



**BULUT TABANLI DERİN ÖĞRENME
KULLANARAK İNSANSIZ HAVA ARAÇLARI İÇİN
GERÇEK ZAMANLI NESNE ALGILAMA**

Mehmet Bilge Han TAŞ

Danışman: Prof. Dr. Abdulsamet HAŞILOĞLU

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Ana Bilim Dalı

2021

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

**BULUT TABANLI DERİN ÖĞRENME KULLANARAK İNSANSIZ HAVA
ARAÇLARI İÇİN GERÇEK ZAMANLI NESNE ALGILAMA**
(Real-Time Object Detection for Unmanned Aerial Vehicles Using Cloud-Based Deep
Learning)

YÜKSEK LİSANS TEZİ

Mehmet Bilge Han TAŞ

Danışman: Prof. Dr. Abdulsamet HAŞILOĞLU

Erzurum
Haziran, 2021

KABUL VE ONAY TUTANAĞI

Mehmet Bilge Han TAŞ tarafından hazırlanan “Bulut Tabanlı Derin Öğrenme Kullanarak İnsansız Hava Araçları İçin Gerçek Zamanlı Nesne Algılama” başlıklı çalışması .. / .. / 20.. tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Bilgisayar Mühendisliği Ana Bilim Dalı, Bilgisayar Mühendisliği Bilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Başkanı:	Prof. Dr. Asaf VAROL <i>Maltepe Üniversitesi</i>	
Danışman:	Prof. Dr. Abdulsamet HAŞILOĞLU <i>Atatürk Üniversitesi</i>	
Jüri Üyesi:	Dr. Öğr. Üyesi Barış ÖZYER <i>Atatürk Üniversitesi</i>	

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof. Dr. Saltuk Buğrahan CEYHUN
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisan Tezi olarak *Prof. Dr. Abdulsamet HAŞILOĞLU* danışmanlığında sunulan “Bulut Tabanlı Derin Öğrenme Kullanarak İnsansız Hava Araçları İçin Gerçek Zamanlı Nesne Algılama” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	0	30
Kuramsal Temeller	0	30
Materyal ve Yöntem	0	35
Bulgular	0	20
Tartışma	0	20
Tezin Geneli	1	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Mehmet Bilge Han TAŞ	Prof. Dr. Abdulsamet HAŞILOĞLU
21.6.2021	21.6.2021
İmza:	İmza:

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Yüksek lisans öğretimim boyunca değerli ve eşsiz fikirleriyle yolumu aydınlatan, tezimin her aşamasında bilgi, tecrübe ve desteğini hiçbir zaman esirgemeyen ve bize yeni çalışmalar konusunda teşvik eden ve kılavuzluk yapan tez danışmanım, saygı değer hocam Sayın Prof. Dr. Abdulsamet HAŞILOĞLU'na,

Çalışmalarımın gerçekleşmesinde katkılarını esirgemeyen ve sürekli yapıcı tutumlarından dolayı Atatürk Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği öğretim üyelerine ve görev yaptığım, Erzincan Binali Yıldırım Üniversitesi Bilgisayar Mühendisliği Bölümü öğretim üyelerine,

Benim için her şeye katlanan her zaman yanımda olan, beni sabırla ve sevgiyle yetiştiren canım annem Süreyya TAŞ'a, çocukluktan bugüne kadar özel ilgi ve alaka ile yetiştiren, kişiliği ve akademik hayatını örnek aldığım, gurur kaynağım babam Prof. Dr. Necati Fahri TAŞ'a, beni sürekli destekleyen, her konuda yardımcı olan ağabeylerim Necip Gökhan TAŞ ve Hakan Gökalp TAŞ'a, çalışmalarımı her zaman destekleyen huzurlu ve rahat bir çalışma ortamı oluşturmak için her fedakarlığı göze alan eşim Senanur TAŞ'a

Saygı ve sevgilerimle sonsuz teşekkürlerimi sunarım.

Mehmet Bilge Han TAŞ

ÖZET

YÜKSEK LİSANS TEZİ

BULUT TABANLI DERİN ÖĞRENME KULLANARAK İNSANSIZ HAVA ARAÇLARI İÇİN GERÇEK ZAMANLI NESNE ALGILAMA

Mehmet Bilge Han TAŞ

Danışman: Prof. Dr. Abdulsamet HAŞILOĞLU

Amaç: Çalışma, zayıf işlem gücüne sahip ve hareket edebilen sistemlerin bulut servislerini kullanarak nesne algılayabilmesini sağlamak amacıyla yapılmıştır. Buna ek olarak, büyük veri oluşturmak için sürekli etiketleme işlemi yaparak veri seti genişletilmektedir. Çalışmada insansız hava aracıyla (İHA) bulut tabanlı derin öğrenme yöntemleri kullanarak nesne algılama yapılması hedeflenmiştir.

Yöntem: Çalışmada bulut servis sağlayıcı olan Google Colaboratory ile eğitim işlemleri yapılmıştır. Eğitim işlemleri YOLO tabanlı bir sistem olup, kendi ihtiyaçlarımız doğrultusunda parametreleri revize edilerek bir evrişimli sinir ağı oluşturulmuştur. Evrişimli sinir ağı modeli, görüntü verilerini istenen piksel aralıklarına getirerek, evrişim katmanlarındaki nöronlar arasında iletişim sağlamaktadır. Etiketli olmayan resimler etiketlenerek eğitime dahil edilmektedir. Bu sayede veri havuzunun sürekli bir biçimde büyütülmesi mümkündür. İHA’larda kullanılan mikrobilgisayarlar, bu işlemler için yetersiz kalması nedeniyle bulut tabanlı bir eğitim modeli oluşturulmuştur.

Bulgular: Çalışma sonucunda İHA hem manuel hem de otonom uçuş sağlayabilmektedir. Bulut tabanlı derin öğrenme modelleri istenen şekilde çalışmaktadır. Modelin doğruluğunu kayıp fonksiyonlarda görülen, düşük kayıplar ile göstermek mümkündür. Çalışmada ayrıca veri havuzu oluşturulmuş olup sürekli bir şekilde verileri bulutta tutmak mümkündür. LIDAR ile çevre etkileşimi gözlenmiş, hareketli ve hareketsiz nesnelerin fark edilmesi sağlanmıştır.

Sonuç: İHA gibi hareketli sistemlerde, düşük işlem güçlü mikrobilgisayarlar kullanılmaktadır. Eğitimlerin sağlanabilmesi için yüksek işlem gücüne sahip ekran kartlarına ihtiyaç duyulmaktadır. Görüntü verileri üzerinde çalışırken güçlü ekran kartlarını kullanmak elzemdir. Böylece bulut hizmetleri kullanarak hem ekonomik açıdan hem de zaman açısından maliyet düşürülmüş. Bulut hizmetleri kullanarak eğitim hızlandırılmış, yüksek oranlı nesne tespitleri yapılmıştır. Etiketleme işlemleri yaparak, veri havuzu büyütülmüştür ve sürekli bir şekilde büyümeye devam edecektir. Bunlara ek olarak LIDAR kullanımının önemi belirtilmiştir ve çevre etkileşimi bu sayede artırılmıştır.

Anahtar Kelimeler: Bulut Tabanlı Derin Öğrenme, LIDAR, İnsansız Hava Aracı, Gerçek Zamanlı Nesne Algılama, Nesne Tespiti, Evrişimli Sinir Ağları.

Haziran 2021, 69 sayfa

ABSTRACT

MASTER'S THESIS

REAL-TIME OBJECT DETECTION FOR UNMANNED AERIAL VEHICLES USING CLOUD-BASED DEEP LEARNING

Mehmet Bilge Han TAŞ

Supervisor: Prof. Dr. Abdulsamet HAŞILOĞLU

Purpose: The study was carried out to enable mobile systems with weak processing power to detect objects using cloud services. In addition, it enlarges the dataset by continuously labeling it to create its own big data. In the study, it is aimed to make object detection using unmanned aerial vehicles and cloud-based deep learning methods.

Method: In the study, training procedures were carried out with the cloud service provider Google Colaboratory. Training processes are a YOLO-based system, and a convolutional neural network was created by revising the parameters of the system in line with our own needs. In the convolutional neural network model, communication between neurons in the convolutional layers is provided by bringing the image data to the desired pixel intervals. Unlabeled pictures are included in the training by being tagged. In this way, it is possible to continuously enlarge the data pool. Since the microcomputers used in unmanned aerial vehicles are insufficient for these processes, a cloud-based training model has been created.

Findings: As a result of the study, the UAV can provide both manual and autonomous flight. Cloud-based deep learning models work as desired. It is possible to show the accuracy of the model with the low losses seen in missing functions. In the study, a data pool has also been created and it is possible to keep the data in the cloud continuously. Environmental interaction was observed with LIDAR, and it was ensured that moving and stationary objects were noticed.

Results: With the study, low processing power microcomputers are used in mobile systems such as UAV. Graphics cards with high processing power are needed to provide training. It is essential to use powerful graphics cards when working on image data. Thus, by using cloud services, the cost has been reduced both in terms of economy and time. By using cloud services, training was accelerated and high-rate object detections were made. By doing tagging operations, the repository has been enlarged and will continue to grow continuously. In addition to these, the importance of using LIDAR is stated and environmental interaction is increased in this way.

Keywords: Cloud Based Deep Learning, LIDAR, Unmanned Aerial Vehicle, Real Time Object Detection, Object Detection, Convolutional Neural Network.

June 2021, 69 pages

İÇİNDEKİLER

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR VE SİMGELER DİZİNİ	xi
GİRİŞ.....	1
KURAMSAL TEMELLER.....	3
İnsansız Hava Araçlarının Mekanik ve Aerodinamik Tasarımı	3
İnsansız Hava Araçlarında Otonom Uçuş ve Haberleşme.....	4
Robotlarda Görüntü İşleme	5
İnsansız Hava Araçlarında Bilgisayarlı Görü.....	6
İnsansız Hava Araçlarında Görüntü İşleme.....	8
İnsansız Hava Araçlarında Yapay Zekâ	9
İnsansız Hava Araçlarında Derin Öğrenme.....	10
İnsansız Hava Araçlarında Evrişimli Sinir Ağları	12
İnsansız Hava Araçlarında Gerçek Zamanlı Nesne Tespiti.....	13
Bulut Tabanlı Nesne Algılama	14
MATERYAL METOT	17
İnsansız Hava Aracının Aerodinamik ve Mekanik Yapısı	17
İnsansız Hava Aracının Aviyonik Tasarımı	22
İnsansız Hava Aracında Kullanılan Ekipmanlar ve Kurulum	26
İnsansız Hava Aracında Kullanılan Yazılımlar	33
İşletim sistemi.....	34
Yer istasyonu yazılımı	40
ROS	41
Derin Öğrenme	43
Evrişimli Sinir Ağları	45
Bulut Tabanlı Derin Öğrenme Yöntemleri Kullanılarak Gerçek Zamanlı Nesne Algılama	47
Kullanılan veri seti	48
Kullanılan CNN model.....	49
Veri setini büyütme için nesne eklenmesi	50
Görüntü ve video üzerinde nesne tespiti	51
Bulut tabanlı gerçek zamanlı nesne tespiti	53

ARAŞTIRMA BULGULARI VE TARTIŞMA.....	54
Sistem Performans Özellikleri.....	54
Tasarımın Boyutsal Parametreleri	54
Gövde ve Mekanik Sistemler	55
Aerodinamik Özellikler	55
Uçuş Performans Parametreleri	59
Uçuş Testleri ve Performans Sonuçları	59
LIDAR Sonuçları.....	60
Bulut Tabanlı Eğitilen Modelin Sonuçları.....	61
Bulut Tabanlı Nesne Algılama Sonuçları.....	65
Tartışma.....	66
SONUÇ VE ÖNERİLER	68
KAYNAKLAR.....	70
ÖZGEÇMİŞ.....	73

TABLÖLAR DİZİNİ

Tablo 1. İHA Tasarımında Kullanılan Parçaların Ağırlıkları	32
Tablo 2. Katmanların matematiksel modelleri.....	46
Tablo 3. Yaygın olarak kullanılan aktivasyon fonksiyonları.....	47
Tablo 4. İHA'nın Denge Kuvvetleri ve Yaptığı Hareketler	57
Tablo 5. İHA'nın Bazı Performans Verileri	58



ŞEKİLLER DİZİNİ

Şekil 1. Döner ve sabit kanatlı İHA	17
Şekil 2. Çeşitli motora sahip olan İHA türleri.....	17
Şekil 3. İHA için kullanılan DJI F450 gövde ve PDB (Power Distributor Board)	18
Şekil 4. Kauçuk sönümleyici grafiği	20
Şekil 5. Pitch, Roll, Yaw eksenleri.....	20
Şekil 6. Motorlar ve eksenleri	21
Şekil 7. Motor dönme eksenleri	22
Şekil 8. Navio2 ile Raspberry Pi 4 bağlantısı.....	23
Şekil 9. Li-Po Pil, PDB, ESC, BLDC motor bağlantısı	24
Şekil 10. Navio 2, Raspberry Pi 4, 2. Raspberry Pi kamera modülü, PPM kodlayıcı ve RC kumanda alıcısı bağlantısı	25
Şekil 11. Montaj için kullanılan PDB	26
Şekil 12. Raspberry Pi 4 Model B, İHA'nın mikrobilgisayarı	27
Şekil 13. Navio2 uçuş kontrol kartı.....	27
Şekil 14. Çalışmada kullanılan Li-Po batarya	28
Şekil 15. SunnySky motor (X2212), pervane (1045) ve ESC.....	28
Şekil 16. PPM Encoder, Kumanda, Telemetry	29
Şekil 17. Raspberry Pi kamera modülü	29
Şekil 18. RPLIDAR A1M8 LIDAR modülü.....	30
Şekil 19. LIDAR'ın haritalandırmasını gösteren bir örnek	30
Şekil 20. LIDAR Type-C dönüştürücü.....	31
Şekil 21. İHA'nın kurulum ve devre şeması	32
Şekil 22. Navio ve Raspberry Pi bağlantı şeması.....	33
Şekil 23. Raspbian işletim sisteminde Python projesi çalıştırılması	34
Şekil 24. Navio linux işletim sistemi giriş ekranı	35
Şekil 25. Emlid Raspbian için gerekli Wi-Fi konfigürasyon dosyası	36
Şekil 26. Emlid Raspbian için gerekli ağ ayarları	36
Şekil 27. Yerel ağa ait IPv4 adres bilgisi	37
Şekil 28. Advanced IP Scanner kullanılarak yerel ağa bağlanan cihazları tarama	37
Şekil 29. Bitwise SSH Client ile Raspberry Pi'a bağlanması	38
Şekil 30. Ardupilot ayarlarının yapılması	39

Şekil 31. Arducopter için telemetri ayarları	39
Şekil 32. Mission Planner giriş ekranı	40
Şekil 33. Gazebo Iris Dünyası giriş ekranı.....	42
Şekil 34. Genel yapay sinir ağları modeli	44
Şekil 35. Çok katmanlı ve gizli katmanlı bir yapay sinir ağı modeli	44
Şekil 36. Havuzlama işlemi.....	45
Şekil 37. Eğitim için kullanılan veri setinden örnek görüntüler	49
Şekil 38. Çalışmada kullanılan modelin mimarisi	49
Şekil 39. Önerilen bulut tabanlı büyük veri	51
Şekil 40. Resim üzerinden nesne algılama.....	52
Şekil 41. Görüntü ve video üzerinde nesne tespitinin akış diyagramı ile gösterimi	53
Şekil 42. Görüntü ve video üzerinde nesne tespitinin kaba kodu	53
Şekil 43. Pervane kuvvetleri ve eksenlerdeki hareket yönleri.....	56
Şekil 44. MissionPlaner GPS üzerinden alınan konum.....	60
Şekil 45. LIDAR ile alınmış görüntüler ve Google Earth ile karşılaştırılması	61
Şekil 46. Ağaç tespiti için eğitilen modelin kayıp fonksiyonu ve tespit başarı oranı	62
Şekil 47. Tekerlek tespiti için eğitilen modelin kayıp fonksiyonu ve tespit başarı oranı.....	63
Şekil 48. Pencere tespiti için eğitilen modelin kayıp fonksiyonu ve tespit başarı oranı	64
Şekil 49. Bisiklet tespiti için eğitilen modelin kayıp fonksiyonu ve tespit başarı oranı	65
Şekil 50. Pencere (a), ağaç (b), bisiklet (c), tekerlek (d) nesneleri için bulut tabanlı nesne algılama sonuçları.....	66

KISALTMALAR VE SİMGELER DİZİNİ

ANN	: Artificial Neural Network (Yapay Sinir Ağları – YSA)
CNN	: Convolutional Neural Networks (Evrışimli Sinir Ağları – ESA)
COG	: Center of Gravity (Ağırlık merkezi – AM)
DL	: Deep Learning (Derin Öğrenme – DÖ)
EKF	: Extended Kalman Filter (Genişletilmiş Kalman Filtresi – GKF)
GPS	: Global Positioning System (Küresel Konumlandırma Sistemi – KKS)
GPU	: Graphic Process Unit (Grafik İşlem Birimi – GİB)
IMU	: Inertial Measurement Unit (Atalet Ölçü Birimi – AÖB)
LIDAR	: Light Detection and Ranging (Işık Saptama ve Uzaklık Ölçümü – ISUÖ)
LR	: Logistic Regression (Lojistik regresyon – LR)
ML	: Machine Learning (Makine Öğrenmesi – MÖ)
ODE	: Open Dynamics Engine (Açık Dinamikler Motoru – ADM)
PDB	: Power Distribution Board (Güç Dağıtım Kartı – GDK)
RELU	: Rectified Linear Unit (Doğrultulmuş Doğrusal Birim – DDB)
RF	: Random Forest (Rastgele Orman – RO)
ROS	: Robot Operating System (Robot İşletim Sistemi – RİS)
SVM	: Support Vector Machine (Destek Vektör Makinesi – DVM)
UAV	: Unmanned Aerial Vehicle (İnsansız Hava Aracı – İHA)
YOLO	: You Look Only Once (Sadece Bir Kez Bak – SBKB)

GİRİŞ

Yapay zekâ çalışmaları 1950’li yıllarda Alan Turing’in “Makineler düşünebilir mi?” sorusuna yanıt aramakla başlamıştır (Turing & Haugeland, 1950). Daha sonra Cahit Arf’in kıymetli eserinde makinelerin düşünebilme yeteneği var mıdır ve eğer varsa nasıl düşünen makineler oluşturulabilir gibi sorulara yanıt aranılmıştır (Arf, 1959). Günümüze kadar, insanların içindeki bu merakla, makinelere mantıksal bir misyon yüklemek temel gaye olmuştur. Yapay zekâ çalışmaları 1990’lı yıllara kadar bu merak ve istekle devam etmiştir, ancak yetersiz işlemci güçleri ve yetersiz veri nedeniyle çalışmaların ivmesinde azalma olmuştur. Daha sonra gelişen teknoloji ve internetin yaygınlaşmasıyla çalışmalar hem hızlanmış hem de yayılması daha kolay bir hale gelmiştir. Bunların sonucu olarak yapay zekâ ve görüntü işleme çalışmaları yüksek bir hızla artmış ve popüler olmaya başlamıştır. Günümüzde yapay zekâ sayesinde daha akıllı, düşünebilen bilgisayarlar ve robotlar yapmak mümkündür. Görüntüler üzerinde çalışabilmekte, manipülasyon yapabilmekte; nesneleri, hareketleri, renkleri ve sayısız şeyleri tespit edebilmekteyiz. Bu sayede geçmişten beri arzu edilen, makinelerin bir şeyi öğrenmesi ve düşünmesi, teknolojinin yettiği ölçüde gerçekleştirilebilmektedir.

İlerleyen teknolojiyle birlikte dünya çapında popülerliği gittikçe artan İHA teknolojileri, Türkiye başta olmak üzere muasır medeniyetlerin birçoğunda yakından takip edilen bir konudur. Gelişen teknolojiyle birlikte görüntü işleme ve yapay zekâ kullanılarak yetenekli hale getirilmiş bir İHA, gündelik hayatı kolaylaştırmasının yanı sıra birçok yeni kullanım alanında da hizmet vermektedir. Yapay zekâ ve görüntü işleme ile donatılmış bir İHA, çok daha yetenekli hale getirilebilmektedir. Böyle bir İHA daha hızlı karar verebilir, çeşitli amaçlara uygun ve daha yüksek başarıyla, verilen görevi yerine getirebilir.

İHA, çok eski yıllarda yapılmaya başlanmış olsa da günümüzde kullanılan İHA’lar, çok daha yetenekli ve yapay zekâ, görüntü işleme gibi alanlarla birlikte çok daha gelişmiş bir seviyede kullanılmaktadır. İHA’ların kullanıldığı başlıca alanlar; keşif – gözlem yapma, zirai amaçlı kullanım, yangın tespiti ve söndürmesi, fotogrametri, savaştan İHA’lar, taşıma gibi birçok alanda kullanılmaktadır. Ayrıca çalışmada, LIDAR ile çevre etkileşimi yüksek, verilen görevleri hem otonom hem manuel olarak yerine getirebilen, bulut tabanlı derin öğrenme yöntemleri kullanarak nesne tespiti yapabilen bir İHA ortaya koyulmaktadır.

Çalışmanın ilerleyen bölümlerinde başlıklar altında detaylandırmalar yapılmıştır. “Kuramsal Temeller” bölümü altında, konuyla ilgili ve başlıklar olarak ayrılmış şekilde literatür taraması yapılmıştır. “Materyal Metot” bölümü altında İHA’nın montaj aşamaları, yer istasyonu ile bağlantıları, bulut tabanlı derin öğrenme yöntemleri kullanarak nesne tespiti nasıl yapıldığı, LIDAR’ın kullanım şekli ve tüm bağlantıları anlatılmıştır. “Araştırma Bulguları ve Tartışma” bölümünde, çalışmada elde edilen sonuçlar verilmiş ve diğer çalışmalarla karşılaştırılması yapılmıştır. “Sonuç ve Öneriler” bölümünde çalışmanın sonuçları ve literatüre katkısı anlatılmıştır. Ulaşılan sonuçlar bir bütünlük içerisinde aktarılmaya çalışılmıştır. Son paragrafta ise gelecek çalışmaların ne olacağı anlatılmıştır.



