y.T., Tsui, W.Y., So, H.C. and Ching, P. “Time-of-arrival based localization under NLOS conditions”, IEEE Transactions on Vehicular Technology, 55(1), 17-24, doi: 10.1109/TVT.2005.861207, (2006).

Michael, N., Mellinger, D., Lindsey, Q. and Kumar, V. “The grasp multiple micro-uav testbed”, Robotics & Automation Magazine, IEEE, 17(3), 56-65, (2010).

Kushleyev, A., Mellinger, D., Powers, C. and Kumar, V. “Towards a swarm of agile micro quadrotors”, Autonomous Robots, 35(4), 287-300, doi: 10.1007/s10514-013-9349-9, (2013).

Dorigo, M. et al., “Swarmanoid”, IEEE Robotics & Automation Magazine, 1070(9932/13) [online], (29 Ağustos 2022), <http://iridia.ulb.ac.be/~mathews/papers/DorFloGam-etal2013:ram.pdf>, (2013).

Seçkin, A. Ç., “Adaptive Positioning System Design Using AR Markers and Machine Learning for Mobile Robot”, içinde 2020 5th International Conference on Computer Science and Engineering (UBMK), 160-164, (2020).

Zakiev, A., Tsoy, T., Shabalina, K., Magid, E. and Saha, S. K. “Virtual Experiments on ArUco and AprilTag Systems Comparison for Fiducial Marker Rotation Resistance under Noisy Sensory Data”, içinde 2020 International Joint Conference on Neural Networks (IJCNN), 1-6. doi: 10.1109/IJCNN48605.2020.9207701, (2020).

Kato, H., Billingham, M. and Poupyrev, I. “ARToolKit Version 2.33”, Human Interface Lab, Universidade de Washington, (2000).

Wang, Y. Zheng, Z. Su, Z., Yang, G., Wang, Z. and Luo, Y. “An Improved ArUco Marker for Monocular Vision Ranging”, içinde 2020 Chinese Control And Decision Conference (CCDC), 2915-2919. doi: 10.1109/CCDC49329.2020.9164176, (2020).

Garrido-Jurado, S., Muñoz-Salinas, R., Madrid-Cuevas, F. J. and Marín-Jiménez, M. J. “Automatic generation and detection of highly reliable fiducial markers under occlusion”, *Pattern Recognition*, 47(6), 2280-2292, doi: 10.1016/j.patcog.2014.01.005 (2014).

Kalman, R. E. “A New Approach to Linear Filtering and Prediction Problems”, *Journal of Basic Engineering*, 82(1), 35-45, doi: 10.1115/1.3662552, (1960).

Ankişhan H. ve Efe, M., “Eşzamanlı konum belirleme ve harita oluşturmaya Kalman filtre yaklaşımları”, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 1(1), (2010).

Jimenez, A. R., Seco, F. Prieto, C. and Guevara J., “A comparison of pedestrian dead-reckoning algorithms using a low-cost MEMS IMU”, içinde 2009 IEEE International Symposium on Intelligent Signal Processing, 37-42, (2009).

Do, T.N., Liu, R., Yuen, C., Zhang, M. and Tan, U.X., “Personal dead reckoning using IMU mounted on upper torso and inverted pendulum model”, *IEEE Sensors Journal*, 16(21), 7600-7608, (2016).

Brossard, M., Barrau, A. and S. Bonnabel, “AI-IMU dead-reckoning”, *IEEE Transactions on Intelligent Vehicles*, 5(4), 585-595, (2020).

Hess, W. Kohler, D. Rapp H. ve Andor, D. “Real-time loop closure in 2D LIDAR SLAM”, içinde 2016 IEEE International Conference on Robotics and Automation (ICRA), 1271-1278, (2016).

Quan S. and Chen, J. “AGV localization based on odometry and LiDAR”, içinde 2019 2nd World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM), 483-486, (2019).

Veerannapeta, V. “Low Power Indoor Robotic Vacuum Cleaner Using Sensors and SLAM”, *International Research Journal of Innovations in Engineering and Technology*, 3(4), 51, (2019).

Seçkin, A. Ç. “Pedestrian and Mobile Robot Detection with 2D LIDAR”, *EJOSAT*, 23, 583-588, (2021).

Se, S., Lowe, D. ve Little, J. “Mobile robot localization and mapping with uncertainty using scale-invariant visual landmarks”, *The international Journal of robotics Research*, 21(8), 735-758, (2002).

Davison, A. J. "Real-time simultaneous localisation and mapping with a single camera", içinde *Computer Vision*, 2003. *Proceedings. Ninth IEEE International Conference on*, 1403-1410 [onile], (06 Şubat 2022), http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1238654, (2003).