KURAMSAL TEMELLER

Bu bölümde tez çalışması çerçevesinde literatür taraması yapılmıştır. Daha düzgün ifade edebilmek adına ayrı başlıklarda incelenmiştir. Çalışma, bulut tabanlı derin öğrenme yöntemleri kullanarak insansız hava araçlarında nesne algılamadır. Bu yüzden temelde İHA ve bulut tabanlı derin öğrenme olarak iki parça düşünülerek düzenlenmiştir. Genelden özele gidilen bir anlatım tercih edilmiştir. Literatür tarandıktan sonra çalışmaya ışık tutacak detaylar mümkün mertebe eklenmiştir.

İnsansız Hava Araçlarının Mekanik ve Aerodinamik Tasarımı

Çalışmada aerodinamik parametre tahmini yapılmasının İHA'lar için ne denli önemli olduğundan bahsedilmiştir. Oluşturulacak ayrıntılı simülasyon ortamları ve kontrol sistemleri tasarımı aerodinamik tasarım yapılırken çok önemlidir. Bu yüzden uçuş testinde ölçülen verileri kullanarak simülasyon ortamında tekrar test edilmesi büyük önem arz eder. Bunun yanında sürekli ve belirlenemeyen gürültüler; rüzgâr, nem, sinyaller gibi birçok parametrenin olması, yapılacak simülasyonla gerçek arasında farklar ortaya çıkaracağından yapılması zordur. Bu yüzden problemleri çözmek için filtreleme yapmak gerekmektedir. Genişletilmiş Kalman Filtresi (GKF) bu tarz problemlerin çözümünde çok etkili olacağından bahsetmişlerdir. Standart GKF sistem dinamiklerinin birinci dereceden yaklaşımına dayanmaktadır. Yinelemeli GKF gibi daha rafine filtreler kullanılması doğrusal olmayan parametreler içeren sistemler için daha uygundur. Bu sayede doğrusallaştırma hatası daha az alınacak ve tutarlı bir simülasyon sonucu alınabilir hale gelecektir. Çalışma, sabit kanatlı İHA'lar için yapılmış olmakla birlikte bu tarz bir filtreleme işlemi döner kanatlı bir İHA için de kullanılabilir. Çünkü yinelemeli GKF ile doğrusal olmayan parametrelerin çözümü için iyi bir filtredir (Meng et al., 2010).

Yapılan çalışmada, çok motorlu İHA'lar için yüksek hassasiyetli Hesaplamalı Akışkanlar Dinamiği (HAD) simülasyonları kullanarak gerçekleştirilmiştir. Araştırmada üç farklı çok motorlu İHA kullanılmıştır bu bunlar; klasik DJI Phantom 3, SUI Endurance ve Urban Air Mobility (UAM) için yeni bir konsept olan Elytron 4S, özelleştirilmiş ileri görüşlü bir dört motorlu İHA'dır. Çift zamanlı adımlama ve bir hibrit türbülans modeli kullanılmıştır. Buna ek olarak Navier-Stokes denklemleri kullanılmıştır. DJI Phantom 3, basitleştirilmiş bir gövdeyle iniş takımı ve kamera eklenerek simüle edilmiştir. Hava etkileri; basınç, rüzgâr, nem gibi simüle edilen ortamda detaylı şekilde incelenmiştir. Özel tasarımlı SUI Endurance hibrit bir model ile karşılaştırılmış ve ileriye dönük olarak geliştirilebilen bir model olduğu

anlatılmıştır. Elytron 4S hem uçak modunda hem de helikopter modunda simüle edilmiştir. Çalışmada bu İHA'lar karşılaştırılarak gerekli simülasyon işlemleri yapıldıktan sonra birbirleriyle karşılaştırılmıştır ve tasarımlarındaki farklı artılar ve eksiler ortaya koyulmuştur (Ventura Diaz & Yoon, 2018).

Bu çalışmada türbülanslı rüzgârda birçok çeşitteki İHA'nın karşılaştırmalı bir simülasyon ortamı kurularak değerlendirilmesi yapılmıştır. Kullanılan araçlar çok motorlu olarak seçilmiştir. Aerodinamik kuvvet modellerini açıklamak amacıyla karşılaştırması yapılmıştır. Çok basit aerodinamik etkiler ile daha kapsamlı ve hesaplaması çok daha maliyetli modelleri kullanarak bir model oluşturulmaya çalışılmıştır. Oluşturulan modelde aracı, statik rüzgâr tüneline yani sabit bir rüzgâr hızı oluşturulmuş ortamda, motorlar arasındaki açısal motor hızı, hücum açısındaki farklılıklar ve görünen rüzgâr hızı hesaba katılarak oluşturulmuştur. Deneysel doğrulama iç mekânda tekrar denenerek serbest uçuştaki durumuna bakılarak teyit edilmiştir. Simüle edilmiş ortamda izleme hatasının, gerçek ortamla arasındaki hata payının %31 olduğu hesaplanmıştır. İzleme hatasının rüzgâr arttıkça yükseldiği bulunmuştur. Rüzgâr yönünde yapılan deneyde, hataların standart sapması tüm deneydeki ortalamadan %7 sapma ile gerçekleştirilmiştir. Rüzgâr dik eksende verildiğinde ise bu hatanın %56 olarak tespit edildiği görülmüştür (Bannwarth et al., 2019).

İnsansız Hava Araçlarında Otonom Uçuş ve Haberleşme

Çalışmada, küçük veya mikro olarak tanımlanan İHA'lar için otonom uçuş sistemleri çalışılmıştır. Temel amacı küçük İHA'ların potansiyelini ortaya koymak ve ticari amaçlar veya açık kaynaklı ortamlara destek olması amacıyla bir özetleme sunmaktır. Bu sayede literatürde otonom olarak uçurulan ve istenilen amaçlar çerçevesinde kullanılabilecek bir kaynak ortaya koyulmuş olacaktır. Çalışmada temel olarak yazılım ve donanım olarak iki farklı kategoride incelenmiştir. Bunun yanında radyo sinyallerinin aktarılması, otonom uçuş yapılabilecek sistemin geliştirilmesi gibi konular da incelenmiştir. Kontrolcü güçleri, hazır otonom uçuş yazılımları, sensörler ve gözlem yaklaşımları çalışmada incelenmiştir. Açık kaynaklı hazır otonom uçuş yazılımları karşılaştırılmış ve incelenmiştir. Çalışmanın sonucunda mevcut otonom uçuş yazılımları ve gelecekteki durumları hakkında bilgiler verilmiştir (Chao et al., 2010).

Bu çalışmada iletişim altyapısı olmayan İHA'larda kablosuz bir bağlantının daha ucuz ve etkili nasıl olacağı anlatılmaktadır. İrtifa seviyesi düşük İHA'larda daha az masraflı ve iletişim sağlayacak istasyonun daha kolay yerleştirileceği anlatılmaktadır. Bu sayede daha az masraflı ve efektif bir uygulama ortaya çıkacaktır. Çalışmada temel ağ mimarisi yöntemleriyle

nasıl iletişim kurulduğu anlatılmaktadır. Çalışmada üç farklı iletişim tekniğinden bahsedilmiştir ve bunlar; İHA destekli aktarma, İHA destekli veri yayılımı ve temel ağ mimarisi ve ana kanal özellikleri çalışılmıştır. Bu çeşitli iletişim ağları birbirleriyle kıyaslanarak en verimli sonuç aranmaya çalışılmıştır. Temel amaç etkin ve maliyeti düşük olmasıdır (Zeng et al., 2016).

Bu çalışmada, tarımsal uygulamalar için İHA'lerden faydalanılarak düzenli bir zirai sistem kurmak amaçlanmaktadır. İHA'ların havadaki gözetleme ve otonom faaliyetlerinden yararlanarak geniş çaplı ve düzenli bir sistem kurmak en temel amaçtır. Çalışmada İHA'lar ile robotları, yapay zekâyı, iletişim teknolojilerini, büyük veriyi ve nesnelerin internetini birleştirmektedir. Zirai amaçlı olarak kullanılacak olan İHA, çok yetenekli hale getirilmiş ve gübreleme, tohum ekimi, görüntü işleme kullanılarak büyüme değerlendirmesinin yapılması, haritalandırma gibi birçok alanda tarımsal faaliyetleri destekleyecek duruma getirilmiştir. Yapılan çalışmada bu denli çeşitli alanlarda kullanılmasından ötürü zirai İHA piyasasında önemli bir yer alacağı bahsedilmiştir. İHA'ların kontrol mekanizması, kullandığı ekipmanlar gibi birçok donanımsal ve yazılımsal entegrasyonları döneminin en iyi seviyede olduğu belirtilmiştir. Bunların yanında kullanılacak zirai amaçlı İHA'ların gelecekteki durumu ve genişleyen pazardaki yerinin ne olacağından söz edilmiş ve incelenmiştir (Kim et al., 2019).

Robotlarda Görüntü İşleme

Çalışmada mobil olarak tasarlanmış robotlarda Evrişimli Sinir Ağları (Convolutional Neural Network – CNN) ile görüntü işleme çalışması yapılmıştır. Kullanılan CNN modelde ileri beslemeli bir yöntem tasarlanmış ve uyarlanabilir filtreler ile desteklenmiştir. CNN model ile dağınık verilerin işlenmesinde önemli bir rol oynadığı belirtilmiş ve kurulan modelin ağırlıkları üzerinde etkin bir payı olduğu belirtilmiştir. CNN modellerin genellikle yüz ve karakter tanımda etkin olduğu yaygın bir düşünce olsa da çok daha çeşitli nesneler üzerinde kullanılabileceği belirtilmiştir. Çalışmada evrişimli sinir ağlarının gerçek dünyadaki görüntü işleme problemlerine çözüm getirmek amacıyla incelemeler yapılmıştır. Bunların yanı sıra mimarinin robot görüşünü etkileyecek problemlerden bahsedilmiş ve bir çözüm önerilmiştir. Üç boyutlu görüntülerde CNN modelin efektif şekilde nasıl kullanıldığından bahsedilmiştir. Kullanılan filtreler ile daha iyi performans alınabileceği incelenmiştir (Browne et al., 2008).

Bu çalışmada, otonom robotların kontrolünün zor olması ve maliyetli hesaplamalar için gerekli ekipmanların ne şekilde çözüme ulaşabilecekleri incelenmiştir. Otonom şekilde hareket edecek olan robotların veri işlemede büyük bir hesaplama maliyeti olmasından dolayı, sisteme gereksiz bir maliyet katan önemsiz fazla bilgilerin çıkarılması önerilmiştir. Bunun yanında ardışık çerçevelerin zamansal tutarsızlıklarından bahsedilmiş ve bunun çözümü için Pearson'ın

Korelasyon Katsayısına dayalı bir çözüm önerilmiştir. Bunlara ek olarak; gözden geçirme kriterleri metodolojisi, dinamik güç yönetimi çözümü, çevre gözlemci yöntemi ile bölgedeki engelleri aşabilecek ve kaçınabilecek yöntemler ve doğrusal olmayan değişkenlere bağlı olarak çarpışma riski tahmini yapabilecek bir yöntem önerilmiştir. Daha önce Pearson'ın Korelasyon Katsayısıyla önerilmiş bir yöntem olmadığı için çalışmanın özgün olduğunu söylemektedirler. Çalışmanın tamamı gerçek araçlarla yapılmış olup varılan sonuçlar bu çerçevede dahilinde incelenmiştir. Çalışma gerçek zamanlı bir sistemle yapılmıştır ve anlık hareketler uygulanmıştır. LIDAR ile çevre etkileşimi yüksek ve engellerden kaçan bir sistem ortaya koyulmuştur. Görşelliği olan bu otonom sistemde gerçek enerji tüketimleri gösterilmiştir. Altı çizilen başka bir detay ise görüntü işleyecek sistem ile robotun diğer aktiviteleri yapacağı sistem birbirinden bağımsızdır. Yani görüntü başka bir sistemde işlenirken otonom hareketler başka bir sistemde işlenmektedir. Bu sayede işlem maliyetini iki farklı sisteme dağıtarak daha performanslı şekilde çalışmaktadır (Neto et al., 2013).

Bu çalışmada basit robotik görevleri yerine getirebilecek ve Raspberry Pi 2 ile yapılmış bir robot tasarlanmıştır. Öğrencilerin ve bazı basit görevleri yerine getirebilmesi için tasarlanan bu robota Cube ismi verilmiştir. Yapılmış olan robotta Raspberry Pi kamerası kullanılmıştır ve sadece bir adet Raspberry Pi kullanılmıştır. Pi kamerasının kullanılma sebebi hafif olması ve yeterince düzgün bir çözünürlükte çalışabilmesidir. Görüntü işleme yöntemini MATLAB'da Simulink aracılığıyla yapılmıştır. Öznitelik çıkarma ve görüntü işleme işlemleri gerçek zamanlı yapılmış olup mümkün olduğunca hesaplama maliyeti düşük olması için bir yöntem geliştirmişlerdir. Kenar, köşe ve çizgi izleme gibi yetenekleri olan bu mini robotta yerleşik olan Raspberry Pi 2 ile işlemler yapılmıştır. Çalışmada yapılan uygulama çeşitli görüntüler üzerinde uygulanarak test edilmiştir. Gerçek zamanlı algılama için sistemlerin performansını artırmak adına yapılmış bu çalışmada deneysel çalışmalar incelenmiştir. Bunlara ek olarak sistemin ne kadar bir enerji ihtiyacı olduğunu ve bu enerjilerin yönetiminin nasıl olacağını ortaya koymuştur (Horak & Zalud, 2016).

İnsansız Hava Araçlarında Bilgisayarlı Görü

Bu çalışmada, İHA'ların iniş yerini bulabilmesi için çalışmalar yapılmıştır. İHA'lar GPS sayesinde bir rotalama yaparak otonom uçuş yapabilirler. GPS ile konum bilgileri girilip bir rotalandırma yaparak istenen otonom güzergâh belirlenir ve İHA bu güzergâh doğrultusunda görevini tamamlar. Bu çalışmada GPS sinyallerinin bozulması veya GPS ile uydu arasında herhangi bir nedenden dolayı kopma olması durumunda ineceği yeri tayin edebilmesi için bir sistem geliştirilmiştir. Bu inişi otonom bir şekilde gerçekleştirmektedir. İneceği yeri GPS'ten

bağımsız bir şekilde bilgisayarlı görü sayesinde yapabilmektedir. Güvenli inişe yardımcı olacak görüntü bölümlleme prosedürlerine dayanan otomatik bir sistem önerilmektedir. Döner kanatlı İHA'larda kullanılan bu sistem herhangi bir arıza veya veri kaybı durumunda devreye girerek güvenli otonom inişi vadetmektedir (Garcia-Pulido et al., 2017).

Bu makalede, son on yılı kapsayacak biçimde İHA'lar alanında geliştirilen bilgisayarlı görme algoritmalarının ve görüntülere dayalı akıllı sistemlerin geliştirilmesi incelenmiştir. Çalışmada gelişen teknolojinin getirileri olarak; daha yüksek işlem gücüne sahip cihazların üretilmesi, daha küçük üretilebilen İHA'lar ve bileşenleri, görme tekniklerinin gelişmesi gibi birçok yeni çıkan sistemler sayesinde İHA'ların da ilerlemesi gerçekleşmiştir. Bu çeşitli teknolojileri İHA'lara entegre edebilmemiz ve bunları kullanabilmemiz sayesinde birçok probleme çözüm getirilmiş olunacaktır. Entegre edilen sistemler İHA'ların çevre etkileşimini artırmış ve engellerden kaçma, nesne tespiti ve havada hareketlerine karar verme gibi önemli unsurları ile önemli bir hale gelmiştir. Gelişen bu teknolojiler sayesinde İHA'ları sadece askeri amaçlar doğrultusunda kullanmanın yanı sıra çok geniş ve sınırı olmayan bir yelpazede kullanımının önünü açmıştır. İHA'lar bilgisayarlı görme ve diğer gelişmiş sistemlerle birlikte algılama kapasitesi artmış ve konumlandırma yetenekleri sayesinde havada çarpışmalarını önlemek için sistemler geliştirilmiştir. Çalışmada görsel kilometre sayacı, engel tespiti, haritalandırma gibi çeşitli yeteneklere sahip İHA'lar karşılaştırılmış ve farklı kategorilerde ele alınmıştır (Al-Kaff et al., 2018).

Çalışmada İHA'ların yüksek hareket kabiliyetleri ve farklı irtifada uçuş yapabildiği için keşif ve gözlem amacıyla kullanılmıştır. Keşif ve gözlem amacıyla rahat bir şekilde kullanılabildiği için trafik izlemesi konusunda da kullanılabileceğinden söz edilmiştir. Çalışmada belli bir irtifa seviyesinde trafikte olan arabaların gerçek zamanlı bir tespitini yaparak, yoldan geçen arabaların da sayılması sağlanmıştır. Gerçek zamanlı yapılacak bu bilgisayarlı görü çalışmasında çeşitli CNN model kullanılarak karşılaştırma yapılmıştır. Karşılaştırılan bu modellerin birbirinden üstünlükleri çeşitli senaryolar üzerinde denendi ve fayda/zararları her bir senaryo için farklı şekilde ortaya koyulmuştur. Temel olarak kıyaslanan modeller R-CNN ve YOLOv3'tür. Bu iki model arasında hızlı çalışması, zaman maliyeti farkları ve daha yüksek başarımlı hesaplamalar hesaba katılarak karşılaştırma yapılmıştır. Arabaların tanınması için büyük bir veri seti kullanılmıştır ve her iki model için de eğitimler, aynı veri seti kullanarak ağırlıkları tutulmuştur. Karşılaştırma sonucundan YOLOv3'ün R-CNN'den daha hızlı bir sonuç elde edildiği görülmüştür (Benjdira et al., 2019).

İnsansız Hava Araçlarında Görüntü İşleme

Bu çalışmada İHA'lar ile yapay zekâyı birleştirerek, doğadaki canlıların popülasyonlarını, istilacı hayvan veya böceklerin durumlarına bakılabilecek bir araştırma yapmışlardır. Doğada bulunan canlıları termal kamera ile tespit edilmesi için ona uygun algoritmalar kullanmışlardır. Canlıların termal kamerayla tespitini veya görüntü işleyerek çevredeki nesnelerin tespit edilmesi ve sınıflandırılması sağlanmıştır. Bunun yanı sıra nesnelerin özel bir modelle kolay bir şekilde oluşturulabileceğinden bahsetmişlerdir. Çalışmada döner kanatlı bir İHA kullanılmıştır ve temel amacı keşif ve gözlemdir. Bu sayede hem maliyeti düşüktür hem de hafiftir. 16000mah ve 6 hücreli bir batarya kullanıldığından dolayı çok uzun süreler uçuş sağlanabilir. FLIR kamera kullanılmış olup görüntüler bu sayede alınabilmektedir. Görüntüler gri formata çevrilip aynı zamanda termal görüntülere dönüştürülerek tespit işlemi sağlanmaktadır. Tespit işlemleri 20 metre, 30 metre, 60 metre mesafelerden farklı açılar kullanılarak yapılmıştır (Gonzalez et al., 2016).

Bu çalışmada, orman yangınlarının erken tespit edilebilmesi görüntü işleme teknikleri kullanarak tespit edilmesi ele alınmıştır. Orman yangınlarının erken tespit edilmesi çok önemlidir o yüzden bu çalışmada orman yangınlarını erkenden tespit edilmesinde bir çalışma yürütülmüştür. Düşük maliyetli kameralar, işlem gücü yüksek bellekler ve gelişmiş işlemciler ile küçük ve hafif bir İHA tasarımı yapılmıştır. Geliştirilen İHA hem düşük maliyetli hem de hafif bir yapısı vardır. Görüntü işleme gerçek zamanlı yapılmıştır. İHA üzerinde gelişmiş bir yangın izleme ve tespit yapabilen algoritmalar kullanılmıştır. Kullanılan bu yöntemler geleneksel yangın izleme ve takip algoritmalarından performans ve teknik olarak daha gelişmiş olduğu söylenmektedir. Çalışmada, yangının hem renk hem de yangın hareketini tespit etme yeteneği mevcuttur. Bu sayede yayılımı ve yangının ne derecede ciddi olduğuna karar verilebilmektedir. Renk ve hareketin algılanması, yanlış yangın alarmlarının önüne geçebilecek özel bir sistemdir. Aynı zamanda bu ayrımın yapılması da performansı artırabilmektedir. Performans karşılaştırmasının daha iyi anlaşılabilmesi için kapalı alanda yani iç mekânda deneyler yapılmıştır. Çalışmada orman yangını algılama ve performansının iyileştirilmesi üzerine çalışılmıştır. Çalışmanın güvenilirliğini artırmak adına hem renk hem de hareket özellikleri detaylı incelenmiştir. Algoritma, önce optik akış yöntemi ve daha sonra renk tabanlı karar kuralları uygulanarak hareket ve renk özellikleri çıkarılır. Deneysel doğrulama iç mekânda yapılır. Geliştirilen uygulama yapılan bu deneyler sonucunda kanıtlanmıştır (Yuan et al., 2016).

Çalışmada, İHA ile kıyı şeridini tespiti ve izlenmesi konusunda çeşitli araştırmalar yapılmıştır. Kıyı şeridinde çevresel faktörleri, kıyı şeridindeki farklıları tespit edebilmek için

alışılmış bir sistemdir. Kıyı şeridini, yüksek özünürlüklü fotoğraflarla kıyı şeridini ıkaran ve yüksek verimli bir metodolojiyle tespit etmektedir. İHA ile fotogrametrik bir görüntü ıkarak uzaktan algılama yaklaşımı kullanılmıştır. Bu sayede kıyı şeridinin yüksek özünürlüklü dijital yüzey modelleri ıkarılmıştır. Ü boyutlu uzayda işlenebilen bir noktalar uzayı ıkartılarak, kıyıda gözlenen morfolojik farklılar ve erozyon gibi olaylar tespit edilebilmektedir. Bu alışma ile kıyı şeridinin yönetimi ve yapısal işlerde kullanılması noktasında kararlar verilebilmesine olanak sağlar. Sonuç olarak, İHA'lar ile görüntü alınır ve görüntüler işlendikten sonra kıyı şeridi üç boyutlu uzayda incelenir. Daha sonra yüksek özünürlüklü fotoğraflar ile karşılaştırılır ve bu sayede kıyıdaki deėişimler tespit edilebilir. Ama bu işleme otomatikleştirmektir. Bunlara ek olarak kıyı şeridinde yapılacak olan yapılanmalara bu sayede karar verilebilir (Topouzelis et al., 2017).