Karlsson, N. Di Bernardo, E., Ostrowski, J., Goncalves, L., Pirjanian, P. and Munich, M. E. “The vSLAM, algorithm for robust localization and mapping”, içinde *Robotics and Automation*, 2005. *ICRA 2005. Proceedings of the 2005 IEEE International Conference on*, 24-29 [onile], (06 Şubat 2022), http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1570091, (2005).

Steder, B. Grisetti, Stachniss, G. C. and Burgard, W. “Visual SLAM for flying vehicles”, *Robotics, IEEE Transactions on*, 24(5), 1088-1093, (2008).

Rosten, E. and Drummond, T. “Machine learning for high-speed corner detection”, içinde *Computer Vision–ECCV 2006*, Springer, 430-443 [onile], (30 Kasım 2022). http://link.springer.com/chapter/10.1007/11744023_34, (2006).

Rosten, E., Porter, R. and Drummond, T. “Faster and better: A machine learning approach to corner detection”, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 32(1), 105-119, (2010).

Donoser, M. and Bischof, H. “Efficient maximally stable extremal region (MSER) tracking”, içinde *Computer Vision and Pattern Recognition*, 2006 *IEEE Computer Society Conference on* [Onile], 1, 553-560 (28 Kasım 2021), http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1640804, (2006).

Agrawal, M., Konolige, K. and Blas, M. R. “CenSurE: Center Surround Extremas for Realtime Feature Detection and Matching”, içinde *Computer Vision – ECCV 2008*, 5305, Forsyth, D., Torr, P. and Zisserman, A. Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 102-115 [Onile], (28 Kasım 2021), http://link.springer.com/10.1007/978-3-540-88693-8_8, (2008).

Calonder, M., Lepetit, V., Strecha, C. and Fua, P. “Brief: Binary robust independent elementary features”, *Computer Vision–ECCV 2010*, 778-792, (2010).

Leutenegger, S., Chli, M. and Siegwart, R. Y., “BRISK: Binary robust invariant scalable keypoints”, içinde *Computer Vision (ICCV), 2011 IEEE International Conference on*, 2548-2555 [online], (28 Kasım 2021), http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6126542, (2011).

Alahi, A., Ortiz, R. and Vandergheynst, P., “Freak: Fast retina keypoint”, içinde *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, 510-517, [online], (28 Kasım 2021), http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6247715, (2012).

Lowe, D. G. “Distinctive image features from scale-invariant keypoints”, *International journal of computer vision*, 60(2), 91-110, (2004).

Rublee, E., Rabaud, V., Konolige, K. and Bradski, G. “ORB: An efficient alternative to SIFT or SURF”, içinde *Computer Vision (ICCV), 2011 IEEE International Conference on*, 2564-2571, [online], (28 Kasım 2021). http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6126544, (2011).

Bay, H., Tuytelaars, T. and Van Gool, L. “Surf: Speeded up robust features”, içinde *Computer vision–ECCV 2006*, Springer, 404-417, [online], (28 Kasım 2021). http://link.springer.com/chapter/10.1007/11744023_32, (2006).

Noureldin, A., Karamat, T. B. and Georgy, J. “Inertial Navigation System”, içinde *Fundamentals of Inertial Navigation, Satellite-based Positioning and their Integration*, Noureldin, A., Karamat, T. B. and Georgy, J. Ed. Berlin, Heidelberg: Springer, 125-166, doi: 10.1007/978-3-642-30466-8_4, (2013).

Hori, T. et al., “Low-latency real-time meeting recognition and understanding using distant microphones and omni-directional camera”, *IEEE transactions on audio, speech, and language processing*, 20(2), 499-513, (2011).

Le, M.H., Hoang, V.D., Vavilin, A. and Jo, K.H. “Vehicle localization using omnidirectional camera with gps supporting in wide urban area”, içinde Asian Conference on Computer Vision, 230-241, (2012).

Campos, M. B. et al., “A backpack-mounted omnidirectional camera with off-the-shelf navigation sensors for mobile terrestrial mapping: Development and forest application”, *Sensors*, 18(3), 827, (2018).

Gallego, G. et al., “Event-based Vision: A Survey”, *IEEE Trans. Pattern Anal. Mach. Intell.*, 1-1, doi: 10.1109/TPAMI.2020.3008413, (2020).

Sarmadi, H., Muñoz-Salinas, R., Olivares-Mendez, M. A. and Medina-Carnicer, R. “Detection of Binary Square Fiducial Markers Using an Event Camera”, *IEEE Access*, 9, 27813-27826, doi: 10.1109/ACCESS.2021.3058423, (2021).

Lawrence, A. *Modern Inertial Technology: Navigation, Guidance, and Control*. Springer Science & Business Media, (2012).