İnsansız Hava Aralarında Yapay Zekâ

Bu alışmada, genetik bulanık mantık algoritmaları kullanılmıştır. Buna ek olarak genetik bulanık ağa metotları kullanılarak karmaşık olan problemleri özmeyi amaçlamışlardır. ok yüksek performanslı hesaplama verimliliėi ile özümüne gidilmektedir. ok eşitli senaryolarda ve doğrusal olmayan deėişkenlerle karşılaşılsa bile yüksek başarımlı sonuçlar ortaya konularak spontane gelişen olaylara bile doğru cevaplar verilebilmektedir. Kolayca tasarlanabilir ve kullanılabilir olmasından dolayı da kullanımı pratiktir. alışmada ok gerçeki simülasyon ortamları kurulmuştur ve hava muharebe görevlerinde İHA'ları kontrol eden bir yapay zekâ olan ALPHA'yı kullanmışlardır. İddialarına göre alışmanın yazıldığı seneye kadar ki en karmaşık algoritmaları kullanan ve bunu bulanık mantık tabanlı bir yapay zekâ ile yaptıklarını anlatmaktadırlar (Ernest et al., 2016).

Bu alışmada telefon tabanlı ve İHA üzerine yerleşik makine öğrenmesi yapay zekasına sahip bir sistem geliştirmişlerdir. Mevcut yapay zekâ özümünün genellikle yüksek hesaplama yeteneklerine sahip güçlü platformlarda alışmaktadır. Bunun birlikte gelişen bu teknolojiyle birlikte İHA teknolojileri de bu artan kullanım şeklini bünyesine dahil etmektedir. Bu yüzden sisteme entegre güçlü sistemler kullanılmaktadır. Bu makalede, nesne algılama ve tanıma uygulamaları için akıllı telefon tabanlı yeni bir sistem önerilmektedir. Akıllı telefonda makine öğrenme tekniklerini nasıl yapılabileceğinden bahsedilmektedir. Bu farklı senaryo için yeni bir sistem tasarlanmıştır ve özelleştirilmiş bir iş akışı inşa edilmiştir. Yerleşik sistem için kullanılacak makine öğrenmesi algoritmaları açık kaynak kodlu tercih edilmiştir ve TensorFlow kütüphanesi kullanılmıştır. Bu sistemin genel odağı arama kurtarma alışmalarıdır. Bunun sebebi gerçeki senaryolarda sistemin ne denli doğru alıştığını kanıtlamaktır. Deneysel

alıřmaların sonucunda beklendiđi gibi yksek performansla alıřan ve gerek ile simlasyon arasında ufak farkların olduđu yksek dođruluk deđerleri alındıđı grlmektedir. zm iin akıllı telefonlar gibi kısıtlı iřleme gc olan cihazlar ile makine đrenimi glendirilmiřtir. TensorFlow ktphanesinin yanı sıra OpenCV gibi birden fazla ktphane alıřmada kullanılmıřtır. nerilen sistem SSD, YOLOv3 ve Tiny-YOLOv3 dahil olmak zere farklı CNN modellerin kullanımını desteklemektedir. Yksek dođruluk oranı istendiđinde YOLOv3 kullanılmasının daha dođru olduđunu nk yapılan testler sonucunda en yksek performansın bu modelde alıřtıđı gzlenmiřtir (Martinez- Alpiste et al., 2020).

alıřmada, son zamanlarda artan ucuz ve kompakt tasarımlara sahip İHA'lar ile hafif grnt algılayıcılar sayesinde uzaktan algılama uygulamaları arttıđından bahsedilmiřtir. CNN modellerin geliřtirilmesi İHA'ların sınırlı kaynaklardan dolayı hiper parametrelerle alıřmak ve bunları hassas ayarda sınıflandırmak zordur. Bu makalede İHA'lar ile CNN modelleri birleřtirerek ok amalı ve optimize edilmiř algoritmalar geliřtirerek zm getirmeyi amalamaktadırlar. Sahne sınıflandırma modelinin performanslarını artırabilmek adına iki farklı veri seti kullanılmıřtır. Bu veri setleri birbirleriyle kıyaslamak iin seilmiřtir. nerilen yntemde, diđer modellerle kıyasla ortalama 80 saniye daha kısa srede sonu vermektedir ve bařarı oranı 97.88 olarak dođruluk vermektedir. alıřmada, İHA'lar ile video kaydı alınıyor ve bir dizi olarak ereveler haline getiriliyor. Daha sonra n iřleme yapabilmek iin video kareleri kullanılıyor. Daha sonra CNN model kullanılıp eđitim bařlatılıyor. Model sonucunda istenen deđerler alınıyor ve bu iřlemi diđer modellere nazaran daha kısa bir srede elde ediyor. Performans olarak ve bařarı oranı olarak daha yksek bir sonu bulunmuřtur (Rajagopal et al., 2020).

İnsansız Hava Aralarında Derin đrenme

Bu alıřmada, İHA'lar iin tek kameradan nesne tespiti ve takibi iin bir derin đrenme yntemi sunulmaktadır. İHA'ların ađırlıđıyla iliřkili sınırlamalar sebebiyle optik sensrler, diđital kameralar gibi sistemler İHA'ların arpıřmasını nlemek ve evre etkileřimini artırmak iin kullanılmaktadırlar. alıřmada, farklı bir İHA zerine yerleřtirilmiř bir kameradan nesne tespiti ve nesne takibi yapmak iin yeni bir yntem ortaya koyulmaktadır. Bařlangı olarak perspektif dnřm modeli kullanarak arka plan hareketlerini tahmin edip, ardından manuel olarak etiketlenmiř veri setleri zerinde eđitilmiř derin đrenme sınıflandırmalarını kullanarak arka plandaki hareketli nesneleri tespit edilir. Her bir hareketli nesne iin optik akıř eřleřtirme yntemiyle zellikleri bulunur ve arka planla karřılařtırılır. Bu karřılařtırma sonucunda hareketli nesnenin ne olduđu bulunur. Kalman filtresiyle algılanan hareketli nesneler daha

tutarlı şekilde bulunur. Algoritma oluşturulurken, İHA ile alınmış video kaydıyla işlemler yapılmıştır. Bu sayede gerçekçi bir çalışma ortamı ve sonuçları ortaya koyulmuştur. Yapılan uygulamalar sonucunda küçük işlem gücü kaynaklarına sahip araç etkili bir şekilde algılama ve takip yapabildiği ortaya koyulmuştur (Ye et al., 2018).

Bu çalışmada gerçek zamanlı derin öğrenme yöntemleri kullanılarak İHA'lar için sistem tanımlama yapılmaktadır. Sistem tanımlama, girdi ve çıktı değerlerine dayalı dinamik sistemlerin matematiksel modelleri çıkarılmasıyla ilgilenen otomasyon disiplini. Geleneksel sistem tanımlama modelleri kapsamlı ve çok büyük verilerin üretilmesi gerektiğinden gerçek zamanlı uygulamalar için çok uygun değildir. Bu makalede, değiştirilmiş röle geri bildirim testi ve derin öğrenme kullanılmıştır. Bu yöntemler doğrultusunda dinamik sistemlerin parametrik tanımlaması yapılarak bu tanımlamaları gerçek zamanlı bir şekilde ortaya koymak için önerilmiştir. Önerilen yaklaşım, tek bir değiştirilmiş röle geri bildirim testi kararlı durum döngüsü gerektirir. Tanımlama ve kontrol aşamalarını stabil bir şekilde çalışması gerektiğini vaat eder. Softmax kullanılarak derin öğrenme modeline daha uygun bir şekilde model kurulmuş olur. Dört kanatlı bir İHA, havadaki durumu, irtifa seviyesi, gibi değişkenleri doğrulamak adına simüle edilir. Yapılan bu simülasyon ile gerçek karşılaştırılır ve sonuçların birbirleriyle tutarlı olduğu görülmektedir (Ayyad et al., 2020).

Bu çalışmada evrişimli sinir ağları ve transfer öğrenme kullanılarak, insansız hava aracı uçuş modu sınıflandırması yapılmıştır. Çalışmada İHA'ların küresel çapta çok verimli faydaları olduğundan bahsedilmektedir. Makalede, İHA uçuş modlarının sınıflandırılması risk değerlendirmesi için yardımcı olacak bilgiler verecektir. Örnek olarak istihbarat operasyonlarında video ile çekim alınırken uçan bir İHA tespit edebilir. Bu zafiyeti gidermek adına çok faydalı bir yol olmuş olur. Çalışmada Parrot Bebop, Parrot AR ve DJI Phantom 3 İHA'ları kullanılmıştır. DroneRF veri seti eğitim yapılmıştır. Uçuş modları olarak; gezinme, video aktarımı olan ve video aktarımı olmayan toplamda üç mod üzerinde çalışma yapılmıştır. Her bir sınıf için sinyal görüntüleri baz alınır ve aktarım öğrenmesi için ImageNet veri tabanında önceden eğitilmiş bir VGG16 evrişimli sinir ağı kullanılarak özelliklerin çıkarılmasıyla gerçekleştirilir. Makine öğrenme sınıflandırıcısı olarak Rastgele Orman (Random Forest – RF), Destek Vektör Makinesi (Support Vector Machine -SVM) ve Lojistik Regresyon (Logistic Regression – LR) kullanılmıştır. Çalışmada iki sınıf, İHA var veya İHA yok olarak, dört sınıf İHA'ların tipi ve on adet İHA uçuş modları için bir değerlendirme yapılmıştır. Deneyler sonucunda İHA'nın tespit edilmesi %100 doğruluk ve LR ile İHA tip sınıflandırması %88.6 doğruluk sağlandığı bulunmuştur. Uçuş modları sınıflandırmasında ise %87.3 doğrulukta bir sonuç bulunmuştur. Çalışmada bahsedildiği üzere DroneRF veri setiyle

alışan daha nceki alışmalara kıyasla daha yksek sonular bulunmuştur (Swinney & Woods, 2020).

İnsansız Hava Aralarında Evriřimli Sinir Ağıları

alışmada İHA'ların ekmiř olduėu grntleri kullanarak sel baskınları veya tařkınların haritalandırılması iin derin evriřimli sinir ağıları kullanılmıřtır. Su baskını, zellikle byk nfuslu yerleřim yerlerinde byk can ve mal kaybına yol aan byk bir doėa afetidir. Su baskını yařanan yerlerin hızlı ve hassas bir řekilde haritasının ıkarılması, acil durum planlarının oluřturulması ve desteklenmesinde ok nemlidir. İHA'lar hem kk hem dřk maliyetli olmasının yanı sıra tehlikeli yerlere girebilmesinden ve evresindeki grntleri aktarabilmesinden dolayı kullanımı ok etkilidir. alışmada, tařkınların sınıflandırılabilmesi ve haritalandırılabilmesi iin SVM ve CNN kullanılmıřtır. CNN model, grnt sınıflandırma ve zellik ıkarmadaki yetenekleri sayesinde yaygın řekilde kullanılan bir yntemdir. alışmada VGG tabanlı bir evriřimli sinir ağı oluřturuldu. Model optimize edildi ve k-Fold doėrulama kullanılmıřtır. nerilen yntemin doėruluėunu gstermek adına karmařıklık matrisi sonuları elde edildi. Deneyisel sonular su basmıř alanların tespiti iin FCN-16 ile %97.52, FCN-8 ile %97.8, FCN-32s ile %94.2 ve son olarak SVM ile %89 bařarı oranıyla sonular elde edilmiřtir (Gebrehiwot et al., 2019).

Bu alışmada nesne tespiti zerinde literatrle alakalı bir karřılařtırma yapılmıřtır. alışmaya gre gnmze kadar nesne tespiti ve video analizi alışmalarının sıėlıėından bahsedilmiřtir. Dřk seviyelerden gelen grnt zelliklerinin yksek seviyelere gelmesiyle performanslarda durgunlařma yařandıėından bahsedilmiřtir. Derin ėrenme alışmalarının artması ve geliřtirilen yeni algoritmalar sayesinde bu durgunluėun yerini akıcılıėa bırakacaėı belirtilmiřtir. alışmada derin ėrenme tabanlı nesne tespiti ervelerinin bir incelenmesi yapılmıřtır. alışmada derin ėrenmenin tarihinden bařlayarak, modellerin nasıl kurulması hakkında temel noktalara deėinilmiř ve nesne algılamayla ilgili mimarilerin nasıl olması gerektiėiyle ilgili vurgular yapılmıřtır. Kurulan algoritmalar aėırlıklı olarak insan yz tespiti, nesne tespiti ve insan tespiti hakkında yapılmıřtır. eřitli derin ėrenme yntemleri denenerek birbirleriyle karřılařtırılmıřtır ve iyi sonuların artıları ve eksileri ortaya konularak bir sonuca gidilmiřtir (Zhao et al., 2019).

Bu alışmada uzamsal grafikler ve tam evriřimli sinir ağıları kullanarak havadan grnt alan İHA ile kalabalık algılayan bir model ortaya koyulmuřtur. alışmadaki ama kamu gvenliėini saėlamak ve olası tehlikelerin nne gemek iin kalabalıkların tespit edilmesidir. Arařtırmacılar tarafından belirtilen zorluėun kamu alanlarında İHA'ların umasının yasak

olmasıdır. Bu sebepten dolayı kalabalık bir kitle ile karşılaşıldığında İHA'nın güvenli bir biçimde yere iniş yapmasını sağlamaktadır. Uygulama gerçek zamanlı çalışan ve bilgisayarlı görü algoritmaları kullanan bir tasarıma sahiptir. Sisteme entegre edilmiş şekilde çalışan bir kamera mevcuttur. Önerilen yöntemde, İHA'ların sınırlı işlem kapasitesine sahip sistemler kullandığı için, bu donanım kısıtlamasını aşmak adına performansı artırılmış ve optimize edilmiş bir çalışma yapılmıştır. Modelin hızlı çalışması için çok hafif çalışan bir algoritma oluşturulmuştur. Önerilen model, literatürde yer modellerden daha iyi olduğu iddia edilmektedir. Temel karşılaştırmalarının MobileNet olduğunu vurgulamışlardır ve bu kıyas sonucunda daha yüksek performanslı ve hızlı şekilde çalıştığından bahsedilmiştir (Castellano et al., 2020).

İnsansız Hava Araçlarında Gerçek Zamanlı Nesne Tespiti

Bu çalışmada gerçek zamanlı, bulut tabanlı bir nesne algılama yapılmıştır. Gerçek zamanlı nesne tespiti keşif ve gözetleme, arama kurtarma ve altyapı denetimi gibi birçok alanda kullanılan bir uygulamadır. Son yıllarda CNN modellerin ve algoritmaların yaygınlaşmasıyla birlikte bu konudaki çalışmalar da artmıştır. Çalışmada temel olarak oluşturulmuş İHA, kamerasıyla görüntülerini bir bilgisayara atmaktadır. Bilgisayara yollanmış olan görüntü, bilgisayarda işlenerek bir nesne algılama yapar. Burada bilgisayar, bulut olarak düşünülmektedir. Görüntüler İHA'da bulunan kamera ile Wi-Fi üzerinden yollanmaktadır. Oluşturulmuş modelle istenen nesneler tespit edilebilir. Burada kullanılan veri setine özel olarak etiketlenmiş nesneler de etiketlendirilebilir. Çalışmada yüzün üstünde bir etiketlenmiş nesne olduğu söylenmektedir. Çalışmada CNN model ile eğitim yapılır ve gerçek zamanlı bir şekilde nesne tespiti yapılmaya çalışılmaktadır (Lee et al., 2017).

Bu çalışmada gerçek zamanlı İHA tespiti yapılmıştır. İHA tespiti için derin öğrenmeye dayalı YOLO algoritması üzerinde çalışılmıştır. Yaygın çalışmalarda kendi veri setinin oluşturulması oldukça zahmetli ve zor bir iştir. Çünkü binlerce yüksek çözünürlüklü görüntü çekmek gerekmektedir. Veri seti oluşturulduktan sonra YOLOv2 ve YOLOv3 karşılaştırılmıştır. Özel olarak oluşturulmuş veri seti için YOLOv3 doğruluk ve hız açısından YOLOv2'den daha iyi bir sonuç vermiştir. Veri setinin azlığından dolayı kendi veri setlerini oluşturmuşlardır. Derin bir ağ olan Darknet-53, 53 evrişimli katmana sahip olup YOLOv3'ün omurgasını oluşturmaktadır. Bu evrişimli katmanlar kullanılarak bir etiketleme işlemi yapılmış olur. Bir nesne bir sınıfa aitse başka bir sınıfa ait olamaz mantığı düşünülerek Softmax kullanılmıştır. Tüm bu işlemler yapıldıktan sonra model eğitilmiş ve YOLOv3'ün daha yüksek performansta çalıştığı gözlemlenmiştir (Xie et al., 2018).

Bu çalışmada, İHA'lar için gerçek zamanlı nesne algılama konuları araştırılmıştır. İlk olarak YOLO (You Look Only Once) yönteminden bahsedilmiştir. YOLO sayesinde hızlı ve yüksek performanslı gerçek zamanlı nesne tespiti yapmak mümkündür. YOLO yüksek başarımlı bir tespitten ziyade hızlı karar verebilen sistemler için oldukça uygundur. YOLO ile insan, araba, otobüs gibi hareketli nesneler daha iyi şekilde tanınabilir ve tespit edilebilmektedir. Çalışmada yüksek, orta, düşük irtifada farklı ışık açıları da göz önünde bulundurularak insan, araba, kamyon, otobüs gibi nesneler farklı arka planlarda değerlendirilmiştir. Bu farklı arka planlarda her nesnenin bir deneysel sonucunu görmek mümkündür. Farklı arka planlarda çekilen görüntülerle tekrar YOLOv3 ile eğitilmiştir ve bunun amacı daha fazla görüntü ile eğitimin başarısını artırmaktır. Yeniden eğitilmiş YOLOv3, yoğun arka plana sahip görüntülerde arabaları çok iyi şekilde tespit ederken; insan, otobüs, kamyon görüntülerini iyi şekilde tespit edemediği görülmüştür (Wu & Zhou, 2019).

Bu çalışmada, uzamsal bağlam analizi ile özellik füzyonu kullanılarak tek atışlı dedektör kullanılarak İHA görüntülerindeki küçük nesneleri algılama araştırılmıştır. İHA'larda görüntüler, irtifası yüksek uçuşlarda oldukça küçük gözükmetedir. Nesne tespiti konusunda küçük nesnelerin tespit edilmesi hala çözilememiş problemlerden biridir. Bu çalışmada bu probleme değinilmiştir ve küçük nesnelerin tespiti için özellik füzyonu ve ölçeklendirme tabanlı tek atış sensörü önerilmektedir. Özellik piramidi oluşturmak için ortalama bir havuzlama işlemi yapılmaktadır. Orijinal özellik füzyon dalı, küçük nesneleri algılama konusunda daha iyi olacağı için göreve uygun şekilde ayarlanır. Deneyler sonucunda ortaya koyulan yöntemle daha iyi bir başarıyla küçük nesnelerin tespiti sağlandığı görülmektedir. Bunun yanı sıra daha fazla veri setiyle beslenmiş bir model daha yüksek sonuçları elde edebilmek için gereklidir (Liang et al., 2019).

Bulut Tabanlı Nesne Algılama

Bu çalışmada videolarda bulut tabanlı ve ölçeklenebilir nesne algılama ve sınıflandırma işlemleri yapılmıştır. Kameralar, cep telefonları gibi görüntü alabilen cihaz sayısı arttığı için her gün büyük miktarda veri üretilmektedir. Bu video verileri o kadar büyüktür ki artık manuel olarak etiketlendirmek neredeyse imkânsız hale gelmiştir. Çalışmada çok sayıda video akışını işlemek için bulut tabanlı ve otomatikleştirilmiş bir video analiz sistemi önerilmektedir. Burada temel altyapı dikkate alınarak akışların sayısına ve boyutuna göre ölçeklendirebilir. Önerilen sistemde manuel etiketlemeyi azaltmak ve iş yükünden kurtarmak için otomatik çalışan bir sistem sunulmaktadır. Burada hem çok büyük hızla verilerin etiketlenmesinin kolaylaşması hem de artan verileri işleyebilecek manuel gücün olmamasından dolayı bu otomatik sistemin

çok yararlı olacağı düşünülmektedir. Video akışları daha sonra otomatik olarak bir bulut depolama sisteminde tutulur ve analiz edilir. Önerilen sistem, 6.5 saatte on beş düğümlü bir bulut üzerinde 175GB boyutunda olan ve bir aylık görüntü içeren videolardan nesneleri bulabildi ve sınıflandırabilmiştir. GPU destekli altyapının aynı görevi tekrar yerine getirmesi 3 saati bulmuştur. Bulutta çalışan GPU kullanımı optimize edilmiş ve CPU ile GPU arasındaki veri aktarımı en aza indirilmiştir. Sistemin başarısı %95 gibi yüksek bir doğruluk oranıyla başarısını kanıtlamıştır (Yaseen et al., 2018).

Bu çalışmada, internet üzerinden İHA'ları kullanarak bulut tabanlı gerçek zamanlı nesne izleme üzerinde araştırmalar yapılmıştır. Düşük maliyetli İHA'lar nesnelerin interneti uygulamalarının ufkunu açacak bir seviye gelmiştir. Bulut tabanlı sistemlerin de kullanımının artmasıyla daha düşük maliyetle yüksek işlem güçleri kullanabilir hale gelmiştir. Aynı zamanda diğer nesnelerle olan etkileşimi de artmaktadır. Bunun yanında gerçek zamanlı bulut teknolojileri daha fazla araştırma gereken temel bir zorluk olmaya başlamaktadır. Çalışmada internet üzerinden, bir nesneyi takip eden bir İHA kullanılmıştır. Nesnenin tespit edilmesi ve takip edilmesi işlemi bulut tabanlı ve gerçek zamanlı bir biçimde yapılmaktadır. Yapmış oldukları bu sisteme DroneTrack denmiştir. DroneTrack, İHA'ların internet üzerinden kontrolü, iletişimi ve yönetimi için bir sistem olan DroneMap'ten yararlanmaktadır. İzleme yapılırken GPS üzerinden alınan bilgileri bulut aracılığıyla değiş tokuş ederek bir sistem tasarlanmıştır. Gerçek ve simüle edilmiş bir ortam hazırlanmıştır. Çalışma sabit hızda hareket eden bir nesneyi 3.5 metrelik bir uzaklıktan takip ederek yapılmıştır. Bu çalışma deneysel ve simüle edilmiş veriler kıyaslanarak birbirine çok yakın sonuçlar elde edilmiştir (Koubâa & Qureshi, 2018).