Skog I. and Handel, P. “In-Car Positioning and Navigation Technologies—A Survey”, *IEEE Transactions on Intelligent Transportation Systems*, 10(1), 4-21, doi: 10.1109/TITS.2008.2011712, (2009).

Se, S., Lowe, D. and Little, J. “Mobile Robot Localization and Mapping with Uncertainty using Scale-Invariant Visual Landmarks”, *The International Journal of Robotics Research*, 21(8), 735-758, doi: 10.1177/027836402761412467 (2002).

Steder, B., Grisetti, G., Stachniss, C. and Burgard, W. “Visual SLAM for Flying Vehicles”, *IEEE Transactions on Robotics*, 24(5), 1088-1093, doi: 10.1109/TRO.2008.2004521, (2008).

Fonseca, L. M. G. and Manjunath, B. S. “Registration Techniques for Multisensor Remotely Sensed Images,” *Photogrammetric Engineering*, and *Remote Sensing*, 1049-1056, (1996).

Zitová, B. and Flusser, J. “Image registration methods: a survey”, *Image and Vision Computing*, 21(11), 977-1000, doi: 10.1016/S0262-8856(03)00137-9, (2003).

Gonçalves, H., Gonçalves, J. A. and Corte-Real, L. “HAIRIS: A Method for Automatic Image Registration Through Histogram-Based Image Segmentation”, *IEEE Transactions on Image Processing*, 20(3), 776-789, doi: 10.1109/TIP.2010.2076298, (2011).

Yang, K., Pan, A., Yang, Y., Zhang, S., Ong, S. H. and Tang, H. “Remote Sensing Image Registration Using Multiple Image Features”, *Remote Sensing*, 9(6), doi: 10.3390/rs9060581 (2017).

Brown, L. G. “A survey of image registration techniques”, *ACM Comput. Surv.*, 24(4), 325-376, doi: 10.1145/146370.146374, (1992).

Li, Q., Wang, G., Liu, J. and Chen, S. “Robust Scale-Invariant Feature Matching for Remote Sensing Image Registration”, *IEEE Geoscience and Remote Sensing Letters*, 6(2), 287-291, doi: 10.1109/LGRS.2008.2011751, (2009).

Acar, H., Karsli, F. and Dihkan, M. “Automatic 3D Coordinate Extraction from High Resolution Digital Aerial Images”, *J Indian Soc Remote Sens*, 45(2), 209-216, doi: 10.1007/s12524-016-0600-7, (2017).

Calonder, M., Lepetit, V., Strecha, C. and Fua, P. “BRIEF: Binary Robust Independent Elementary Features”, içinde *Computer Vision – ECCV 2010*, Berlin, Heidelberg, 778-792. doi: 10.1007/978-3-642-15561-1_56, (2010).

Alahi, A., Ortiz, R. and Vandergheynst, P. “FREAK: Fast Retina Keypoint”, içinde *2012 IEEE Conference on Computer Vision and Pattern Recognition*, 510-517. doi: 10.1109/CVPR.2012.6247715, (2012).

Harris C. and Stephens, M. “A combined corner and edge detector”, içinde *In Proc. Fourth Alvey Vision Conference*, 147-152, (1988).

Smith S. M. and Brady, J. M. “SUSAN—A New Approach to Low Level Image Processing”, *International Journal of Computer Vision*, 23(1), 45-78, doi: 10.1023/A:1007963824710, (1997).

Rosten E. and Drummond, T. “Machine Learning for High-Speed Corner Detection”, içinde Computer Vision – ECCV 2006, Berlin, Heidelberg, 430-443. doi: 10.1007/11744023_34, (2006).

Lowe, D. G. “Distinctive Image Features from Scale-Invariant Keypoints”, International Journal of Computer Vision, 60(2), 91-110, doi: 10.1023/B:VISI.0000029664.99615.94, (2004).

Bay, H., Ess, A., Tuytelaars, T. and Van Gool, L. “Speeded-Up Robust Features (SURF)”, Computer Vision and Image Understanding, 110(3), 346-359, doi: 10.1016/j.cviu.2007.09.014, (2008).

Ma W. et al., “Remote Sensing Image Registration With Modified SIFT and Enhanced Feature Matching”, IEEE Geoscience and Remote Sensing Letters, 14(1), 3-7, doi: 10.1109/LGRS.2016.2600858, (2017).

Seçkin, A. Ç. “Özdeş olmayan bileşenlerden oluşan multikopter yapıları ve çoklu yapı uygulamaları: sürü modelleri tasarımı”, Multicopter structures with non-identical components and multiple architecture applications: swarm models [online], (29 Eylül 2022), <http://acikerisim.pau.edu.tr:8080/xmlui/handle/11499/1994>, (2017).

Fischler M. A. and Bolles, R. C. “Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography”, Commun. ACM, 24(6), 381-395, doi: 10.1145/358669.358692, (1981).

Page, G. F. “Multiple View Geometry In Computer Vision, by Richard Hartley and Andrew Zisserman, CUP, Cambridge, UK, 2003, vi+560 pp., ISBN 0-521-54051-8. (Paperback £44.95)”, Robotica, 23(2), 271-271, doi: 10.1017/S0263574705211621, (2005).

Hartley R. and Zisserman, A. Multiple View Geometry in Computer Vision. Cambridge University Press, (2003).

Lucas B. D. and Kanade, T. “An iterative image registration technique with an application to stereo vision”, (1981).

Bouguet, J.Y. “Pyramidal implementation of the affine lucas kanade feature tracker description of the algorithm”, Intel corporation, 5(1-10), 4, (2001).

Shi J. and Tomasi, C. “Good features to track”, içinde 1994 Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 593-600. doi: 10.1109/CVPR.1994.323794, (1994).

Lowe, D. G. “Object recognition from local scale-invariant features”, içinde Proceedings of the Seventh IEEE International Conference on Computer Vision, Eyl 2, 1150-1157, doi: 10.1109/ICCV.1999.790410, (1999).

Nogar, S. M. “Autonomous Landing of a UAV on a Moving Ground Vehicle in a GPS Denied Environment”, içinde 2020 IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR), 77-83 doi: 10.1109/SSRR50563.2020.9292607, (2020).

Altman, N. S. “An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression”, The American Statistician, 46(3), 175-185, doi: 10.1080/00031305.1992.10475879, (1992).

Masand, B., Linoff, G. and Waltz, D. “Classifying news stories using memory based reasoning”, içinde Proceedings of the 15th annual international ACM SIGIR conference on Research and development in information retrieval, 59-65, (1992).

Freund, Y. and Schapire, R. E. “Experiments with a new boosting algorithm”, içinde Icml, 96, 148-156, (1996).

Freund Y. and Schapire, R. E. “A decision-theoretic generalization of on-line learning and an application to boosting”, Journal of computer and system sciences, 55(1), 119-139, (1997).

Bertoni, A., Campadelli, P. and Parodi, M. “A boosting algorithm for regression”, içinde International Conference on Artificial Neural Networks, 343-348, (1997).

Liaw, A. and Wiener, M. “Classification and regression by randomForest”, R news, 2(3), 18-22, (2002).

Akman, M., Genç, Y. and Ankaralı, H. “Random forests yöntemi ve sağlık alanında bir uygulama”, *Türkiye Klinikleri Journal of Biostatistics*, 3(1), 36-48, (2011).

Adithya, V. and Deepak, G. “HBlogRec: A Hybridized Cognitive Knowledge Scheme for Blog Recommendation infusing XGBoosting and Semantic Intelligence”, içinde 2021 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT), 1-6, doi: 10.1109/CONECCT52877.2021.9622526 (2021).

Da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B. and Dos Reis Alves, S. F. *Artificial Neural Networks*. Cham: Springer International Publishing, doi: 10.1007/978-3-319-43162-8, (2017).

Alpaydin, E., *Introduction to machine learning*. MIT press, (2009).

Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D. and Veith, T. L. “Model evaluation guidelines for systematic quantification of accuracy in watershed simulations”, *Transactions of the ASABE*, 50(3), 885-900, (2007).

Willmott, C. J. “Some comments on the evaluation of model performance”, *Bulletin of the American Meteorological Society*, 63(11), 1309-1313, (1982).

Gümüőboęa, İ. “İnsansız hava aracı temelli bir otomatikleőtirilmiő stok sayım sistemi tasarımı”, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(4), 1767-1782, (2022).

Seękin, A. Ç. “Adaptive Positioning System Design Using AR Markers and Machine Learning for Mobile Robot”, içinde 2020 5th International Conference on Computer Science and Engineering (UBMK), 160-164, doi: 10.1109/UBMK50275.2020.9219475, (2020).

Khalaf-Allah, M. “Particle Filtering for Three-Dimensional TDoA-Based Positioning Using Four Anchor Nodes”, *Sensors*, 20(16), doi: 10.3390/s20164516, (2020).

Marasigan, R. I., Austria, Y. D., Enriquez, J. B., Lolong Lacatan, L. and Dellosa, R. M. "Unmanned Aerial Vehicle Indoor Navigation using Wi-Fi Trilateration", içinde 2020 11th IEEE Control and System Graduate Research Colloquium (ICSGRC), 346-351. doi: 10.1109/ICSGRC49013.2020.9232623, (2020).

Magree D. and Johnson, E. N. "Combined laser and vision-aided inertial navigation for an indoor unmanned aerial vehicle", içinde 2014 American Control Conference, 1900-1905, doi: 10.1109/ACC.2014.6858995, (2014).