Bu çalışmada 2D LIDAR ve RGB-D kamera kullanılarak ROS tabanlı otonom mobil robot navigasyonu alanında araştırmalar yapılmıştır. Çalışmada robot işletim sistemi (Robot Operating System – ROS) ile otonom bir robot uygulaması sunulmaktadır. Sistem, düşük güç tüketimli ve ucuz yerleşik bir bilgisayarla yapılmıştır. Minimum parametre değişikliği yapılarak temel ROS paketleri kullanılmıştır. İki farklı robot kullanılmıştır. İlk oluşturulan sistemde Raspberry Pi 3 ve üzerine kurulmuş bir LIDAR ile oluşturulmuştur. İkinci sistemde Intel NUC üzerine LIDAR ve RGB-D kamera entegre edilerek kullanılmıştır. Performans karşılaştırılması yapılabilmesi için birçok deney ve gözlem yapılmıştır. Deneyler yapılırken, ortamdaki engellerden robotun kaçabilmesi ve kaçamayacak durumlarda durabilmesine dikkat edilmiştir. LIDAR sayesinde çevredeki nesnelerin ne kadar uzakta ve iki boyutlu uzayda konumlarının nerede olduğu saptanarak kaçınma veya durma hareketleri yapılmıştır. LIDAR iki boyut uzayda çevresini görebilirken tam olarak konumlandırma yapamadığı için, çevre etkileşimini artırmak

adına kamera da etkin bir rol üstlenmiştir. Bu yüzden kamera ve LIDAR olan sistem daha iyi bir performans göstermiştir (Gatesichapakorn et al., 2019).



MATERYAL METOT

İnsansız Hava Aracının Aerodinamik ve Mekanik Yapısı

İHA'lar güç kullanımı ve hareket kabiliyeti çok önemlidir. Bu sebeple doğrusal olmayan çevre değişkenlerini hesaba katarak bir yapı oluşturmak çok önemlidir. İHA'lar belli kalıplar altında değişkenlik gösterirler. Örneğin bir İHA döner kanat ve sabit kanat olmak üzere ikiye ayrılır diyebiliriz. Şekil 1'de olduğu gibi temelde iki çeşit İHA türü vardır. Çalışmada kullanılan İHA ise döner kanatlı ve dört motorlu İHA'dır.



Şekil 1. Döner ve sabit kanatlı İHA

Döner kanatlı İHA'lar ise motor sayısına göre isimlendirilir ve çok çeşitli sayıda motora sahip olabilirler. Çalışmada kullanılan 4 motorlu olup quadrotor olarak da isimlendirilebilir.



Şekil 2. Çeşitli motora sahip olan İHA türleri

İHA yapımında ihtiyaç duyulan çeşitli malzemeler vardır. Bu malzemeler hem İHA'nın karar ve görme mekanizmasını sağlayan parçalar olup bunun yanında ona uçuşu için enerji kaynağı olan bataryalar vardır. Motorların ve ona bağlı olan pervanelerin seçimi ve uygunluğunun araştırılması önemlidir. İHA'lar kullanım amacına göre dizayn edilir ve ona uygun malzemeler seçilmelidir. Amacın dışında seçilen malzemeler ile istenen sonuçların elde edilmesi mümkün değildir. Bunun yanında parçaların kalitesi ve gücü de başarıya gidilecek yolda dikkate alınması çok gereklidir.




Şekil 3. İHA için kullanılan DJI F450 gövde ve PDB (Power Distributor Board)

Şekil 3'te verilen İHA'yı oluşturan gövdedir. Bu gövde sayesinde İHA'nın dengeli bir uçuş yapması sağlanır. Diğer malzemeler bu gövdenin üzerine yerleştirilir ve motor sayısına göre o kadar kol olması gerekir. 4 kollu gövdelere 8 adet motor yerleştirmek de mümkündür. Bu tarz değişiklikler tamamen yapılacak çalışmanın şartlarına göre ayarlanır. Birbirine merkezi olarak bağlı dört kolu olan bir ana gövdeden ve kolun her bir serbest ucuna takılmış dört DC fırçasız motordan oluşan quadrotor. Quadrotor, her motor şaftına bağlı dört rotordan / pervaneden oluşur. Sabit açılı dört rotor, gövdeyi ve yükü kaldırmak için her bir uçta eşdeğer kuvvet üretmek için sabit bir eğimi temsil eder. Tüm DC fırçasız motorlar, her bir motorun hızını kontrol etmek için elektronik hız kontrol cihazına bağlanır. Güç dağıtım panosuna paralel bağlantı ile birbirine bağlanan dört elektronik hız kontrolörü. Güç kaynağı olarak bir pil kullanılır. Pervanenin dönüşü uzaktan kumanda (RC) ile kontrol edilir (Shah et al., 2014). Çalışmada kullanılan gövde hem aviyonik tasarımda kolaylık sağlamaktadır hem de dört motorlu İHA'lar için oldukça uygundur. İHA gövdesi klasik DJI F450 modeli kullanılmıştır. Tercih edilme nedenlerinden biri de oldukça hafif ve dayanıklı olmasıdır.

Tasarım kurguları, yeni ortaya çıkan ve spekülatif olanları yakın gelecekteki hayallerin şekillendirilmesi ve inşaat ile yansıma alanları sunar. Günümüzde ihtiyaç halinde var olması beklenen fikrin bir tasarım sürecine girmesi gerekir (Morrison et al., 2013). Son 10 yılda, hızla gelişen teknoloji dünyasında ihtiyaçlar doğrultusunda quadcopternere yoğun bir ilgi söz konusudur. Örnek olarak; dönemsel orman izleme ve arama / kurtarma görevleri, yangın söndürme, savaş alanında, hava araştırmaları, fotoğrafçılık gibi alanlarda sıkça yararlanılmaktadır. Genel olarak tasarlanan her quadcopter sistemin inşa edilmesi ve entegre edilmesi için farklı materyallere ihtiyaç duyar. Buradan yola çıkarak üzerinde en çok durulan noktalar İHA'nın uçuş kabiliyeti ve bulunduğu konuma uygun ilerlemeler kaydetmesi ve verilerin aktarılması için kapasitesinin belirlenmesi olmuştur (Sabikan & Nawawi, 2016).


Bu çalışmada, İHA'nın matematiksel modellemesi denge koşullarından optimum seviyede yararlanmak için X- konfigürasyonu şeklinde uygun görülmüştür. Araştırılıp toplanan verilere göre bu yapılandırma şeklinin büyük ölçüde avantajları vardır. Bir X- konfigürasyonunda, kollar dönme ekseninden 45 derecelik bir açıda olduğu için, itme kuvvetleri $r \times \cos \frac{\pi}{4}$ yaklaşık $0.71 \times r$ mesafede uygulanır. Atalet momenti, matematiği yapıldığında aynıdır, bu yüzden fark, dört motorun hepsiyle tork yapabilmektedir. Bu nedenle döndürmek için $\sqrt{2}$ daha fazla kullanılabilir torka sahiptir. Bu, "x" yapılandırmasının diğerlerinden yaklaşık %41 daha fazla dönme ivmesi alabileceği test edilmiştir. Kamera Ark Açıklığı: Bir "x" çerçevenin önünde engel olmadan diğer düzeneklerden daha verimli görüş açıklığı sağlar. Bazı tasarımlarda, kamerayı monte edebilmek için farklı alanlar oluşturmaya çalışır veya hareketli iniş takımı ile bu problemi giderir. Fakat "X" çerçevede böyle bir duruma ihtiyaç yoktur.

Plakaların birbirine montajında titreşim sönümleyici malzemeler kullanılmıştır. Çalışma sırasında motorların oluşturduğu titreşimi veya uçuş esnasında karşılaşılabilecek küçük çaplı darbeleri sönümlemek ya da etkiyi en aza indirmek hedeflenmiştir. Sönümleme işinin temel taşı kauçuktur. Kauçuğun titreşim izolasyonunda neden bu kadar değerli olduğunu örneklemek gerekirse; Kauçuğun önemli avantajları arasında montaj kolaylığı, enerji depolama kapasitesi ve bazı enerji türlerini yön değiştirdiğinde ısıya dönüştürme yeteneği bulunmaktadır. Böylelikle natürel kauçuk, az miktarda histerez oluşturur ve sönümleme ve enerji dağılımını belirli kuvvete maruz kalmış sistemlerde sağlamış olur. Kauçuk titreşimleri şekilde görüldüğü gibi büyük ölçüde sönümlemektedir. Sönümleme işleme çok önemlidir. Çünkü titreme ve darbelerde uçuş kontrol kartı ve mikrobilgisayarda çeşitli sinyal bozuklukları ve elektriksel iletkenlikte problem olmaktadır. Bunun yanında telemetri ve kumanda alıcı-vericisinde sinyal dalgalarında problem yaşanabilmektedir. Bu yüzden titreşim sönümleyici modülleri kullanmakta fayda vardır.



Şekil 4. Kauçuk sönümleyici grafiği


Alt ve üst plakaların birbirine montajları kollar tarafından sağlanmaktadır. Kolların gövdeyle birleştiği noktalar kolların tasarımındaki omuzlarla sağlanmaktadır. Böylece plakalarda var olan yük, kollara eşit şekilde nüfus etmiş olup daha sağlıklı bir yük dağılımı oluşmuş olur. Bu omuzlar alt ve üst plakalara M2, M2.5, M3 vidalarla sabitlenmiştir. İHA da kullanılan bütün malzemelerin (Sensörler, Li-po batarya, ESC, motorlar vb.) ağırlıkları ve geometrileri analiz edilerek kolların ve plakaların montajı ağırlık merkezi de dikkate alınarak uçuş ve görev sırasında dengesizlik oluşturmayacak şekilde yapılmıştır. Bu nedenle X çerçeve kullanılmıştır. Motorlar ağırlık merkezi ortada olacak şekilde yerleştirildi. İHA tasarımlarında ağırlık merkezinin (Center of Gravity - COG) yeri oldukça mühim olup iyi belirlenmelidir. Pitch ve Roll Eksenleri X frame çerçevede çok simetrik olduğu için bu tasarım sayesinde hızlı yön değiştirme ve iyi takla kabiliyetine sahip olacaktır.



Şekil 5. Pitch, Roll, Yaw eksenleri


Cisme etki eden kuvvetlerin ve momentlerin hesaplanması bu cismin etrafındaki havanın hareketinin doğru analizi ile mümkündür. Katı bir cisim üzerinde hava akımından dolayı kuvvetler oluşur. Bu kuvvetler sürüklenme, ağırlık, savurma ve kaldırma kuvvetleridir. Bunlardan kaldırma ve sürüklenme uçuşun en önem arz eden aerodinamik kuvvetleridir. Hesaplamalar hava akışının sürekli olduğu varsayılarak yapılmaktadır. Ağırlık merkezinin konumu incelenen aerodinamik yapıda en önemli özelliklerden biridir. Ağırlık merkezi çeşitli unsurların (Örneğin; piller, sensörler veya araç bilgisayarı) seçilmesiyle motorların ekvatorial düzlemin biraz üstünde veya biraz altında seçilebilen noktadır. Statik denge için Ağırlık merkezinin ekvatorial düzlemin üzerinde olması makul bir durumdur. Ancak stabilite için yeterli bir koşul değildir. Çünkü istenen bu etkiye katkıda bulunan bir ters dönen tork üretir. Ancak torkun tam tersi işaretine, yani ağırlık merkezinin ekvatorial düzlemin altında olması halinde istenmeyen durumlar ortaya çıkar. Merkezin düzlemin üzerinde ya da altında olması her iki

durum için de rüzgâr etkisinin minimuma indirilmesi veya belirli bir irtifada ileri uçuş düzenliliği için geçerlidir. Diğer sorular, öteleme hareketi sırasında motorların neden olduğu gözlemlenen aerodinamik sürüklemeyi baz alır. Analitik ifadeleri, quadrotor stabilitesinde ve gözlenebilirliğinde anahtar rol oynar (Hugo et al., 2007) (Tayebi & McGilvray, 2006) (Guenard, 2007) (Bristeau et al., 2009). İHA yapısı her ne kadar motor, pervane gibi basit mekanik yapıda da olsa statik ve dinamik konular önem arz eder.



Şekil 6. Motorlar ve eksenleri

Temelde bu konuyu açıklayacak olursak: Quadcopterler aşağı ve yukarı hareketini eş zamanlı çalışmaya başlayan, devirleri aynı olan ve ikisi farklı yönlere dönmesi gereken dört pervanenin hareketiyle olur. Aerodinamik itiş gücünün pervaneler üzerinde oluşturduğu etki ile yükselme alçalma hareketleri sağlanır. Tüm motorların net itme gücü 0'a eşit olduğunda, quadcopter aynı zamanda sabit irtifa durumunu da korur. Pervanelerin farklı yönlerde dönmesi bir denge kuvveti ortaya çıkarır. Bu kuvvet İHA'nın kontrol dışındaki yalpa hareketinin önüne geçer. Farklı yönlerden kasıt çaprazlamasına düşünüldüğünde iki tanesi saat yönünün tersine, diğer çaprazda kalan ikisi de saat yönüne dönmesiyle İHA uçuşunu gerçekleştirir. Pervanelerin farklı yönlerde dönmesi bir denge kuvveti ortaya çıkarır. Bu kuvvet İHA'nın kontrol dışındaki yalpa hareketinin önüne geçer. Farklı yönlerden kasıt çaprazlamasına düşünüldüğünde iki tanesi saat yönünün tersine, diğer çaprazda kalan ikisi de saat yönüne dönmesiyle İHA uçuşunu gerçekleştirir.




Şekil 7. Motor dönme eksenleri

Başlangıç olarak döner kanat İHA'nın uçuş sırasında konumunu, hareketini ve pervane dönüş hızları hakkında bilgi alınmasını ve analiz edip veriler toplanmasını sağlayan matematiksel modülün çıkarılmasıyla ilgilenilmiştir. Hesaplamalar esnasında çalışmaları kolaylaştırmak adına İHA'nın gövdesinin simetrik olduğu X- çerçeveye karar verilmiştir.

Bir diğer husus ise gövde ağırlık merkezinin, gövde koordinat sistemi orijini ile kesiştiği kabul edilmiştir. Eğer bu çakışma gerçekleşmemiş ise (ağırlık merkezi-motor düzlemi) ağırlık merkezinden sorumlu tutum denetleyicisi yanlış sonuç alınmasına sebep olur (Huang et al., 2009). Motorların gövdeye etki etmesi ağırlık merkezi ile dönme düzlemi arasındaki uzaklığa bağlıdır. Büyük tasarımlarda ihmal edilebilen açısal oranları küçük tasarımların motorlarına aktarmak için bu tasarımlardaki tekniklerden yararlanılmıştır (Mettler, 2013), (Vissiere et al., 2008). Motora uygulanan aerodinamik etkiler baz alındığında bir motorun etkisi altında kaldığı kuvvetlerden biri de bıçak çırpma (motorların pervaneyi döndürmesi) olarak bilinen harekettir. Pervanenin saat yönünde dönen kısmının hızı serbest akıma göre daha yüksek iken geride kalan kısmı daha düşük etkili bir hava hızı görür. Aynı zamanda her pervane boyunca artmakta olan yüzey alanı başına aerodinamik sonuç kuvveti de toplanarak sonuç elde edilir (Prouty, 1995).


İnsansız Hava Aracının Aviyonik Tasarımı

İHA kurulumu yapabilmek için bütün bağlantı şemalarının çizilmesi ve teorikteki bilgilerin pratiğe dökülmesi gerekmektedir. Bu sebeple tüm çizimler yapılmış olup bu şemalar ışığında birleştirmeler yapılmıştır. Navio 2 uçuş kontrol kartının insansız hava aracına entegrasyonu ve bu senaryoda kullanılan tüm bağlantılar Proteus programı kullanılarak detaylandırılmıştır.



Şekil 8. Navio2 ile Raspberry Pi 4 bağlantısı

Şekil 8’de görüldüğü üzere Navio 2 uçuş kontrol kartı Raspberry Pi 4 ile Raspberry Pi pin girişleri ve Navio2’nin pin girişlerinden birbirine geçmeli şekilde bağlanırlar. Tasarım konusunda birbirleri ile uyumlu yapılmış olan bu iki kart insansız hava aracı hareket kontrolünde, otonom uçuşlarda önemli rol oynarlar. Raspberry Pi 4 içerisine derlenmiş kodlarla Navio2’ye uçuşla ilgili çeşitli komutlar verir. Yine Şekil 8’de Navio2 uçuş kontrol kartına bağlı olan Navio2 GPS Modülü ve 915 MHz telemetri alıcısı bağlantıları da gösterilmiştir. Navio 2’nin kendine özel GPS modülü mevcuttur. Yine bu GPS modülü için özel olarak kart üzerinde “Anten” portu bulunur. GPS özel entegresi de bu porta bağlanır, insansız hava aracının tüm konum bilgilerini yer bilgisayarına iletir. 915MHz telemetri alıcısı ise kart üzerindeki “UART” portuna bağlanır. RC kumandadan alınan bütün komutları Navio2 uçuş kontrol kartına iletir. Navio2 ise gelen bütün komutları kullanıcının istediği gibi hareket etmek için kullanır.




Şekil 9. Li-Po Pil, PDB, ESC, BLDC motor bağlantısı

Şekil 9'daki çizimde Li-Po batarya, Power Distribution Board (PDB), Electronic Speed Control (ESC), brushless DC motor bağlantısı yer almaktadır. Devreyi tamamlamak için konektör Li-Po bataryaya bağlanır. Burada ki önemli nokta bağlantılarda bakır kullanılmasıdır. Bunun nedeni bakırın iletiminin daha fazla olması ve bu yüzden kabloların fazla ısınmasını engellemesindendir. Navio2'nin güç modülü, Navio2 üzerindeki "Power" portuna bağlanır, Navio2 beslemesi bu bağlantıdan yapılır. Li-Po'dan alınan + (pozitif) besleme ise PDB üzerindeki "BAT +" kısmına lehimlenir. Li-Po dan alınan devre doğrudan devam eden – (negatif) kutup ise PDB üzerindeki "BAT –" kısmına lehimlenir. 4 adet olan EMAX 30A ESC'ler ise PDB üzerindeki "ESC" portlarına pozitif kısma kırmızı ESC kablosu, negatif kısma da siyah ESC kablosu gelecek şekilde lehimlenir.

Her bir ESC'ye bir adet BLDC motor bağlanır. İnsansız hava aracının havada kendi ekseninde dönebilmesi için çaprazlı olarak motorların aynı yöne dönmesi gerekir. Motor dönüş yönlerini ise ESC'ler ile BLDC motorlar arasındaki 3 adet (VCC-Sinyal-GND) kabloların


bağlanış şekli belirler. Bu yüzden çaprazlı olan iki motor için yapılacak bağlantı düz, kalan diğer çaprazlı motorların bağlantısı da bu 3 kablodan herhangi ikisini ters bağlamak gerekir.



Şekil 10. Navio 2, Raspberry Pi 4, 2. Raspberry Pi kamera modülü, PPM kodlayıcı ve RC kumanda alıcısı bağlantısı

Şekil 10'da gösterilen bağlantılar ikinci Raspberry Pi 4 ile ilki USB TTL Dönüştürücü ile bağlanırlar. İkinci Raspberry Pi 4 sistemde Pi kamerayı kontrol eder. Raspberry Pi 4 üzerinde kodlardaki pin girişine bağlanır. Pi kamera modülünün ise Raspberry Pi üzerinde kendi girişi vardır. Navio 2 üzerindeki PPM/SB portu, PPM Kodlayıcının ilk piniyle bağlanır. AUX 1,2,3 ve 4 portları ESC'lerin her birinden giden sinyal kablolarıyla bağlanırlar. PPM kodlayıcı ile RC kumanda alıcısı kumanda sinyallerinin şifrlenmesi için PPM kodlayıcının 2. pininden itibaren sırasıyla birbirine bağlanır. Çerçeveyi oluşturabilmek için öncelikle PDB (Güç Dağıtım Kartı) üzerine ESC lehimleri yapılmalıdır. Önce lehim yapılmasının nedeni ise kollar takıldıktan sonra lehimin yapılmasında zorluk yaşanmasındandır. PDB üzerine ESC lehiminin yapılması için

belli bölgeler bulunur. Bu bölgeler 10 adet olup 8'i ESC için diğer ikisi ise batarya bağlantısı içindir. Bölgeler ikili halde olup + ve – şeklinde 1 adet batarya girişi ve 4 adet ESC çıkışı bulunur. Çalışmada kullanılan PDB Şekil 11'de gösterilmiştir.



Şekil 11. Montaj için kullanılan PDB

PDB'ye lehim şu şekilde yapılır; Önce PDB üzerindeki ESC'ler için ayrılmış bölgelerden herhangi birinin + bölgesine havya yardımıyla lehim damlatılır, ardından ESC'nin kırmızı kablosu biraz ısıtılarak lehim dökülen yere yine havya yardımıyla yapıştırılır. Ardından ESC'nin siyah kablosu – bölgeye aynı şekilde anlatıldığı gibi lehimlenir. Ardından kontrol amaçlı lehimin tutup tutmadığı kabloya biraz baskı uygulanır. İlk lehim yapıldıktan sonra kalan 3 ESC de aynı şekilde lehimlenir. Burada dikkat edilmesi gereken hususlar lehimin bölgenin dışına taşmaması ve lehim yapılan kablodan bir tel dahi dışarı çıkmamasıdır. Aksi takdirde kısa devre ve PDB'nin iş göremez hale gelmesi gibi sorunlar ortaya çıkacaktır.