Tiemann J. and Wietfeld, C. "Scalable and precise multi-UAV indoor navigation using TDOA-based UWB localization", içinde 2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN), 1-7. doi: 10.1109/IPIN.2017.8115937, (2017).

Breiman, L. "Random forests", Machine learning, 45(1), 5-32, (2001).

Vicon MX Systems [online], (14 Aralık 2022). <http://www.vicon.com/products>, (2022).

Leica TS30 [online] (15 Aralık 2022), http://www.leica-geosystems.us/downloads123/zz/tps/TS30/brochures/TS30_Brochure_us.pdf, (2022).

Vikipedi, "Hava gemisi [online]", (04 Ocak 2023), https://tr.wikipedia.org/w/index.php?title=Hava_gemisi&oldid=28884873, (2022).

Vikipedi, "Döner kanatlı hava aracı [online]", (04 Ocak 2023), https://tr.wikipedia.org/w/index.php?title=D%C3%B6ner_kanatlı_hava_arac%C4%B1&oldid=24197155, (2020).

EKLER

9. EKLER

EK A Homography Matrisinin Çıkarılmasında Kullanılan Kodlar

```
# -*- coding: utf-8 -*-
"""
Created on Thu Jul  8 22:24:00 2021
"""
import csv
import cv2
import numpy as np
#import matplotlib.pyplot as plt
import imutils
import os

cv2ocl.setUseOpenCL(False)
feature_extractor = 'brisk' # one of orb 'sift', 'surf', 'brisk', 'orb'
feature_matching = 'bf'
# read images and transform them to grayscale
# Make sure that the train image is the image that will be transformed
image_directory = 'img/'

def getHomography(kpsA, kpsB, featuresA, featuresB, matches, reprojThresh):
    # convert the keypoints to numpy arrays
    kpsA = np.float32([kp.pt for kp in kpsA])
    kpsB = np.float32([kp.pt for kp in kpsB])

    if len(matches) > 4:

        # construct the two sets of points
        ptsA = np.float32([kpsA[m.queryIdx] for m in matches])
        ptsB = np.float32([kpsB[m.trainIdx] for m in matches])

        # estimate the homography between the sets of points
        (H, status) = cv2.findHomography(ptsA, ptsB, cv2.RANSAC,
                                         reprojThresh)

        return (matches, H, status)
    else:
        return None

def detectAndDescribe(image, method=None):
    """
    Compute key points and feature descriptors using an specific method
    """
    assert method is not None, "You need to define a feature detection method. Values
    are: 'sift', 'surf'"
```

```

# detect and extract features from the image
if method == 'sift':
    descriptor = cv2.SIFT_create()
elif method == 'surf':
    descriptor = cv2.SURF_create()
elif method == 'brisk':
    descriptor = cv2.BRISK_create()
elif method == 'orb':
    descriptor = cv2.ORB_create()

# get keypoints and descriptors
(kps, features) = descriptor.detectAndCompute(image, None)

return (kps, features)

def createMatcher(method,crossCheck):
    "Create and return a Matcher Object"

    if method == 'sift' or method == 'surf':
        bf = cv2.BFMatcher(cv2.NORM_L2, crossCheck=crossCheck)
    elif method == 'orb' or method == 'brisk':
        bf = cv2.BFMatcher(cv2.NORM_HAMMING, crossCheck=crossCheck)
    return bf

def matchKeyPointsBF(featuresA, featuresB, method):
    bf = createMatcher(method, crossCheck=True)

    # Match descriptors.
    best_matches = bf.match(featuresA,featuresB)

    # Sort the features in order of distance.
    # The points with small distance (more similarity) are ordered first in the vector
    rawMatches = sorted(best_matches, key = lambda x:x.distance)
    print("Raw matches (Brute force):", len(rawMatches))
    return rawMatches

def matchKeyPointsKNN(featuresA, featuresB, ratio, method):
    bf = createMatcher(method, crossCheck=False)
    # compute the raw matches and initialize the list of actual matches
    rawMatches = bf.knnMatch(featuresA, featuresB, 2)
    print("Raw matches (knn):", len(rawMatches))
    matches = []

    # loop over the raw matches
    for m,n in rawMatches:
        # ensure the distance is within a certain ratio of each
        # other (i.e. Lowe's ratio test)
        if m.distance < n.distance * ratio:
            matches.append(m)

```

```

return matches

images = sorted(os.listdir(image_directory), key=lambda x:
os.path.getctime(image_directory+x))

for i in range(len(images)-1):

    trainImg = cv2.imread(image_directory+images[i], 1)
    trainImg_gray = cv2.cvtColor(trainImg, cv2.COLOR_RGB2GRAY)

    queryImg = cv2.imread(image_directory+images[i+1], 1)
    # Opencv defines the color channel in the order BGR.
    # Transform it to RGB to be compatible to matplotlib
    queryImg_gray = cv2.cvtColor(queryImg, cv2.COLOR_RGB2GRAY)
    """

    fig, (ax1, ax2) = plt.subplots(nrows=1, ncols=2, constrained_layout=False,
figsize=(16,9))
    ax1.imshow(queryImg, cmap="gray")
    ax1.set_xlabel("Query image", fontsize=14)

    ax2.imshow(trainImg, cmap="gray")
    ax2.set_xlabel("Train image (Image to be transformed)", fontsize=14)

    plt.show()
    """

    kpsA, featuresA = detectAndDescribe(trainImg_gray, method=feature_extractor)
    kpsB, featuresB = detectAndDescribe(queryImg_gray, method=feature_extractor)
    """

    # display the keypoints and features detected on both images
    fig, (ax1,ax2) = plt.subplots(nrows=1, ncols=2, figsize=(20,8),
constrained_layout=False)
    ax1.imshow(cv2.drawKeypoints(trainImg_gray,kpsA,None,color=(0,255,0)))
    ax1.set_xlabel("(a)", fontsize=14)
    ax2.imshow(cv2.drawKeypoints(queryImg_gray,kpsB,None,color=(0,255,0)))
    ax2.set_xlabel("(b)", fontsize=14)

    plt.show()
    """

    print("Using: { } feature matcher".format(feature_matching))

    """

    fig = plt.figure(figsize=(20,8))
    """

    if feature_matching == 'bf':
        matches = matchKeyPointsBF(featuresA, featuresB, method=feature_extractor)
        img3 = cv2.drawMatches(trainImg,kpsA,queryImg,kpsB,matches[:100],
None,flags=cv2.DrawMatchesFlags_NOT_DRAW_SINGLE_POINTS)
    elif feature_matching == 'knn':

```

```

    matches = matchKeyPointsKNN(featuresA, featuresB, ratio=0.75,
method=feature_extractor)
    img3 =
cv2.drawMatches(trainImg,kpsA,queryImg,kpsB,np.random.choice(matches,100),
None,flags=cv2.DrawMatchesFlags_NOT_DRAW_SINGLE_POINTS)

"""
plt.imshow(img3)
plt.show()
"""

M = getHomography(kpsA, kpsB, featuresA, featuresB, matches, reprojThresh=4)
if M is None:
    print("Error!")
(matches, H, status) = M
print(H)

filename="MURAT2_"+feature_extractor+".csv"
with open(filename,'a',newline='') as f:
    b=H.flatten()
    b=b.tolist()
    writer = csv.writer(f,delimiter=';')
    writer.writerow(b)

# Apply panorama correction
width = trainImg.shape[1] + queryImg.shape[1]
height = trainImg.shape[0] + queryImg.shape[0]

result = cv2.warpPerspective(trainImg, H, (width, height))
result[0:queryImg.shape[0], 0:queryImg.shape[1]] = queryImg
"""
plt.figure(figsize=(20,10))
plt.imshow(result)

plt.axis('off')
plt.show()
"""

# transform the panorama image to grayscale and threshold it
gray = cv2.cvtColor(result, cv2.COLOR_BGR2GRAY)
thresh = cv2.threshold(gray, 0, 255, cv2.THRESH_BINARY)[1]

# Finds contours from the binary image
cnts = cv2.findContours(thresh.copy(), cv2.RETR_EXTERNAL,
cv2.CHAIN_APPROX_SIMPLE)
cnts = imutils.grab_contours(cnts)

# get the maximum contour area
c = max(cnts, key=cv2.contourArea)


```

```
# get a bbox from the contour area
(x, y, w, h) = cv2.boundingRect(c)

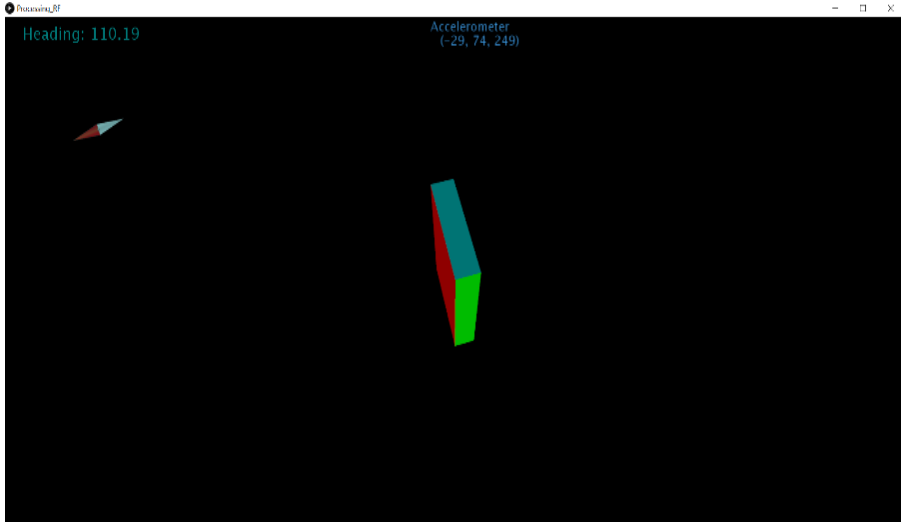
# crop the image to the bbox coordinates
result = result[y:y + h, x:x + w]
"""

# show the cropped image
plt.figure(figsize=(20,10))
plt.imshow(result)
"""
```