İnsansız Hava Aracında Kullanılan Ekipmanlar ve Kurulum

Raspberry Pi bir mikrobilgisayardır. Yani bilgisayardaki tüm işlevlerini yerine getirebilen kredi kartı boyutunda çok kullanışlı ve işlem gücü yüksek bir karttır. CPU anlamında yeni modelleriyle birlikte gücü daha da artmış olup sunduğu diğer özelliklerle de çok kullanışlı bir yapısı vardır. İşletim sistemi Linux tabanlıdır ve açık kaynaklı kod yazmaya elverişlidir. Çalışmada kullanılan yazılımlar Python dilinde yazıldığı için bu kartı kullanmak çok verimli olmuştur. Bunun yanında Raspberry Pi ile Navio2 birbirine uyumlu olduğun için de uçuş kontrol kartının tam kullanımı sağlanabilmektedir. Raspberry Pi ve Navio2 birlikte çok iyi bir şekilde çalışabildiği için çevre bağlantılarını da bağlamak ve enerji vermek çok kolaydır. Örnek

uçmasını sağlar. Li-po bataryalar hücre sayısına ve mah değerlerine göre çeşitlilik gösterebilir. Çalışmada kullanılan batarya 6000mah olup 3S hücreli bir bataryadır.



Şekil 14. Çalışmada kullanılan Li-Po batarya

İHA'nın ihtiyacı olan itki gücünü motorlar ve motorlara takılan pervaneler sağlamaktadır. Uçuş kontrol kartının denetiminde olan ESC'ler bu motorların dönme hızlarını ayarlayarak bir itki oluşturur. Bu itkinin oluşabilmesi için ise pervaneler gereklidir. ESC'ler motorların dönüm hızlarını, uçuş kontrol kartındaki jiroskop ve IMU gibi özellikler ile kontrol edildikten sonra ayarlama yapar ve bu dengeli uçuşu için gereken dönümü yaptırabilir. Uçuş kontrol kartı tüm hesaplamaları yaptıktan sonra gerekli uçuş modu hangisiyse o moda hizmet edecek şekilde dönümler hesaplayarak ESC'lere gönderir ve bu sayede dönüm sayısı hesaplanmış olur. İHA bu sayede istenen modda da uçuş gerçekleştirebilir.




Şekil 15. SunnySky motor (X2212), pervane (1045) ve ESC

PPM Encoder, kumanda alıcısına bağlanarak bir şifreleme yapar. Yapılan şifrelemeyle sinyallerin karışması önlenmeye çalışılır. Daha sonra kumandadan gelen veriler telemetri modülüyle birlikte bir yer istasyonuna bağlanır. Bu sayede İHA ile yer arasında bir iletişim ağı kurulmuş olur.



Şekil 16. PPM Encoder, Kumanda, Telemetri

Şekil 17’de verilen kamera modülü İHA’nın görmesi sağlanır. Bu kamera modülü Raspberry Pi için üretilmiş olup direkt olarak uyumlu çalışır. İHA bu modül sayesinde bir görme elde eder ve nesne tespiti veya diğer şeyler için kullanılır. Görüntülenen üç boyutlu uzay ise işlenerek veya bilgisayarlı görü ile tespit yapılmasında kullanılır. Bu tespitleri çevrimiçi veya çevrimdışı yapmak da mümkündür. Eğer eş zamanlı bir tespit yapılmak isteniyorsa bu çevrimiçi yapılmalıdır. Eğer görüntüler alınıp daha sonra işlemcide veya ekran kartında yapılacaksa çevrimdışı yapabilmek mümkündür. Bu modül ile hem resim çekilebilir hem de video çekilebilir. Verilecek bu kararla görüntü işleme yöntemi de çeşitlenebilmektedir.



Şekil 17. Raspberry Pi kamera modülü

Çevre etkileşimini artırmak adına LIDAR kullanılmaktadır. LIDAR sayesinde İHA, çevresindeki nesneleri daha iyi algılayıp çevre faaliyetlerini ve nesneleri daha iyi saptayabilmektedir. Çalışmada kullanılan ürün RPLIDAR A1M8’dir (Bkz Şekil 18). Şekil 20’de görülen dönüştürücü ile LIDAR’ı USB girişinden bağlamak mümkündür. Bu sebepten bağlantısı çok basittir. Bu dönüştürücü sayesinde Raspberry Pi’a takmak ve güç vermek çok kolaylaşır.


LIDAR teknolojisi çevre etkileşimi ve için çok önemli bir sensördür. LIDAR sayesinde çevre haritalandırması yapılarak, çevredeki nesneleri algılayıp görüntüleyebilmekteyiz. Çalışmada kullanılan LIDAR iki boyutlu olup nesneleri ve çevre elemanlarını iki boyutlu bir düzlemde görüntüleyebilmektedir. Çevre haritalandırmadaki başarı, uygulamanın doğruluğuna ve bunun güvenilirliğine bağlıdır. Çevredeki nesnelerin algılanmasında kullanılan sensörlerin de

kalitesi büyük önem arz etmektedir. Çalışmada kullanılan LIDAR genel olarak iç mekanların haritalandırmasında kullanılsa da 24 metrelik çapı sayesinde dış ortamların haritalandırılmasında da kullanılabilir (Markom et al., 2015). Çeşitli haritalandırma sonuçlarında gayet iyi sonuç vermekle birlikte, Raspberry Pi ile uyumlu çalışması da bu ürünün tercih edilmesinde büyük bir unsur oluşturmıştır .



Şekil 18. RPLIDAR A1M8 LIDAR modülü

LIDAR bağlantısı yapıldıktan sonra çevreyi 2 boyutlu bir şekilde haritalandırma yapılabilmektedir. Bu sayede İHA'nın girdiği yerleri belli mesafelerde haritalandırabilir. Çalışmada kullanılan LIDAR 24 metre çapa sahip bir menzilde 2 boyutlu haritalandırma yapması mümkündür. Şekil 19'da görüldüğü gibi kapalı alanlarda kullanılabileceği gibi açık alanlarda da kullanılması mümkündür.




Şekil 19. LIDAR'ın haritalandırmasını gösteren bir örnek



Şekil 20. LIDAR Type-C dönüştürücü

Kurulumun tamamı gerçekleştiğinde Şekil 21’de verildiği üzere bağlantı gerçekleştirilmiştir. İHA, temel uçuş mekaniklerini gerçekleştirebilmek için uçuş kontrol kartına ihtiyaç duymaktadır. Eğer uçuş kontrol kartı kullanmazsak jiroskop, pusula, GPS gibi özellikleri kullanmamız mümkün olamaz. Bu sebepten dolayı uçuş kontrol kartlarına ihtiyaç duyarız. Uçuş kontrol kartları, İHA’nın stabil uçmasında, uçuş modlarını kontrol etmede, dengede kalmasında, motorların dönüm sayısını ESC’lere aktarmasında, otonom uçmasında kilit bir rolü vardır. Ancak içerisinde hafif denebilecek olan Emlid Linux işletim sisteminin görsel bir ara yüzü olmayışından dolayı çeşitli programların çalışmasında büyük sıkıntı yaşanmaktadır. Başka bir işletim sisteminde otonom faaliyetler incelenir veya kodlanır, Emlid Linux işletim sisteminde koşturulur. Bu yüzden dolayı anlık görsel görüntülerin kullanılması için ayrı bir sisteme daha ihtiyaç duyulur. Bu sebepten projede iki adet Raspberry Pi kullanılmaktadır. Navio2 takılı Raspberry Pi ile İHA hareketleri kontrol edilirken, Görüntü ve LIDAR görüntüleri ise görsel ara yüz ihtiyacından dolayı Ubuntu işletim sistemi kurulmuş ve ROS kullanan bir başka Raspberry Pi kullanılmıştır. Enerji ihtiyacı yüksek olduğundan dolayı Navio2 üstünden Li-Po bağlanarak enerji ihtiyacı sağlanmıştır.



Şekil 21. İHA'nın kurulum ve devre şeması


Döner kanatlı insansız hava aracının tüm gövde, kol ve mekanizması ağırlıkları hesaplanarak detaylı bir biçimde bulunmak zorundadır. Tasarımlarda bulunan birden çok boşluk kabloların rahat geçişini ve bağlantıların kolay yapılabilmesini sağlaması adına düşünülmüştür. Yine motor hızlarını kontrol etmek için kullanılan ESC'lerinde kollara montajlanırken başka yerlerden etkilenmemesi için sabitlenmiştir. Motor başına düşen yükün hesaplanması için ağırlık çok önemlidir. İHA'nın motoru genellikle planlanan ortalama ağırlığa göre tercih edilir. Aynı zamanda ağırlık arttıkça İHA'nın uçuş süresi kısılacağı için çok ağır olmaması hedeflenir. Ancak belirlenen hedef doğrultusunda tolere edilebilecek seviyede ağırlık eklemesi yapılabilir. Ekleniecek ağırlık göz önünde bulundurulduğunda motor ve ona uygun parçaların da değişmesi uygun olacaktır. Maksimum itki kuvvetinde İHA, dengede kalacak kadar itki kuvvetinin biraz üstüne çıkabilmelidir ki İHA yükselme hareketi gösterebilsin. Bu yüzden ağırlığın ayarlanması ve kullanılacak olan konfigürasyona uygun seçilmiş olmalıdır. Çalışmada kullanılan İHA'nın ağırlık dağılımları Tablo 1'de verilmiştir.

Tablo 1. İHA Tasarımında Kullanılan Parçaların Ağırlıkları

Parça Adı	Ağırlık (gram)	Adet	Toplam Ağırlık (gram)
11.1V 6000mAh 25C Li-Po	456	1	456
Navio Güç Modülü	12	2	24
PDB ve Gövde Tutucu	63	1	63
ESC	24	4	96
X2212 980KV Fırçasız Motor	70	4	280
1045 Pervane	12	4	48
Pi Kamera	10	1	10
Pervane Adaptörü	5	4	20
Raspberry Pi	50	2	100
Navio2	23	2	46
Telemetry	19	1	19
Tallysman GPS	31	1	31
RC Alıcı	25	1	25
PPM Encoder	8	1	8
LIDAR	220	1	220
11.1V 4200mAh 25C Li-Po	372	1	372
İniş Takımı	300	1	300
TOPLAM	1675	32	2097

İnsansız Hava Aracında Kullanılan Yazılımlar

Görüntü işleme ve nesne tespiti yapabilmek için öncelikle Raspberry Pi ile diğer uçuş kontrol kartlarını yönetebilmek ve istediğimiz yazılımsal çalışmaları yapabilmek için kurulum yapılması gerekmektedir. Öncelikle Raspberry Pi'a Navio2 bağlanması gerekmektedir. Bu bağlantı gerçekleştirildikten sonra istenen İHA hareketleri sağlanabilir. Örnek olarak İHA'nın ihtiyaç duyduğu denge, IMU, GPS gibi özellikler Navio2 içinde olan sensörler ve bağlantılar ile yapılabilmesi mümkündür. Yapılacak olan işlemler Navio2 için üretilmiş olan bir işletim sistemi sayesinde gerçekleştirilir. Bu işletim sisteminin temel amacı, yukarıda bahsedilen sensörleri kullanmak ve bazı hareket kabiliyetlerini artırmak içindir.



Şekil 22. Navio ve Raspberry Pi bağlantı şeması

Şekil 22'de de görüldüğü gibi Navio ile bağlantı kurulması için bu bağlantı şeması çerçevesinde bağlantılar yapılmalıdır. Bu bağlantılar yapıldıktan sonra Raspberry Pi ve Navio2'ye yazılım yapabilmek için Raspbian işletim sistemi yüklenmesi gerekmektedir. Raspbian üzerinden ya da daha önceden yazılmış Python projesini Raspberry Pi'da çalıştırılabilir.

```
#alias la='ls -A'
#alias l='ls -CF'

# Alias definitions.
# You may want to put all your additions into a separate file like
# ~/.bash_aliases, instead of adding them here directly.
# See /usr/share/doc/bash-doc/examples in the bash-doc package.

if [ -f ~/.bash_aliases ]; then
    . ~/.bash_aliases
fi

# enable programmable completion features (you don't need to enable
# this, if it's already enabled in /etc/bash.bashrc and /etc/profile
# sources /etc/bash.bashrc).
if ! shopt -oq posix; then
    if [ -f /usr/share/bash-completion/bash_completion ]; then
        . /usr/share/bash-completion/bash_completion
    elif [ -f /etc/bash_completion ]; then
        . /etc/bash_completion
    fi
fi
xhost +
echo Running at boot
sudo python /home/pi/sample.py
```

Şekil 23. Raspbian işletim sisteminde Python projesi çalıştırılması

İşletim sistemi

İki adet Raspberry Pi kullanılacağı için İHA ile alakalı gerekli işlemleri yapabilmek adına Raspbian işletim sistemine entegre olan Emlid Raspbian kurulmuştur. Bunun temel nedeni Navio2 içerisinde bulunan bütün sensörler ve yazılım ihtiyaçları tam olarak karşılanmaktadır. Direkt Navio2 ve Raspberry Pi birlikteliğini güçlendirme adına yapılmış bir işletim sistemidir. Navio Linux, İHA'nın yönetilmesi, otonom hareketlerin tertibi ve sensör ve motorların hareketleri gibi çeşitli konularda yardımcı olur. Ayrıca kullanılacak olan İHA'nın motor sayısını ve cinsinin ne olduğunun ayarlanmasını da sağlar. Bu tarz yaklaşımlar sayesinde İHA daha stabil bir uçuş gerçekleşmesi sağlanacaktır. Tüm bunlara ek olarak yazılmış Python kodlarının koşturulması daha kolay olacaktır.

Navio için kullanılan bu işletim sistemi görsel yönü zayıf olduğundan dolayı işlemler simülasyon ortamlarında veya başka yazılım ortamlarında kodlanıp, bu işletim sistemine yüklenirler. Gerekli düzenlemeler ve optimizasyon işlemleri yapıldıktan sonra bu sisteme yüklenir ve kodlar burada koşturulur. Görsel tarafı zayıf olmasına rağmen hem uyumluluk anlamında çok iyidir hem de hafif bir kullanım sunar. Hafif olmasından dolayı gecikmeler pek yaşanmaz ve tepki süresini artırır. Tercih edilmesinin en temel sebepleri yukarıda anlatıldığı gibi uyumluluk ve sistem kaynaklarını minimal seviyede kullanmasıdır.

```
# # # # # ### #####
## # # # # # # # #
# # # # # # # # #
# # # # # # # # #
# # # ##### # # # #
# ## # # # # # # #
# # # # # # # ### #####

STEP 1:
Choose your vehicle and ArduPilot version using emlidtool
(Please, read carefully all options and select appropriate one for either Navio 2 or Navio+)
- sudo emlidtool ardupilot

STEP 2:
Set your GCS IP
- sudo nano /etc/default/ardupilot
- sudo nano /etc/default/arduplane
- sudo nano /etc/default/ardurover
- sudo nano /etc/default/ardubus

STEP 3:
Reload configuration by issuing these commands
- sudo systemctl daemon-reload

Launch, and enable on boot
- sudo emlidtool ardupilot


IMPORTANT:
To show this message one more time type "sudo emlidtool ardupilot help"

* Documentation: https://docs.emlid.com/
```

Şekil 24. Navio linux işletim sistemi giriş ekranı

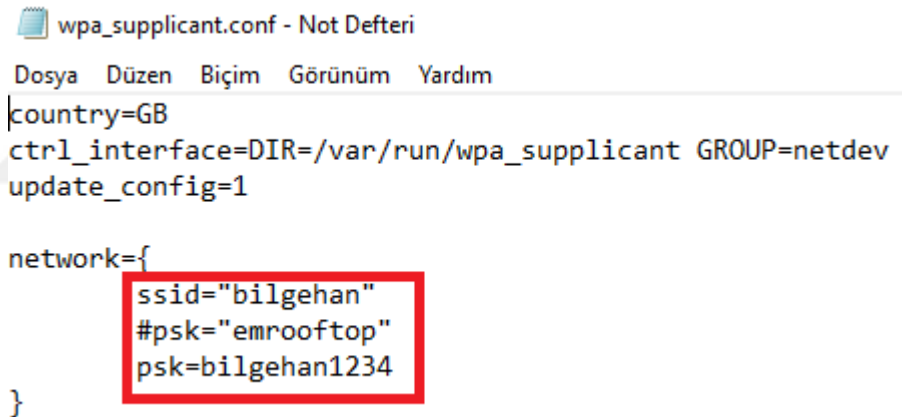
Diğer işletim sistemi LIDAR'ın hareketlerini sağlamak ve iki boyutlu haritalandırma yapabilmek için Linux dağıtımı olan Ubuntu kullanılacaktır. Çünkü ROS kurulumunun en iyi şekilde çalışması için en uygun ortamlardan birisi Linux'tur. ROS içerisinde yüklenen Gazebo ve Rviz simülasyon ortamları kurulacaktır. Rviz ile LIDAR işlemleri yapılacaktır. Rviz simülasyon ortamı, LIDAR'ın haritalandırma yapabilmesi için çok uygun bir simülasyon ortamıdır. Gazebo'da ise İHA'nın otonom uçuşları için gerekli olan Dronekit kütüphanesine entegre şekilde çalışacaktır. Gazebo'da sadece otonom hareketler değil ayrıca İHA'nın içerisinde koşturulacak olan Python kodlarını deneme ve simülasyon oluşturma anlamında çok önemli işlemler yapılabilmektedir.

Emlid Raspbian işletim sistemi Raspberry Pi'a kurulduktan sonra yapılması çok elzem kurulum adımları vardır. Çünkü bu ayarlar cihazdan cihaza değiştiği için bunların belirtilmesi gerekmektedir. Öncelikle Wi-Fi bağlantısı kurulması için Şekil 25'te gösterilen dosyaya kendi bağlı bulunduğumuz ağı tanıtmalıyız. Daha sonra dosya içerisinde bulunan ağ ayarlarını ssid ağ adı ve psk ağ şifresi olmak üzere ayarlanmalıdır.



Şekil 25. Emlid Raspbian için gerekli Wi-Fi konfigürasyon dosyası

Ağ ayarları Şekil 26'daki gibi kendi ağımızın adı ve şifresi olacak şekilde ayarlanmalıdır. Ülke kısmı daha sonra ayarlanabileceği için burada değiştirmeye gerek yoktur. Daha sonra işletim sistemine erişim sağlandıktan sonra gerekli yerleştirme işlemleri yapılabilmektedir. Ülke ve klavye gibi ayarlar uzaktan bağlantı sağlandığı sürece basit işlemlerdir.



Şekil 26. Emlid Raspbian için gerekli ağ ayarları

Gerekli değişiklik yapıldıktan sonra kendi ağımızın IPv4 adresine ulaşılmalı ve bir IP bulucu program vasıtasıyla Raspberry Pi için uzaktan bağlantı kurulumu yapılmış olacaktır. Komut istemcisi üzerinden “ipconfig” komutuyla kendi IPv4 adresimizi Şekil 27’de gösterildiği gibi bulabiliriz.

```
Subnet Mask . . . . . : 255.255.255.0
Default Gateway . . . . . :

Wireless LAN adapter Yerel Ağ Bağlantısı* 9:

Media State . . . . . : Media disconnected
Connection-specific DNS Suffix . :

Wireless LAN adapter Yerel Ağ Bağlantısı* 10:

Media State . . . . . : Media disconnected
Connection-specific DNS Suffix . :

Wireless LAN adapter Wi-Fi:

Connection-specific DNS Suffix . :
Link-local IPv6 Address . . . . . : fe80::881f:a81f:1341:52a2%12
IPv4 Address. . . . . : 172.20.10.9
Subnet Mask . . . . . : 255.255.255.240
Default Gateway . . . . . : 172.20.10.1


Ethernet adapter Bluetooth Ağ Bağlantısı:

Media State . . . . . : Media disconnected
Connection-specific DNS Suffix . :

C:\Users\bilge>
```


Şekil 27. Yerel ağa ait IPv4 adres bilgisi

Bu işlem tamamlandıktan sonra artık ağa bağlı bulunan cihazları “Default Gateway” adresindeki tüm adresleri tarayarak, bağlı cihazlara erişim sağlanabilir. Bunu yapabilmek için Advanced IP Scanner programı kullanılmıştır. Şekil 28’deki gibi yerel ağa bağlanan cihazları bulmak mümkündür. Raspberry Pi ağa bağlandıktan sonra bu şekilde bulunabilir ve bu sayede bilgisayarımızdan uzaktan bağlantı kurabiliriz.




Şekil 28. Advanced IP Scanner kullanılarak yerel ağa bağlanan cihazları tarama

Raspberry Pi'a bağlanabilmek için Bitwise SSH Client programını kullanabiliriz. Uzaktan bağlantı kurabilmek için kullanılan çok basit ve kullanışlı bir uygulamadır. Almış olduğumuz IP bilgisine ek olarak 22. Port üzerinden uzaktan bağlantı sağlayabiliriz. Bunun temel amacı hem Raspberry Pi'a bağlanabiliriz hem de içindeki dosya ve klasörlere ulaşabiliriz. Bu dosyaların içerisine dosya eklemek ve yazılımları koymak çok kolaydır. Bunlara ek olarak aynı zamanda kameradan alınan video ve fotoğrafları kolay bir şekilde almak da kolaylaşır. Bitwise giriş ekranı Şekil 29'da verilmiştir. Yeni terminal konsoluna tıklandığı takdirde artık bağlantımız tamamlanmış olacaktır.




Şekil 29. Bitwise SSH Client ile Raspberry Pi'a bağlanması

Bağlantı gerçekleştikten ve konsol ekranı açıldıktan sonra “sudo emlidtool ardupilot” komut satırı yazılır ve bu komut sayesinde Navio2 içinde gerekli olan ardupilot ayarları yapılabilir. Ardupilot ayarları Şekil 30'da verildiği gibi olmalıdır. Bu ayarlar her İHA konfigürasyonu için değişiklik gösterebilir. Ancak çalışmada kullanılan İHA konfigürasyonu için ayarlar bu şekilde olmalıdır.



Şekil 30. Ardupilot ayarlarının yapılması

Son olarak İHA ile yer istasyonu iletişimi sağlamak için telemetri ayarlarının doğru olması gerekmektedir. Bu amaçla “sudo vi /etc/default/arducopter” komutu girilerek telemetri ayarlarının bulunduğu yere gelinir. Burada varsayılan ayar olarak TELEM2, yorum satırından çıkarılır ve bu sayede telemetri iletişimi açılmış olur. Daha sonra bu telemetri sayesinde iletişim sağlanabilir bir hale gelir.