EK B 10DOF IMU Verilerinin Anlık Olarak Ekranı Aktarılması



Şekil B.1: IMU pusula ve X, Y oryantasyon görüntüsü.




Şekil B.2: IMU pusula ve X, Y oryantasyon görüntüsü.




Şekil B.3: IMU pusula ve X, Y oryantasyon görüntüsü.


EK C Drone Üzerinden IMU Verilerini Okumak İçin Tasarlanan Sistem



Şekil C.1:ESP32 ve MPU9250 bağlantısı.



Şekil C.2:ESP32 ve adafruit 10Dof imu bağlantısı.



Şekil C.3:Dron üzerinden imu verilerini okumak için 3D yazıcıyla yapılan bağlantı bloğu.

EK D İ mekan ArUco tespit alıřmaları



Şekil D.1: Kapalı alan testlerinden bir görüntü.



Şekil D.2: Kapalı alan testlerinden bir görüntü.



Şekil D.3: Kapalı alan testlerinden bir görüntü.



Şekil D.4: Kapalı alan testlerinden bir görüntü.



Şekil D.5: Kapalı alan testlerinden bir görüntü.

Şekil D.1’den Şekil D.5’e kadar olan kapalı alan çalışmalarının tamamı, Dokuz Eylül Üniversitesi Efes Meslek Yüksekokulu C Blok 1. Kat ortak salonunda yapılmıştır.

EK E Açık Alan ArUco Tespit Çalışmaları



Şekil E.1: Açık alan ArUco testlerinden bir görüntü.



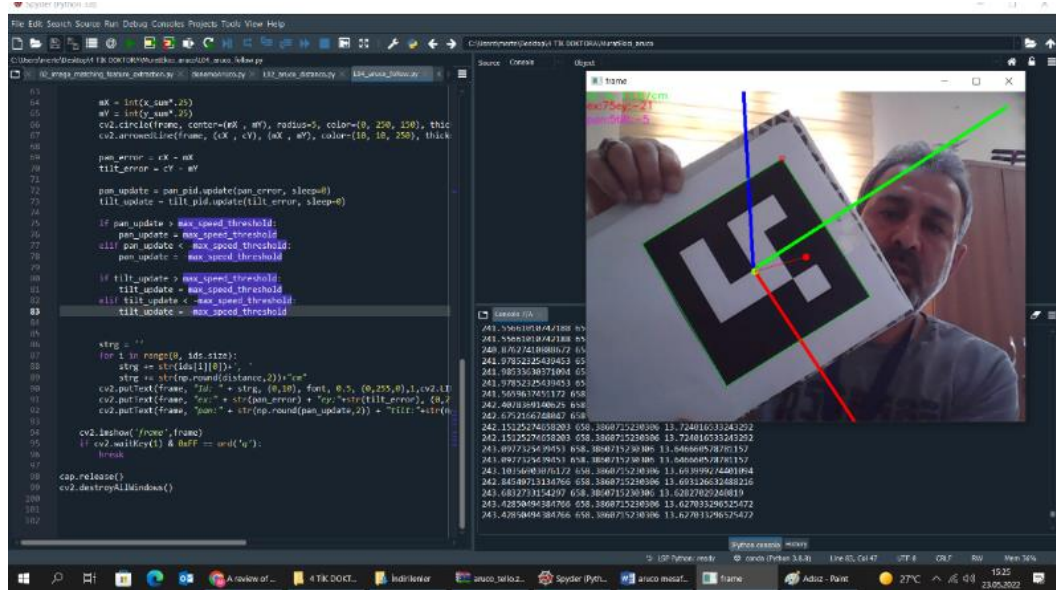
Şekil E.2: Açık alan ArUco testlerinden bir görüntü.