Şekil 31. Arducopter için telemetri ayarları

Yer istasyonu yazılımı

Yer istasyonu yazılımları sayesinde İHA ile yer arasında bağlantı yapmak mümkündür. İHA ile yer istasyonu arasındaki bağlantı telemetri modülleriyle yapılmaktadır. Telemetrinin anteni Navio2'nin UART girişinden bağlanır ve telemetrinin yer istasyonuna takılacak olan kısmı USB portuna takılarak iletişim köprüsü oluşturulur. Yer istasyonu olarak masa üstü bilgisayar veya diz üstü bilgisayarın yanında Raspberry Pi gibi mikrobilgisayarlar da kullanılması mümkündür. Çünkü USB portundan iletişimi sağlamak mümkündür. Bu da yer istasyonu bağlantısı kolaylaştırır. Çalışmada diz üstü bilgisayar tercih edilmiştir. Çünkü taşınabilir olması ve İHA'nın yer değiştirmesinden dolayı taşınabilir bir yer istasyonu tercih edilmelidir. Daha güçlü bağlantılar sağlanırsa yerleşik bir yer istasyonu da kullanmak mümkündür.

İHA'ların uçuş parametreleri ve çevre bilgilerinin alınmasında gerçek zamanlı bir iletişim sağlamak mümkündür. Bu ihtiyacı telemetri modülleriyle sağlamak hem ekonomik hem de ucuzdur. Anlık takibin kolaylaşması ve verilerin dinlenmesi için ara yüz yazılımları kullanmak kolaylık sağlar. Mission Planner programı bu görevleri yerine getirebilmek için biçilmiş kaftandır (HrISToV et al., 2016).



Şekil 32. Mission Planner giriş ekranı

Mission Planner sayesinde yer istasyonu ve İHA arasındaki iletişimin yanı sıra İHA ile alakalı konfigürasyonlar da bu yazılım sayesinde yapılabilmektedir. Mission Planner İHA ile

alakalı yön, pusula, hız, GPS konumu gibi birçok anlık bilgisini verebilmektedir. Bu açılardan kullanımının pratik olması ve anlık raporladığı veriler sayesinde çokça tercih edilmektedir.

ROS

Gerçek donanımları test etmek ve hataları giderebilmek hem çok zahmetli hem de zaman anlamında çok sarfiyat gerektiren bir iştir. Bunun yanında robotlara bağlı olan donanımlar çok maliyetli olduğu için gerçek hayatta test edilmesi çok riskli olabilir. Özellikle ilk çalıştırmalarda veya İHA için ilk uçurmalarda beklenmedik olaylarla karşılaşılması muhtemeldir. Bunların önüne geçebilmek için üç boyutlu simülasyon ortamlarında test edilmesi ve daha sonra uçuşa çıkılması çok önemlidir. Bu bağlamda açık kaynaklı ve ücretsiz olan ROS kullanılması, maliyet kayıplarının önüne geçilmesi için gereklidir. Açık kaynaklı ve olmasından dolayı, robot ile iletişimi sağlamak çok kolaydır. Python gibi güçlü açık kaynaklı dillerin de gelişmesinden dolayı ROS çok kilit bir konuma gelmiştir (Mendonça et al., 2013).


Çalışmada ROS kurulumu çok önemli olduğu için detaylı bir anlatım ile gösterilmesi gerekmektedir. Çünkü farklı kurulumlar sonucunda istenen verim alınamayabilir. ROS kurulumu sonrasında içinde gelen bazı simülasyon programları vardır. Bu programlardan Gazebo, Dronekit ile uyumlu çalışıp güzel bir simülasyon ortamı sağlamaktadır. Bu sayede İHA'nın otonom uçuşları burada programlanıp simüle edilebilirler. Rviz simülasyon ortamında ise LIDAR hareketleri ve çevre haritalandırma işlemleri yapılabilir.

3.4.3.1. Gazebo

Gazebo, 2002 yılında South California University'de geliştirilmiştir. Geliştirilme amacı, dış ortamda ve çok çeşitli koşullar altında simülasyon ortamı oluşturmaktır. Yapılan simülasyonda, simüle edilecek olan aracın yüksek kaliteli ve gerçekle yakın sonuçlar bulunması istenmiştir. Prototip geliştirme faaliyetlerinde sıkça kullanılan Açık Dinamik Motoru (Open Dynamics Engine – ODE) sayesinde çok iyi sonuçlar vermektedir. Fizik olarak güzel çalışan ve gerçek hayatla kıyasla yakın sonuçlar veren bir fizik motorudur. Bunlara ek olarak açık kaynaklı diğer programlarla entegre olması gayet kolay ve kullanışlıdır (Rivera et al., 2019).

Çalışmada, Gazebo üzerinden temel otonom komutları oluşturulmaya çalışılmış ve denenmiştir. İHA'nın maliyetli oluşu ve kimi zaman yüksek irtifalarda uçmasından dolayı her zaman bir düşme riski mevcuttur. Bu nedenle simülasyon ortamlarında denenmesi daha sonra uçurulması gerekmektedir. Bunun yanında kırım yaşamış bir İHA, görünürde hasarlı olmasa bile düşme kaynaklı bozulmalar veya sinyallerde bir dağılma görülmesi muhtemeldir. GPS anteninin ve telemetrinin sinyallerinde oluşacak bir bozukluk iletişimi koparabilir ve bu nedenle

istenmeye durumlar yaşanabilmektedir. Gazebo içerisinde DroneKit için oluşturulmuş bir Iris dünyası vardır. Burada temel hareketleri simüle etmek mümkündür.



Şekil 33. Gazebo Iris Dünyası giriş ekranı

3.4.3.2. Rviz

Bilgisayar grafiklerinde ve hesaplamalı bilimlerde görüntüyü temsil etmek adına görselleştirme çok önemlidir. Bu sayede görselleştirilmiş görüntüler üzerinden çıkarım yapmak ve amaç doğrultusunda ne gibi değişikliklerin olduğunu görmemiz mümkündür. Görselleştirme sistemlerinde veri akışını göstermek için kullanılan uygulamalar esnek şekilde çalışmamaktadır. Bu sorunu çözmek için girdi bilgisi veri yapılarından bağımsız olan yeni bir görselleştirme aracı olan Rviz ortaya konulmuştur. Soyutlanmış bilgilere yönelik ara yüz Rviz ile çok daha kolaydır. Herhangi bir bilimsel veriyi görselleştirmek ve bir uygulamanın veri akış modelinin çıkarılması son derece kolaydır. Mesafe alan bilgisi, haritalandırma işleri gibi şeylerin görselleştirilmesi mümkündür (Kam et al., 2015).

Çalışmada LIDAR görüntülerinin kullanılabilmesi için Rviz kullanılmıştır. Bu sayede dış mekanların haritalandırması kolay bir şekilde görselleştirebilecek ve çevre etkileşimi adına kolaylık sunacaktır. Bir yandan nesnelerin tespiti kameradan yapılırken diğer yandan çevrenin haritalandırması yapılması mümkün olacaktır. Çevre nesneleri haritalanmış görselde görülebilir bir hale gelirken bir dahaki uçuşlarda istenen nesne İHA'nın orayı gezmesiyle bulunabilir. Bu da gözden kaçan veya kamera kayıtlarına girmeyen nesnelerin tekrar algılanabilmesinde fayda sağlayacaktır.

Derin Öğrenme

Derin öğrenme, yapay sinir ağları gibi sistemler insan beynini ve çalışmasını taklit ederek bir sistem oluşturulmaya çalışılmıştır. Bu sistemi matematiksel bir modele oturtmak ve bunun üzerinde çalışmalar yapmak için insan beynini ve sinir iletimini sağlayan nöronlardan ilham alınmıştır. Genel olarak nöronların elektriksel iletimini baz alarak giriş, gizli ve çıkış katmanları oluşturulup bir matematiksel model ortaya konulmuştur. Çok çeşitli sınıflara ayrılan model günümüzde hala kullanılmaktadır.


Derin öğrenme, özellik çıkarma ve dönüşüm gibi işlemleri giriş katmanından gelen bilgileri daha sonra gizli katmana iletirler. Bu iletim sırasında birbirlerine ardışık şekilde olarak sağlanır. Yani bir nöron hemen önündeki nörona iletir o da önündeki nörona iletir. Bu sayede giriş katmanından verilen bir bilgi tüm ağı dolaşarak çıkış katmanına iletilir. Çıkış katmanında bize istenen sonucun verilmesi beklenir. Örnek olarak bir araba nesnesi tespit edilmek isteniyorsa giriş katmanında bir arabaya ait; tekerlek sayısı, kapıları, rengi, şekli, plakası gibi öznitelikler verilmiş olur ve bir görüntü üzerinden bu öznitelikleri tarayarak çıkış katmanında o nesnenin bir araba olup olmadığı bilgisini çıktı olarak verir.

Son yıllarda derin öğrenme algoritmalarının, makine öğrenmesi algoritmalarından daha iyi performans gösterdiği ve bilgisayarlı görü için çok önemli bir duruma geldiği görülmektedir. Derin öğrenme, çok işlem katmanlarını hesaplamada beynin çok modlu bilgileri nasıl anladığını ve yorumladığını taklit ederek çoklu soyutlama seviyelerinde nasıl karar verdiğini modelleştirir ve bir karar verir. Derin öğrenme, sinir ağlarını hiyerarşik olasılık modellerini ve çeşitli denetimli ve denimsiz öğrenme algoritmalarını içeren zengin bir yöntem ailesidir. Bunlara ek olarak çok çeşitli alanlarda kullanılabilir (Voulodimos et al., 2018).

Derin öğrenmenin; nesne algılama, görüntü ve doğal dil işleme gibi birçok alanda başarılı olduğu bilinmektedir. Bununla birlikte grafik verilerine derin öğrenme yöntemleri uygulamak grafik temelli verilerde çok önemlidir. Derin öğrenme son yıllarda, teknolojinin de gelişmesiyle birlikte uygulamalarda kullanılması gitgide arttı. Sistematik olarak çalışan alt yöntemleri sayesinde derinlemesine farklı alanlarda çalışabilmesi mümkün hale geldi. Derin öğrenme çalışmaları nesnelerin algılanmasında önemli bir hale gelirken bu konu hakkında çalışan araştırmacılara da yeni alanlar sunmaya devam etmektedir (Zhang et al., 2020).


Günümüzde, canlıların davranışlarını inceleyip matematiksel bir model haline getirerek çeşitli teknolojiler ortaya koyulmuştur. Bunlara benzer şekilde insan beyninin incelenip matematiksel bir model olarak ortaya koyulmasıyla da derin öğrenme ve bunun alt dalı olarak

yapay sinir ağıları geliştirilmiştir. Temel olarak insan beyni alınmış ve öğrenme yöntemleri, yaptığı mantıksal çıkarımlar örnek alınarak bir model oluşturulmuştur.



Şekil 34. Genel yapay sinir ağıları modeli

Bu model bir nesnenin, sesin, örüntünün gibi birçok alanda kullanılabilir haldedir. Ancak çok daha çeşitli verilerin kullanılmasında iyi performans vermediği için çok katmanlı yapay sinir ağıları kullanılmaya başlanmıştır. Çünkü veri sayısı arttıkça ve etiketlenmesi gereken verinin sayısı arttıkça yüksek performans vermesi çok zordur.




Şekil 35. Çok katmanlı ve gizli katmanlı bir yapay sinir ağı modeli

Çok katmanlı modeller veri setindeki bilgilerin ve etiketlerin artmasıyla daha kolay bir kullanım sunmanın yanı sıra aynı zamanda modelin karar mekanizmasıyla doğrudan ilişkilidir. Veri sayısının artması ve etiketlenmiş verilerin çoğalmasıyla birlikte çok katmanlı ve çok gizli katmanlı bir yapay sinir ağı oluşturmak çok önemlidir. Bu sayede daha yüksek performanslı sonuçlar almak olasıdır.

Evrişimli Sinir Ağları

Evrişimli sinir ağları, görüntülerin analizini yapmamızı sağlayan, görüntüdeki çeşitli nesneleri veya objeleri birbirinden ayırtmamızı sağlayan bir derin öğrenme algoritmasıdır. İleri yönlü bir sinir ağıdır ve canlıların görme duyusundan esinlenerek ortaya çıkmıştır. Evrişimli sinir ağı, kendi uyarılmasından ve yaptığı uyarımların oluştuğu bir sistem olarak düşünülebilir. Basitçe ifade etmek gerekirse matematik ve fizik uygulamalarını karmaşık bir yapıdan çıkarıp basitleştirmek için matematiksel bir modelle ifade edilmesidir.

Evrişimli sinir ağları, birden fazla evrişim katmanından alt örneklem katmanından ve standart çok katmanlı bir sinir ağından oluşabilir. Evrişimli sinir ağlarının avantajı daha az girdi ile ve daha az kullanılan parametreyle daha iyi şekilde eğitilebilirler. Örnek olarak, girdi katmanında $K \times L \times M$ boyutunda bir resim düşünelim. Burada K ve L sırasıyla görüntünün yüksekliği ve genişliğidir, M ise kanalların sayısıdır. Evrişim katmanı ise $A \times B \times C$ boyutlarında n adet filtreden oluşur. Filtre için resim boyutundan daha küçük olan A ve B, kanal sayısı olarak da M seçilir. Bu filtrelerle her biri $K-A+1 \times L-B+1$ boyutunda haritalar üretilir. Sonrasında maksimum veya ortalama havuzlama yapılır.



Şekil 36. Havuzlama işlemi

Yapılan işlemlerin sonucunda artık model bir karar verme mekanizmasına dönüşecektir. Verilen girdiler gizli katmanlarda ilgili özniteliklere karşılık veren nesnenin sonucunu çıkış katmanında verecektir. Bu sayede görüntüler üzerinde nesnelerin algılanması sağlanacaktır.

Derin öğrenme yaygın olarak ve nesne tanıma, konuşma algılama gibi birçok alanda kullanılan ve bilgisayarlı görme, görüntü işleme gibi alanlarda önemi yüksek bir yöntemdir. Her problemin çözümünde kullanılamayan ve bazı görüntü verilerinde istenen sonuçları vermeyen bir yöntem olduğu için evrişimli sinir ağlarını kullanmak bazı sorunların çözümünde önemlidir. Evrişimli sinir ağları kurulan modelde derinliği arttıkça doğruluğa ulaşma ihtimali de artmaktadır (Zhou & analysis, 2020). Son zamanlarda derin öğrenmedeki evrişimli sinir ağları mimarileri nokta bulutlarını kullanmada yeteneği yüksektir. Üç boyutlu nesneleri tanımda evrişimli sinir ağları son derece iyi sonuçlar vermektedir. Kurulan model eğer iyi şekilde çalışıyorsa yüksek sonuçlu algılama yapılması son derece normaldir. Bu sebepten kurulacak modelin, istenen sonuca uygunluğu doğru bir şekilde analiz edilmelidir (Hua et al., 2018).

Evrişimli sinir ağlarında model oluştururken; evrişim, aktivasyon, havuzlama, tam bağlantı ve softmax olmak üzere beş temel katman mevcuttur. Evrişim katmanı görüntülerden belirli öznitelikler çıkarmasını sağlar. Görüntüye ait şekilsel parametreleri, kenar, köşe, lekelenme gibi niteliklerin filtrelenmesi sağlanır. Aktivasyon katmanında verilerin matematiksel bir model üzerinde uygunluğu belirlenir. Havuzlama katmanında giriş verilerinden gelen bu özelliklerin uzamsal boyutunu indirgeyerek parametre sayısının azaltılmasını sağlar. Bu sayede o nesneye ait tanıtıcı parametrelerin daha net bir şekilde ayrılmasını sağlar. Softmax katmanında ise sonucu verebilecek tahminleri istatistiksel bir biçimde çıktı üretmesini sağlar. Bu sayede çıkışta ortaya çıkacak nesnenin ne olduğunu yüzdesel bir ifadeyle doğrulanmış olur. Evrişimli sinir ağları matematiksel modeli Tablo 2’de verilmiştir.




Tablo 2. Katmanların matematiksel modelleri

Katman	Formül
Evrişim Katmanı	$g_j^l = x_i^{l-1}(s, t) * w_{ij}^l = \sum_{\sigma=-n_1}^{n_1} \sum_{v=-n_2}^{n_2} x_i^{l-1}(s - \sigma, t - v) w_{ij}^l(\sigma, v) \quad (1)$
Aktivasyon Katmanı(ReLU)	$x_j^l = \max\left(0, \sum_{i \in M_j} g_j^l + b_j^l\right) \quad (2)$
Havuzlama Katmanı	$x_j^{l+1} = f_p(\beta_j^{l+1}(x_j^l) + b_j^{l+1}) \quad (3)$
Tam Bağlantı Katmanı	$x^{L-1} = f_c(\beta^{L-1} x^{L-2} + b^{L-1}) \quad (4)$

$$z_d = \frac{e^{0_d}}{\sum_{c=1}^C e^{0_c}} \rightarrow \frac{e^{x_d^{L-1}}}{\sum_{c=1}^C e^{x_c^{L-1}}} \quad (5)$$

Aktivasyon fonksiyonları, evrişimli sinir ağlarında bir giriş verisini bir sonraki katmana giriş verisi olarak aktarılması için kullanılır. Girdilerin çıkışlarını bir araya getirmek için kullanılırlar. Girdilerin, çıktıların toplamını ve buna karşılık gelen ağırlıkları hesaplamada yardımcı olurlar. Yani kısaca girdiden gelen verileri bir sonraki katmana yollarlar ve buradaki katmanlardan diğerine ulaştırırken de gene aktivasyon işlemleri yapılır. Bunların sonucu olarak son katman olan çıkış katmanına göre bu işlemler yapılır. Yaygın olarak kullanılan aktivasyon fonksiyonları Tablo 3’de (Amidi & Amidi, 2018) verilmiştir.

Tablo 3. Yaygın olarak kullanılan aktivasyon fonksiyonları

Sigmoid	Tanh	ReLU
$g(z) = \frac{1}{1 + e^{-z}} \quad (6)$	$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (7)$	$g(z) = \max(0, z) \quad (8)$
		

Bulut Tabanlı Derin Öğrenme Yöntemleri Kullanılarak Gerçek Zamanlı Nesne Algılama


Nesne algılama, bir görüntü üzerinde (fotoğraf, video, canlı yayın gibi) çeşitli nesnelerin veya objelerin algılanması işlemidir. Gerçek zamanlı nesne algılama ciddi bir işlemci gücü istemektedir. Yerel veya sabit cihazlarda bu yüksek işlemci gücü sağlanabilirken sabit olmayan cihazlarda böyle bir gücü sağlamak hem maliyetli hem de zordur. Bu sebepten ötürü İHA gibi hareket edebilen ve uzaktan bağlantı sağlayabilecek cihazlarda işlemci gücü büyük bir problemdir. İşlemci gücü hem yeterli olmayabilir hem de maliyetli bir durum ortaya çıkabilmektedir. Yukarıda bahsedilen durumlardan dolayı hem ucuz hem daha efektif olan yeni nesil bulut hizmetleri kullanılabilir. Çalışmada Google Colaboratory üzerinden bulut tabanlı derin öğrenme yöntemleri kullanılarak gerçek zamanlı nesne algılama yapılmıştır. Bu sayede hareketli olan İHA hem düşük maliyetli bir hale gelmiştir hem de çok güçlü GPU kullanmamıza olanak tanımaktadır.

Kullanılan veri seti

Veri setleri görüntülerin tespit edilmesinde çok önemlidir. Çünkü veri setlerinin etiketlenmiş olması bulunacak olan nesnelerin algılanmasın yeri çok büyüktür. Bu sebepten veri setlerinin içeriğindeki görüntüler etiketli ve çözünürlüğüne bağlı olarak değişkenlik gösterirler. Çalışmada kendi oluşturduğumuz veri setlerinin yanında temel olarak aldığımız COCO veri seti kullanılmaktadır (Lin et al., 2014). COCO veri setinde 91 adet objenin algılanması sağlanmaktadır. Bunun yanında 329 bin adet görüntü içerisinde 2.5 milyon adet etiketlenmiş nesne içermektedir. Bu veri seti baz alınarak insan, köpek, bardak, telefon gibi öğelerin yanı sıra kendi eklediğimiz nesneler de mevcuttur.

Çalışmada İHA ile görüntüler alınıp buluta kaydedilir. Daha sonra bu kaydedilmiş veriler etiketlenerek veri seti genişletilebilir. Bu sayede sürekli şekilde genişleyen bir veri seti oluşturmak mümkündür. Yıllar öncesinde etiketlenmiş veri bulmak zorken artık Google, Microsoft, Facebook gibi şirketlerin bizlere sunduğu çok büyük etiketlenmiş veri setleri bulmak daha kolaydır. Çalışmada veriler toplanarak bu veri havuzunun sürekli genişletilmesi ve gerekli olan altyapıyı sağlamak mümkün olacaktır.

Çalışmadaki amaçlardan biri de veri setinin genişletilmesi olduğu için bulabildiğimiz kadar fazla nesne bulup, eğitmemiz gerekmektedir. Bulut tabanlı gerçek zamanlı nesne tespiti yaparken bir nesnenin başarı oranı eğitilebilmiş veri setiyle doğru orantılıdır. Bir doyuma gelene kadar eğitilen model yeteri kadar başarı oranı veriyorsa, artık o model için yeterli veri toplanmış demektir. Veri seti oluştururken fazla veri toplamak ve sürekli bir şekilde genişletmek çok önemlidir. Veri setleri oluşturulurken tamamen açık kaynaklı ve içerisinde etiketli nesnelerin olduğu Open Images adlı siteden indirilebilir (Images, 2021). Eğer tespiti istenen nesnenin etiketli hali yoksa çekilen nesnelerin veya açık erişimi olan resimlerin elle etiketlenmesi sağlanabilir. Open Images'ten indirilen veri setleri etiketlenmiş olarak temin edilir. Daha sonra indirilen bu veri setlerini Google Colaboratory üzerinden eğitim için kullanabilir. Eğer tespit edeceğimiz nesneler bu veri setleri içine dahil değilse elle etiketlenmesi gerekmektedir.




Şekil 37. Eğitim için kullanılan veri setinden örnek görüntüler

Çalışmada İHA ile görüntüler alınıp buluta kaydedilir. Daha sonra bu kaydedilmiş veriler etiketlenerek veri seti genişletilebilir. Bu sayede sürekli şekilde genişleyen bir veri seti oluşturmak mümkündür. Çalışmada, veriler toplanarak bu veri havuzunun sürekli genişletilmesi ve gerekli olan altyapıyı sağlamak mümkün olacaktır.