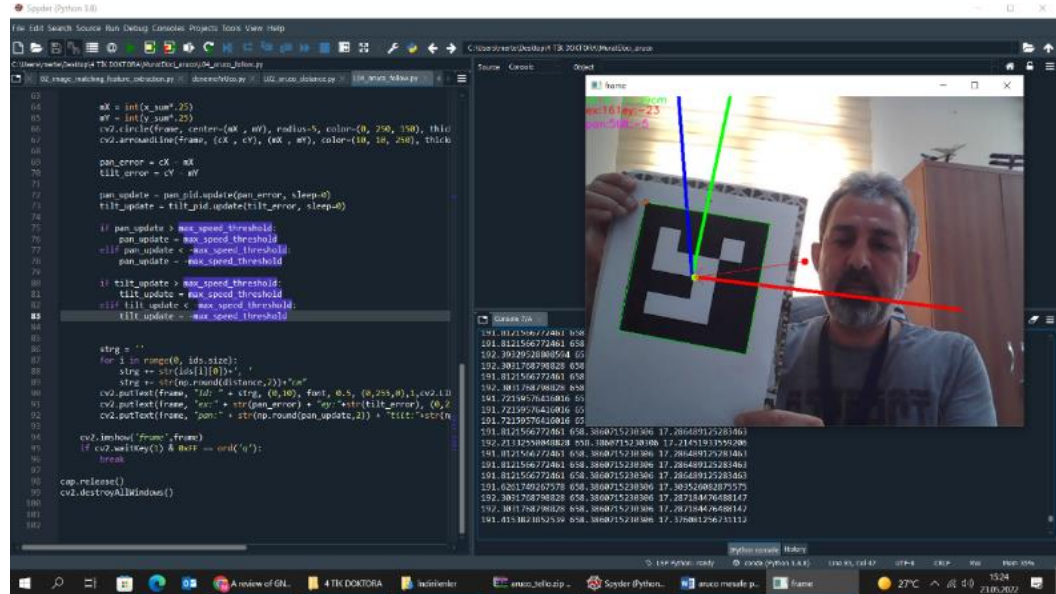
Şekil E.3: Açık alan ArUco testlerinden bir görüntü.

Şekil E.1'den Şekil E.3'e kadar olan açık alan çalışmalarının tamamı, Türk Hava Kurumu Selçuk EFES Havaalanında yapılmıştır.


EK F ArUco Marker'in Kamera Tarafından Tespit Edilmesi Ve Markerin Kamera Odağına Olan Uzaklığının Ölçülmesi



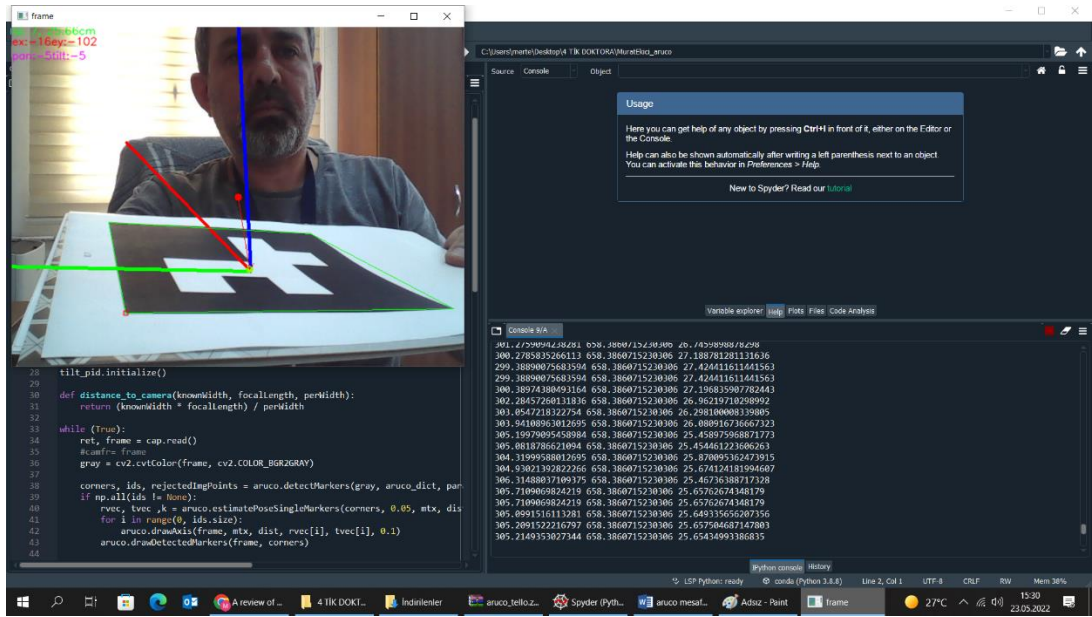
Şekil F.1: ArUco tespiti ve kameraya olan uzaklığının bulunması.



Şekil F.2: ArUco tespiti ve kameraya olan uzaklığının bulunması.



Şekil F.3: ArUco tespiti ve kameraya olan uzaklığının bulunması.



Şekil F.4: ArUco tespiti ve kameraya olan uzaklığının bulunması.