Kullanılan CNN model

Çalışmada bulut tabanlı derin öğrenme yöntemleri kullanılarak gerçek zamanlı nesne algılama yapılmıştır. Önerilen yöntemde yukarıda bahsedilen veri setinin yanında tarafımızca oluşturulan veri setiyle de genişletilmiştir. Eğitimler her nesne için 1000 adet görüntü üzerinden eğitilmiştir. Buna ek olarak düzgün sonuçların alınması için 100 adet görüntü verisi ile bile çok iyi sonuçların alındığı görülmektedir.



Şekil 38. Çalışmada kullanılan modelin mimarisi


Çalışmada Tensorflow, Keras ve OpenCV kütüphaneleri kullanılmıştır. Tensorflow kütüphanesi, Google tarafından geliştirilen GPU ve CPU'da tensor işlemleri gerçekleştirebilmesi için kullanılan çok önemli bir kütüphanedir. CUDA mimarisine uygun ekran kartlarında çalışabilirler ve CPU'lara göre çok yüksek işlem kapasitelerine ulaşabilmektedirler. Keras, derin öğrenme modelini tanımlamak ve eğitmek için uygun bir yol sağlayan derin öğrenme kütüphanesidir. OpenCV gerçek zamanlı bilgisayar görüşü uygulamalarında kullanılan açık kaynaklı bir kütüphanedir.

Görüntü verileri modele girdikten sonra 3x3'lük filtreleme uygulanmaktadır. Her evrişim katmanları arasında havuzlama işlemi yapılmıştır. Havuzlama işlemi 3x3 boyutunda yapılmıştır ve ortalama havuzlama tercih edilmiştir. Her havuzlama işleminin ardından çözünürlük değeri yarıya düşürülerek diğer katmana aktarılmıştır. Havuzlama işlemi uygulanırken Dropout işlemi uygulanır. Dropout kullanılma amacı, çok fazla nöron olduğu için belli bir eşik değeri altında kalan değerlerin modelden atılmasıdır. Dropout değeri 0.3 olarak alınmış ve bu değerin altında kalan bağlantılar modelden atılır.

Eğitilen modeller “.weights” adı verilen ağırlıkların tutulduğu bir dosyada tutulur. Bu dosya sayesinde eğitilmiş modeller tespit işlemi için kullanıldığında, bu ağırlık dosyaları sayesinde algılama yapılabilecektir. Model eğitiminde veri setleri, %80 eğitim ve %20 test olacak şekilde ayrılmıştır. Eğitim işlemi Colaboratory tarafından sağlanan, Tesla T4 16 GB GDDR6 256 bit GPU üzerinde yapılmıştır.

Veri setini büyütmek için nesne eklenmesi


Veri setini büyütmek için etiketli ve etiketsiz verilerin toplanması gerekmektedir. Toplanan veriler etiketli değilse etiketleme işlemi yapılmaz ve daha sonra etiketlenmiş veriler üstünden işlem yapılmalıdır. Etiketli veri setini eğitmek için test ve eğitim grupları birbirinden ayrılması gerekmektedir. Eğitim grubu %80 ve test grubu %20 olmak üzere test ve eğitim gruplarımızı ayırırız. Daha sonra kullanmış olduğumuz CNN model ile verilerimizi eğitmeye başlarız.



Şekil 39. Önerilen bulut tabanlı büyük veri

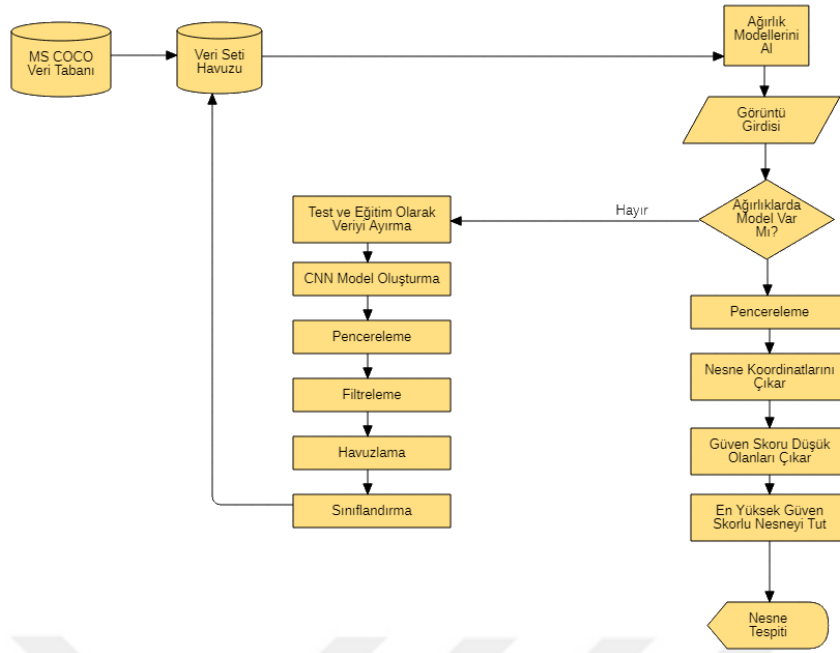
Görüntü ve video üzerinde nesne tespiti

Çalışmada asıl amaç gerçek zamanlı bir nesne tespiti olmasının yanı sıra görüntülerdeki nesnelerin tespit edilmesi de önemlidir. Çünkü İHA ile resimler toplanırken, resim içerisindeki nesnelerin toplanması da önemli bir hale gelmiş olacaktır. Fotoğrafta bulunan resimlerin tespit edilmesi Şekil 37’de gösterilmiştir. Aynı şekilde video çekimi yapılabilir ve videolar üzerindeki görüntüler de aynı şekilde etiketlenebilir. Bu sayede veri seti sürekli bir şekilde genişlemeye devam edebilir.




Şekil 40. Resim üzerinden nesne algılama

MS COCO veri tabanından alınan nesneler ve nesnelerin ağırlıkları oluşturulan veri seti havuzuna alınır. Bunun temel nedeni bu veri tabanında önceden eğitilmiş nesnelerin olmasıdır. Bu sebepten bu nesneleri tekrar eğitip kullanmaktansa zaten optimize edilmiş ve varılacak en yüksek sonuçlar bulunmuştur. Burada amaç en yüksek sonuçla birlikte görüntüde akıcılık da sağlanmalıdır. Çünkü gerçek zamanlı nesne tespiti yaparken görüntü akıcı olmalıdır ki kamera açısında girecek olan nesneler daha ne ve anlık bildirilebilsin. Bu amaçla veri tabanından alınan bilgiler tarafımızca oluşturulan veri tabanına aktarılır. Bu veri tabanında hem etiketli resimler hem de etiketsiz resimler depolanır. Etiketsiz resimler daha sonra etiketlenmek üzere kaydedilir. Etiketli resimlerle de kullanılan CNN model ile eğitim yapıp ağırlık dosyaları oluşturulur. Bu ağırlık dosyaları sayesinde daha sonra istenen ve amaca özel nesne tespiti yapılabilir.



Şekil 41. Görüntü ve video üzerinde nesne tespitin akış diyagramı ile gösterimi



Şekil 42. Görüntü ve video üzerinde nesne tespitin kaba kodu

Bulut tabanlı gerçek zamanlı nesne tespiti

Çalışmada Google Colaboratory üzerinden bulut tabanlı derin öğrenme yöntemleri kullanılarak gerçek zamanlı nesne algılama yapılmıştır. Bulut sistemleri kullanılarak, Raspberry Pi'nin yetersiz işlemci gücü dezavantajından kurtulup, Google Colaboratory'nin sunmuş olduğu yüksek işlem güçlü GPU'sunu kullanmamıza olanak sağlanmıştır. Bu sayede işlemlerimiz çok daha hızlı gerçekleşmektedir. Aynı zamanda yüksek FPS alabilmekteyiz ve görüntüler bu sayede daha akıcı hale gelmektedirler.

ARAŞTIRMA BULGULARI VE TARTIŞMA

Sistem Performans Özellikleri

Gövde ve kolların toplam ağırlığı 396 gramdır. Sistem üzerindeki tüm entegrelerle birlikte tasarlanan aracın toplam ağırlığı 2097 gram olarak ölçülmüştür. Yapılan insansız hava aracının uçuş süresi ise şu şekilde hesaplanır: (11.1V 6000mAh Profuse Batarya, Sunnysky 980kv DC motor) İlk aşama olarak pil kapasitesi (A) * 60 dk şeklinde pilden alınacak maksimum akım miktarı hesaplanır. İkinci aşamada Li-Po piller hiçbir zaman sonuna kadar kullanılamadığından dolayı verimi pilden alınacak maksimum akım miktarının %80'i üzerinden hesaplanır.

$$6000mAh = 6A \quad 6 * 60 = 360A/dk \quad (9)$$

$$360A/dk * 0.8 = 288A/dk \quad (10)$$

9. ve 10. Formüllerdeki gibi hesaplanarak, birim dakikada harcanabilecek net akım miktarı bulunur. Daha sonra;

$$2097gr / 4 = 524.25gr \quad (11)$$

gram olarak motor başına düşen itki kuvveti bulunur. Burada ağırlığı dört motora bölüyoruz ve motor başına düşen ağırlığı hesaplıyoruz. Daha sonra alınan motorların el kitabına bakılarak 524.25gr gram itkide motor başına 6A akım çekileceği görülür.

$$6 * 4 = 24A \quad (12)$$

Son aşama olarak elde edilen bilgilerle birim dakikada harcanabilecek net akım miktarını motorların çekeceği toplam akıma bölerek uçuş süresi hesaplanır.

$$(288A/dk)/24 = 12 \text{ dakika} \quad (13)$$

olarak toplam uçuş süresi elde edilir.

Tasarımın Boyutsal Parametreleri

Hesaplamalar sonucu doldurulan ağırlık denge tablosundan görüldüğü üzere ağırlık merkezine göre bir dengesizlik oluşur. Bu dengesizliği gidermek adına jiroskop kullanılmıştır. Böylece kullanılan jiroskop ESC'lere giden akımı kontrol ederek dengeli bir uçuş sağlamış olur. Kollar, motorlar, ESC'ler, pervaneler ve pervane adaptörleri çerçevenin X oluşundan kaynaklı

koordinat sisteminde simetrik olduğundan denge tablosuna etkisi olmaz. Çalışılan projede, döner kanatlı İHA'nın boyutlandırılması; kullanılacak konfigürasyondaki bileşenlerin en, boy, genişlik ölçüleri dikkate alınarak yapılmıştır. İHA'nın boyutları belirlenirken ilk olarak aracın üzerindeki malzemelerin montesinin yapılacağı parçanın boyutları hesaplanmıştır. Ölçüleri alınan malzemeler göz önünde bulundurularak plakalara; taşma yapmayacak ve bileşenlerin montajlarını kolaylaştıracak şekilde uygun en ve boy uzunlukları verilmiştir. Tasarım için plakaların ana çerçevesi 150 mm x 150 mm, motorun gövdeye olan uzaklığı 181 mm ve çapraz iki motor arası uzaklık ise 510 mm olacak şekilde tasarlanmıştır. Plakaların birbirine montajında titreşim sönümleyici malzeme olarak kauçuk kullanılmıştır. Kullanılan kauçuklar iki plaka arasına yerleştirilmiştir. Böylece kauçukların hava aracı çalışırken motorların oluşturduğu titreşimi veya uçuş esnasında karşılaşılabilecek küçük çaplı darbeleri sönümlemesi ya da etkiyi en aza indirmesi amaçlanmaktadır.

Gövde ve Mekanik Sistemler


Ana çerçeve 150 mm x 150 mm boyutlarında olup kullanılan malzemeler için oldukça rahat bir montaj ve kolay yerleştirme imkânı sunması düşünülmüştür. Malzemelerin yerleştirilmesinde optimum düzeni sağlamak için alt ve üst plakalar arasında yaklaşık 45-50 mm mesafe bulunmaktadır. Böylece yerleştirilen malzemelerin çalışma esnasında birbirleriyle olan ısı alışverişlerinin en aza indirilmesi düşünülmüştür. Alt ve üst plakaların birbirine montajları kollar tarafından sağlanmaktadır. Kolların gövdeyle birleştiği noktalar kolların tasarımındaki omuzlarla sağlanmaktadır. Böylece plakalarda var olan yük, kollara eşit şekilde dağılmış olacak ve araç üzerinde daha sağlıklı bir balans oluşumu görülecektir. Bu omuzlar alt ve üst plakalara M2, M2.5, M3 vidalarla sabitlenmiştir.

İHA'da kullanılan bütün malzemelerin (Sensörler, Li-Po batarya, ESC, motorlar vb.) ağırlıkları ve geometrileri analiz edilmiştir. Kolların ve plakaların montajı ağırlık merkezi de dikkate alınarak uçuş ve görev sırasında dengesizlik oluşturmayacak şekilde yapılmıştır. Bu nedenle X çerçeve kullanıldığı açıklanmıştır. Motorlar ağırlık merkezi ortada olacak şekilde yerleştirilmiştir. İHA tasarımlarında ağırlık merkezinin ("COG" Center of Gravity) yeri oldukça mühim olup iyi belirlenmelidir. Pitch ve Roll Eksenî, X frame üzerinde simetrik olduğu için bu tasarım sayesinde hızlı yön değiştirme ve iyi takla atabilme kabiliyetine sahip olunması düşünülmüştür.

Aerodinamik Özellikler

Kalibrasyonları yapılmış standart ayardaki motorlara aynı anda ve aynı miktarlarda verilecek olan güç İHA'nın hareket etmesini sağlayan itme kuvvetini oluşturur. Motorlardan

gelen güç ile birlikte pervanelerin üzerinde aerodinamik bir kuvvet oluşur. Yani pervanede aynı bir uçak kanadında olduğu gibi üst yüzeyde havanın alt yüzeyden daha hızlı hareket etmesi sebebiyle alt yüzeyde oluşan basınç kaldırma kuvveti oluşturur. Bu kısımda dikkate alınan ve aerodinamik kuvveti oluşturan en önemli faktör hızdır ve bu aerodinamik kuvvet motorların dönüşünün belirli bir seviyeye ulaşması ile sağlanır. Kısaca özetlendiğinde; Pervanelerin takılmış olduğu motorlar hızı oluşturan ve pervanelerin dönme hareketini sağlayan kısımlardır. Bu sayede pervaneler İHA'yı havada tutacak itki kuvvetini üretir. Motor hızları değiştirildiğinde pervanelerin meydana getirdiği kuvvetler arası farklar ile oluşan momentler yardımıyla, İHA belli başlı hareketleri gerçekleştirir. İHA'nın pervane çiftleri uçuş boyunca farklı yönlerde döndürülmektedir. Bu farklılık, motor aracılığıyla dönen pervanelerin oluşturduğu momentlerin birbirlerini etkilemelerini engeller. Böylece, İHA havada sabit bir yönelimde durabilmektedir.



Şekil 43. Pervane kuvvetleri ve eksenlerdeki hareket yönleri

$$F_{net} = F_1 + F_2 + F_3 + F_4 \quad (14)$$

$$W = mg \quad (15)$$

Bu iki kuvvet İHA'ya etki eden temel kuvvetlerdir. Bu kuvvetlerin birbirlerine göre etkileri İHA'nın hareket durumu hakkında bilgi verir. Bu kuvvetleri oluşturan ve kuvvetler dengesinde ne olduğu Tablo 5'te gösterilmiştir.

Tablo 4. İHA'nın Denge Kuvvetleri ve Yaptığı Hareketler

Kuvvet Durumu	Yapılan Hareket
$F_{net} = W$	Dengede Kalma (HOVER)
$F_{net} > W$	Yükselme
$F_{net} < W$	Alçalma
$F_2 + F_3 > F_1 + F_4$	İleri Yunuslama (Pitch)
$F_1 + F_4 > F_2 + F_3$	Geri Yunuslama (Pitch)
$F_3 + F_4 > F_1 + F_2$	Sağa Yuvarlanma (Roll)
$F_1 + F_2 > F_3 + F_4$	Sola Yuvarlanma (Roll)
$F_2 + F_4 > F_1 + F_3$	Sağa Yalpa (Yaw)
$F_1 + F_3 > F_2 + F_4$	Sağa Yalpa (Yaw)

Askıda kalma hareketi İHA'nın uçuşu boyunca en çok kaldığı durumdur. İHA bu durumda sabit bir irtifada uçuşunu sürdürmektedir. Dört pervanenin de oluşturduğu toplam kaldırma kuvveti, İHA'nın kütle merkezine uygulanan yer çekimi kuvvetine eşittir. Böylece İHA hareketsiz olarak, yükselip alçalmadan havada asılı kalır. Her bir pervane aynı anda ve aynı açısal hızlarla pozitif yönde ivmelendirilirse pervanelerin oluşturduğu toplam kaldırma kuvveti İHA'nın ağırlığından fazla olur. Bu da İHA'nın yönelimini değiştirmeden lineer yükselmesine neden olur. Aynı şekilde dönme hızları eşit olacak biçimde azaltılırsa bulunduğu konumdan alçalmaya başlar. $F_{net} > W$ eşitsizliği alçalma durumunu ifade eder. Her bir pervane aynı anda ve aynı açısal hızlarla pozitif yönde ivmelendirilirse pervanelerin oluşturduğu toplam kaldırma kuvveti İHA'nın ağırlığından fazla olur. Bu da İHA'nın yönelimini değiştirmeden lineer yükselmesine neden olur. Aynı şekilde dönme hızları eşit olacak biçimde azaltılırsa bulunduğu konumdan alçalmaya başlar. $F_{net} < W$ eşitsizliği alçalma durumunu ifade eder. Bu hareketi gerçekleştirmek için sağdaki motorlarda itme gücünü artırarak sol taraftaki motorların itme kuvveti azaltılmalıdır. Bunun nedeni net torku sıfır tutmak ve sola doğru net kuvvet sağlamaktır. Yunuslama hareketi ile İHA geri yönde ilerlemektedir. Bu durumun sağlanabilmesi için 1 ve 4 numaralı motorlara giden gücü artırırsak İHA'nın ön kısmının yönelimi aşağı doğru olur. Böylece öndeki motorların hızının azaltılması toplam açısal momentum değerini de korur. Yalpa hareketi İHA'nın z eksenini etrafında dönmesidir. 1 ve 3 numaralı pervane çiftlerinin açısal hızları aynı oranda artırılırsa ve 2 ve 4 numaralı pervane çiftlerinin hızları aynı oranda azaltılarak, sürüklenme farkından dolayı, kendi eksenini etrafında pozitif bir moment oluşur ve İHA dönmeye başlar. Pervane Aerodinamiği, pervane kanadı iki bölümden oluşur. Kalın olan ve dönme yönünde ilerleyen hücum kenarıdır. İnce olan kenar ise firar kenarıdır. Kanat profilinin hücum kenarı, havayı kesen kenarıdır. Hücum kenarı havayı kestikçe, hava kanat yüzünden akar.

İHA'nın yükselme hızı pervanenin hatve değeri (Pitch Angle) ile ilişkilidir. Pervanenin burğu açısı ne kadar büyükse İHA o kadar hızlı yükselir. Pervaneden Elde Edilen Statik İtke Kuvveti Hesabı, statik itki kuvveti hesaplanırken; pervanenin itki sabiti, uçuşun gerçekleştirildiği bölgede ki havanın yoğunluğu, kullanılan pervanenin çapı ve 1 saniyedeki devir sayısı parametrelerine bağlıdır.

$T = c_t \rho n^2 D^4$ (T: İtke Kuvveti c_t : Pervane İtke Sabiti, ρ : Havanın Yoğunluğu (kg/m^3), D: Pervane Çapı (m),n: 1 saniyedeki devir sayısı)

$$T = c_t \rho n^2 D^4, c_t = 0.1125, D = 254 \text{ mm} = 0.254 \text{ m}, KV = 980$$

devir sayısı $n = 980 \times 6.3 / 60 = 102.9$ RPS olarak hesaplanmıştır.

$$T = 0.1125 \times 1.111 \times (102.9)^2 \times (0.254)^4 = 5.51 \text{ N olarak bulunmuştur.}$$

Kalkış için gerekli olan tek motor itke kuvveti :

$$T_{\text{gerek}} = mg/4$$

$$T_{\text{gerek}} = 2.097 \times 9.81 / 4 = 5.14 \text{ N}$$

Yapılan hesaplamalara göre tek motordan üretilen 5.51 N'luk bir kuvvet ile 5.14 N'luk gereksinim karşılanmış olur. Motor başına taşınan kilogram hesabı;

$$(5.51 \text{ N}) / 9.81 = 0.562 \text{ kg} = 562 \text{ gr olarak hesaplanır.}$$

İHA'nın taşıyabileceği toplam kilogram hesabı:

$$0.562 \times 4 = 2.248 \text{ kg} = 2248 \text{ gr olarak bulunmuştur.}$$

Böylece 4 motorun aynı anda ve senkronize bir şekilde çalışması sonucu toplamda 2248 gramlık bir kütle havalanabilir. 2097 gram bulunan İHA kütlesi bu değerin altında yer aldığı için hesaplanan itke (thrust) değeri yeterlidir.

Tablo 5. İHA'nın Bazı Performans Verileri

Voltaj (V)	Pervane Modeli	Akım (A)	İtke (G)	Güç (W)	Verim (G/W)	Devir (RPM)
11.1	1045	6	0.562 kg	129.3	5.84	6679

Uçuş Performans Parametreleri

Hava aracının ağırlığı 2097gr Uçuş Süresi: 9,8dk, motorların ulaşacağı sıcaklık 43°C, motorların toplam itkisi 1.3kg, harcanacak güç miktarı 129 Watt'tır. Pil gereksinim hesabı aşağıdaki şekilde yapılmıştır: Pil kapasitesini $Bc(Ah) \times 60(dakika) / Uçuş\ Süresi\ (dakika)$ $(6*60)/9.8=36.73\ A$ (veya motor başına 9.18A) olarak hesaplanmıştır. Dolayısıyla nominal bir 11.1V'luk 3S pil için bu değer 220W olur (motor başına 55W).

İHA'nın ağırlığı 2097gr ve sonuç olarak;

$$2097/(36.73*9.8)=5.83g/W$$

Uçuş Testleri ve Performans Sonuçları

İHA'nın yapılan test uçuşları sonucunda ulaşılan değerler bu başlık altında detaylandırılmıştır.

Güç Tüketim Testi, 11.1V'luk 3S pil kullanılarak yapılan uçuşta harcanan toplam güç 129W olarak görülmüştür. (motor başına 32.25W). Yapılan bu uçuş, kritik pil düzeyi seviyelerine kadar devam ettirilip uçuş süresi 8 dakika 52 saniye olarak gözlenmiştir.

İtke testleri;

$T = ct \cdot \rho n^2 D^4$, $ct = 0.1125$, $D = 254\ mm = 0.254\ m$, $KV = 980$ kullanılan değerler hava aracının üzerindeki komponentlerin değerleridir. Test uçuşu sonrası motor başına devir sayısı

$$n = 980 \times 6.3 / 60 = 102.9\ RPS\ olarak\ hesaplanmıştır.$$

Yine yapılan uçuşta itke, $T = 0.1125 \times 1.111 \times 102.9^2 \times 0.254^4 = 5.51N$ olarak bulunmuştur. Motorların kaldırdığı ağırlık $(5.51\ N) / 9.81 = 0.562kg = 562gr$ olarak hesaplanmıştır.

Akım ve gerilim testleri;

Yapılan uçuş testinden alınan uçuş süresine göre motorların çektiği toplam akım değeri aşağıdaki gibidir:

$$Pil\ kapasitesini\ Bc(Ah) \times 60(dakika) / Uçuş\ Süresi\ (dakika) \rightarrow (6*60)/8.66 = 41.57A\ (veya\ motor\ başına\ 10.39A)\ olarak\ hesaplanmıştır.$$

Donanım ısınma testleri;

Uçuş sonrası motorların sıcaklığı ölçülmüş ve ortalama olarak bir motorun sıcaklığı 38.6°C olarak ölçülmüştür. Yine uçuş sonrası ölçülmüş olan ortalama bir ESC sıcaklığı ise 34.3°C olarak gözlenmiştir.

Telemetri kapsama alanı ve veri hızı testleri;

Yapılan uçuş sonucu alınan telemetri verileri şöyledir:


Algılanan Mesafe: 2500 metre

Yayılım Hızı: 500mW

Alıcı Hassasiyeti: -124dBm

GPS Hassasiyet Sonuçları


Test uçuşları sonucunda alınan değerlere göre 0.60 metre ile 0.80 metre arasında GPS hassasiyeti bulunmaktadır.



Şekil 44. MissionPlanner GPS üzerinden alınan konum

LIDAR Sonuçları

İHA'nın çevre etkileşimini artırmak adına LIDAR kullanılmıştır ve İHA uçurulurken çalışan LIDAR ile çevre etkileri incelenmiştir. Bu sayede çevredeki engeller, ağaçlar, duvarlar gibi çevre hakkında daha fazla bilgiye sahip olundu. Çevre etkileşimi sayesinde nesne tespitinin yanında nesne algılama işlemi de gerçekleşmiştir. LIDAR'ın lazer atım yarı çapı 12 metredir ve bu ölçüde görüntüler alınmıştır. Uçuş sırasında, çevrede duvar olacak alanlarda LIDAR'ın etkinliği gösterilmek adına çekimler yapılmıştır. Şekil 45'te görüldüğü gibi Google Earth ile işaretlenmiş alanların LIDAR görüntüleri verilmiştir.




Şekil 45. LIDAR ile alınmış görüntüler ve Google Earth ile karşılaştırılması


Bulut Tabanlı Eğitilen Modelin Sonuçları

Veri havuzunu genişletmek ve büyük veri faaliyetlerini desteklemek için sürekli bir şekilde eğitim yapılmaktadır. Bu eğitimler gün geçtikçe artacak ve hiçbir harici sisteme ihtiyaç duymadan büyümeye devam edecektir. Bazı eğitim sonuçlarını görebilmek adına kayıp fonksiyon değerleri verilmiştir. Kayıp değerlerinin az olması sebebiyle nesne tespit işlemleri başarılı bir sonuç verecektir. Kayıp fonksiyonu ve değerleri ne kadar düşük olursa o kadar az hata payıyla tespit yapmamız mümkün olacaktır. Nesnelerin algılanması için çok yüksek başarı sonuçlara erişmek, nesnelerin ayrımında çok önemlidir.

Şekil 46'da görüldüğü gibi yığın değeri 16 ve çözünürlük değeri 256x256 (a) alındığında ortalama kayıp değeri 2.36 olarak ölçülmüştür. Ağaç nesnesini ise %82 başarı oranıyla tespit edildiği görülmektedir. Yığın değeri 64 ve çözünürlük değeri 416x416 (b) olduğunda ise kayıp değeri 1.47 iken ağaç nesnesini %98 başarı oranıyla tespit edilmiştir.




(a)




(b)

Şekil 46. Ağaç tespiti için eğitilen modelin kayıp fonksiyonu ve tespit başarı oranı

Şekil 47’de görüldüğü gibi yığın değeri 16 ve çözünürlük değeri 256x256 (a) alındığında ortalama kayıp değeri 1.59 olarak ölçülmüştür. Ağaç nesnesini ise %99 başarı oranıyla tespit edildiği görülmektedir. Yığın değeri 64 ve çözünürlük değeri 416x416 (b) olduğunda ise kayıp değeri 1.03 iken ağaç nesnesini %100 başarı oranıyla tespit edilmiştir. Ayrıca arka tarafta çok dar bir açıdan gözükten tekerleği tespit ettiği de görülmektedir.




(a)




(b)

Şekil 47. Tekerlek tespiti için eğitilen modelin kayıp fonksiyonu ve tespit başarı oranı

Şekil 48’de görüldüğü gibi yığın değeri 16 ve çözünürlük değeri 256x256 (a) alındığında ortalama kayıp değeri 3.17 olarak ölçülmüştür. Pencere nesnelerini ise %94, %98, %85, %95 başarı oranlarıyla tespit edildiği görülmektedir. Yığın değeri 64 ve çözünürlük değeri 416x416 (b) olduğunda ise kayıp değeri 1.82 iken pencere nesnelerinin %93, %100, %95, %99 başarı oranlarıyla tespit edilmiştir.




(a)




(b)

Şekil 48. Pencere tespiti için eğitilen modelin kayıp fonksiyonu ve tespit başarı oranı

Şekil 49’da görüldüğü gibi yığın değeri 16 ve çözünürlük değeri 256x256 (a) alındığında ortalama kayıp değeri 1.65 olarak ölçülmüştür. Bisiklet nesnelerini ise %90, %66, %70, %91 başarı oranlarıyla tespit edildiği görülmektedir. Yığın değeri 64 ve çözünürlük değeri 416x416 (b) olduğunda ise kayıp değeri 0.86 iken bisiklet nesnelerinin %98 başarı oranlarıyla tespit edilmiştir. Burada dikkat edilmesi gereken başka bir husus ise ilk bisiklet tespiti görüntüsünde bisiklet olmayan bir nesneyi, bisikletmiş gibi algılayıp bir kutulama işlemi yapılmıştır.



(a)



(b)


Şekil 49. Bisiklet tespiti için eğitilen modelin kayıp fonksiyonu ve tespit başarı oranı

Yukarıda gösterildiği üzere çalışmada çeşitli parametreler denenmiş olup, 416x416 ve yığın değeri 64 olduğunda daha başarılı sonuçlar elde edilmiştir. Burada temel amaç belirlenip ya eğitim süresini uzatmayı seçerek daha yüksek başarımlı hesaplama yapılmalıdır ya da eğitim süresini kısaltıp daha düşük başarımlı sonuçlar hesaplanmalıdır. Yüksek çözünürlükte ve uzun süreli eğitimler, kare hızını da etkileyeceği için bu kararın verilmesi çok önemlidir.

Bulut Tabanlı Nesne Algılama Sonuçları

Yapılan araştırmalar sonucunda ve eğitilen sistem sayesinde nesne tespiti yapmak mümkündür. Tüm bu işlemler bulutta yapılmış olup, görüntüler İHA'ya bağlanmış bir Raspberry Pi kamera ile çekilmiştir. Sonuçlar son derece iyi olup Şekil 50'de gösterilmiştir. Bunlara ek olarak görüntüler, kişisel bilgisayarlarda da görülebilir haldedir. Çünkü uzaktan bağlantı kurulup bu görüntülerin alınması mümkündür. İHA'ya bağlanmış bu sistem, düşük

irtifada çekilmiş olup, gerektiği zaman kamera açısı değiştirilerek görüntü alınmıştır. Raspberry Pi kamerası, uzatma kablosu sayesinde istenen açılarda görüntü alınabilecek bir şekilde kullanılabilir.



Şekil 50. Pencere (a), ağaç (b), bisiklet (c), tekerlek (d) nesneleri için bulut tabanlı nesne algılama sonuçları

Tartışma

Çalışma, insansız hava araçlarıyla çevre etkileşimi yüksek ve çevrede gelişen doğrusal ve doğrusal olmayan parametrelerin algılanmasını sağlaması amacıyla yapılmıştır. Kullanılan araç, çevre ile bağlantı kurabilmek için bir kamera ve bir LIDAR ile donatılmıştır. Kamera ile çevredeki nesneleri tespit eder ve amaç doğrultusunda veri havuzunu büyütmek için daha sonra etiketlemek adına buluta kaydedilir. Toplanan görüntüler daha sonra etiketlenir. Etiketlenmiş resimler üzerinde nesneleri tanıyabilmek için çalışmada kullanılan evrişim sinir ağları yöntemiyle eğitim yapılır. Evrişimli sinir ağları ile ağırlıklar oluşturulur ve eğitilen etiketli resimler daha sonra nesne algılamak için buluta yüklenir. Bulutta kaydedilen ağırlıklar kullanılarak bulut tabanlı nesne algılama işlemi sağlanmış olur. LIDAR kullanımının sebebi ise

gene çevre etkileşimini artırmak adına eklenmiş bir özelliktir. LIDAR ile çevredeki hareketli ve hareketsiz nesnelerin uzaklıkları ve şekilsel durumu hakkında bilgiler alınır. 360 derece lazer atımı yapması sebebiyle İHA çevresinde neler olduğu algılanması daha kolaydır.

Hazır kullanılan veri setine ek olarak tarafımızca oluşturulan veri havuzu da kullanılmaktadır. Buradaki temel amaç verileri biriktirip, çok daha fazla veri kümesi oluşturmaktır. Günümüzde çokça araştırılan ve katkı sağlanmaya çalışılan büyük veri çalışmasına bu sayede katkı sağlanmış olur. Etiketli resimlerin bulunması büyük bir problemdir. Çalışma ile hazır hizmetlerde bulunmayan ve bir amaç için özel geliştirilmesi gereken etiketli resimleri yapmak bu sayede çok daha kolay bir hâl alacaktır. Buna ek olarak çok özel durumlarda ve senaryolarda istenen şekilde etiketlemek ve eğitmek mümkün olacaktır.

Bulut üzerinden görüntü alınması, bulut ile eğitimin yapılması, buluta resim dosyalarının eklenmesi gibi işlemler, İHA'ya monte edilecek mikroişlemcilerin sınırlı kapasitesinden dolayı çok güzel bir seçenek olacaktır. Günümüzde taşımaya müsait işlemciler ve ekran kartları sınırlı kapasiteye sahiptir. Bu yüzden hareketli sistemlerde işlemci güçlerinin yetersiz olmasından dolayı işleme yeteneği zayıftır. Görüntü işleme, bilgisayarlı görü gibi görüntü dosyaları ile yapılacak işlemler, zaman ve işleme maliyeti yüksek olan işlemlerdir. Çalışma ile bu gibi yetersiz durumlardan kurtulup, yüksek işlem kabiliyetine sahip bulut sistemlerinden faydalanmak mümkün olacaktır. Sadece internet bağlantısının olmasıyla bu işlemler kolay bir şekilde yapılacaktır.

SONUÇ VE ÖNERİLER

Çalışma düşük işlem kapasiteli ve hareketli sistemler için bulut sistemleri kullanarak, çevre faaliyetlerini ve nesnelerini algılamak için yapılmıştır. İHA'lar için çevre faaliyetli oldukça önemlidir. Çünkü çalışma süresinin önemli bir bölümünü havada geçiren bu sistemler, çevredeki olumsuz şartlara karşı hareket etmelidir. Beklenmedik durumlar geliştiğinde İHA'nın kırım yaşaması kaçınılmazdır. Kırım yaşanması ile büyük bir mali külfet ortaya çıkacaktır. Bunların önlenmesi için çevrede gerçekleşen doğrusal ve doğrusal olmayan hareketleri algılaması çok önemlidir. Bununla birlikte çevredeki nesneleri tanınması ve bu nesnelerin iyi bir seviyede algılaması gereklidir. Nesne algılama işlemini, düşük işlem gücüne sahip mikrobilgisayarlarla yapmak oldukça zordur. Bu yüzden bu işlemleri bulut hizmeti sunan servisler sayesinde yapılabilir. Bulut servisleri hem nesne algılamak için gerekli işlemleri yapmamıza olanak tanırken ayrıca görüntü verilerini depolamak için de kullanılmıştır.

Görüntü işleme ve nesne tespiti işlemleri bulutta gerçekleştirilmektedir. Çalışmada bulut tabanlı derin öğrenme yöntemleri kullanarak gerçek zamanlı nesne algılama yapılmaktadır. Bu işlemi yapabilmek için önce görüntü verileri toplandı, daha sonra bu görüntüler istenen nesneleri algılamak adına etiketlendir. Etiketlenmiş veriler, YOLO tabanlı bir sistem kullanılmıştır. Bu sistem ihtiyaca uygun şekilde revize edilerek istenen şekilde uyarlanmıştır. Görüntü verileri 128x128, 256x256, 320x320 gibi genel bir çözünürlük yerine 416x416 şeklinde kullanılmıştır. Tercih edilen bu çözünürlük sayesinde eğitim hızı arttı ve eğitim aşamalarının süresi kısaltılmıştır. Maksimum yığın değeri 2000 olacak şekilde düzenlenmiştir. Yığın değeri ise işlemin hızını artırmak için 64 olarak kullanılmıştır. Kullanılan yöntemde tek bir sınıf için eğitim yapılabilirken, çok sayıda nesneyi de aynı anda eğitilebilmektedir. Nesne algılamada tespit işlemi kayıp değerleri küçük veri setleriyle bile %2 gibi küçük oranlarda eğitim sağlandığı gözlenmiştir. Eğitim işlemi tamamlandıktan sonra bulut üzerinden gerçek zamanlı nesne algılama işlemleri yapılabilir hale gelmiştir. Aynı zamanda İHA'dan alınan bu nesne tespiti görüntüleri kişisel bilgisayarlardan izlenebilir bir şekilde ayarlanmıştır.

İHA için çevre etkileşimini artırmak adına LIDAR eklenmiş ve enerji sorununu çözmek ve kontrol edilmesinin kolay olması için ekstra bir Raspberry Pi kullanılmıştır. Bu sayede hem enerji problemi çözülmüş hem de görün açısından zayıf olan Emlid Linux işletim sistemi yerine Ubuntu işletim sistemi kullanılmıştır. Ayrıca Linux tabanlı bir işletim sistemi olan Ubuntu ile ROS ve ROS'un içinde bulunan Gazebo, Rviz gibi simülasyon programlarının kullanılması da

sağlanmıştır. ROS robotik sistemlerde görselleştirme ve simülasyon için kullanılan çok önemli bir sistemdir. Bunun sisteme eklenmesi sayesinde daha etkin bir şekilde kullanılması ve direkt bir şekilde müdahale yapılabilir hale geldi.

Hazır olarak kullanılan veri setiyle birlikte genel geçer bazı nesnelerin tespit işlemi kolay bir şekilde sağlandı. Ancak sınırlı bir nesne kapasitesi olan bu hazır veri tabanları spesifik işlemlerin ve özel senaryoların çözümünde kullanmak mümkün değildir. Bu yüzden kendi veri setimizi üretmek çok önemlidir. Bu amaçla çalışmada bir veri havuzu oluşturulmuştur. Bu veri havuzunda istenen nesnelerin etiketli ve etiketsiz halleri depolanmıştır. Etiketli olmayan nesneler daha sonra etiketlenmek adına tutulmaktadır. Etiketli olan görüntü verileri ile evrişimli sinir ağları ile bulut üzerinde eğitilmiştir. Eğitilen nesnelerin ağırlıkları daha sonra nesne algılama işlemleri için kullanılmak üzere kaydedilmiştir. Bu sayede sürekli artacak ve başka servislere bağımlı kalınmamış olacaktır. Büyük veri için sürekli artacak bir veri havuzu oluşturulmuştur.

Çalışmaya ilerleyen zamanda, yeni nesil daha güçlü LIDAR'lar eklenerek üç boyutlu haritala yapılması sağlanacaktır. Üç boyutlu şekilde nesnelerin algılanması çevre etkileşimini artıracak ve çok daha tutarlı hesaplamaların yapılabilmesi mümkün olacaktır. Bunlara ek olarak veri seti büyütmenin en büyük sorunlarından biri olan etiketleme işlemleri, daha önceki eğitilmiş veriler üzerinden eğitilmiş modellerle otomatik bir şekilde etiketlenmesi sağlanacaktır.

KAYNAKLAR

- Al-Kaff, A., Martin, D., Garcia, F., de la Escalera, A., & Armingol, J. M. J. E. S. w. A. (2018). Survey of computer vision algorithms and applications for unmanned aerial vehicles. 92, 447-463.
- Amidi, A., & Amidi, S. (2018). VIP Cheatsheet: Recurrent Neural Networks. In.
- Arf, C. (1959). Makine Düşünebilir mi ve Nasıl Düşünebilir? *Atatürk Üniversitesi – Üniversite Çalışmalarını Muhite Yayma ve Halk Eğitimi Yayınları Konferanslar Serisi*, p. 91-103.
- Ayyad, A., Chehadeh, M., Awad, M. I., & Zweiri, Y. J. I. A. (2020). Real-time system identification using deep learning for linear processes with application to unmanned aerial vehicles. 8, 122539-122553.
- Bannwarth, J. X., Jeremy Chen, Z., Stol, K. A., MacDonald, B. A., & Richards, P. J. J. A. J. (2019). Aerodynamic force modeling of multicopter unmanned aerial vehicles. 57(3), 1250-1259.
- Benjdira, B., Khursheed, T., Koubaa, A., Ammar, A., & Ouni, K. (2019). Car detection using unmanned aerial vehicles: Comparison between faster r-cnn and yolov3. 2019 1st International Conference on Unmanned Vehicle Systems-Oman (UVS),
- Bristeau, P.-J., Martin, P., Salaün, E., & Petit, N. (2009). The role of propeller aerodynamics in the model of a quadrotor UAV. 2009 European control conference (ECC),
- Browne, M., Ghidary, S. S., & Mayer, N. M. (2008). Convolutional neural networks for image processing with applications in mobile robotics. In *Speech, Audio, Image and Biomedical Signal Processing using Neural Networks* (pp. 327-349). Springer.
- Castellano, G., Castiello, C., Mencar, C., & Vessio, G. J. I. A. (2020). Crowd detection in aerial images using spatial graphs and fully-convolutional neural networks. 8, 64534-64544.
- Chao, H., Cao, Y., Chen, Y. J. I. J. o. C., Automation, & Systems. (2010). Autopilots for small unmanned aerial vehicles: a survey. 8(1), 36-44.
- Ernest, N., Carroll, D., Schumacher, C., Clark, M., Cohen, K., & Lee, G. J. J. o. D. M. (2016). Genetic fuzzy based artificial intelligence for unmanned combat aerial vehicle control in simulated air combat missions. 6(1), 2167-0374.1000144.
- Garcia-Pulido, J., Pajares, G., Dormido, S., & de la Cruz, J. M. J. E. S. w. A. (2017). Recognition of a landing platform for unmanned aerial vehicles by using computer vision-based techniques. 76, 152-165.
- Gatesichapakorn, S., Takamatsu, J., & Ruchanurucks, M. (2019). ROS based autonomous mobile robot navigation using 2D LiDAR and RGB-D camera. 2019 First international symposium on instrumentation, control, artificial intelligence, and robotics (ICA-SYMP),
- Gebrehiwot, A., Hashemi-Beni, L., Thompson, G., Kordjamshidi, P., & Langan, T. E. J. S. (2019). Deep convolutional neural network for flood extent mapping using unmanned aerial vehicles data. 19(7), 1486.
- Gonzalez, L. F., Montes, G. A., Puig, E., Johnson, S., Mengersen, K., & Gaston, K. J. J. S. (2016). Unmanned aerial vehicles (UAVs) and artificial intelligence revolutionizing wildlife monitoring and conservation. 16(1), 97.
- Guenard, N. (2007). *Optimisation et implémentation de lois de commande embarquées pour la téléopération de micro drones aériens X4-flyer Nice*].
- Horak, K., & Zalud, L. J. I. J. o. S. P. S. (2016). Image processing on raspberry pi for mobile robotics. 4(2), 1-5.
- HrISToV, G. V., ZAHARIEV, P. Z., & BELoEV, I. H. J. A. T. A. (2016). A review of the characteristics of modern unmanned aerial vehicles. 19(2), 33-38.

- Hua, B.-S., Tran, M.-K., & Yeung, S.-K. (2018). Pointwise convolutional neural networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*,
- Huang, H., Hoffmann, G. M., Waslander, S. L., & Tomlin, C. J. (2009). Aerodynamics and control of autonomous quadrotor helicopters in aggressive maneuvering. 2009 IEEE international conference on robotics and automation,
- Hugo, R., Salazar, S., Sanchez, A., Castillo, P., & Lozano, R. (2007). Modelling and real-time control stabilization of a new VTOL aircraft with eight rotors. 2007 IEEE/RSJ International Conference on Intelligent Robots and Systems,
- Images, O. (2021). Retrieved 16.04.2021 from <https://storage.googleapis.com/openimages/web/index.html>
- Kam, H. R., Lee, S.-H., Park, T., & Kim, C.-H. J. T. S. (2015). Rviz: a toolkit for real domain data visualization. 60(2), 337-345.
- Kim, J., Kim, S., Ju, C., & Son, H. I. J. I. A. (2019). Unmanned aerial vehicles in agriculture: A review of perspective of platform, control, and applications. 7, 105100-105115.
- Koubâa, A., & Qureshi, B. J. I. A. (2018). Dronetrack: Cloud-based real-time object tracking using unmanned aerial vehicles over the internet. 6, 13810-13824.
- Lee, J., Wang, J., Crandall, D., Šabanović, S., & Fox, G. (2017). Real-time, cloud-based object detection for unmanned aerial vehicles. 2017 First IEEE International Conference on Robotic Computing (IRC),
- Liang, X., Zhang, J., Zhuo, L., Li, Y., Tian, Q. J. I. T. o. C., & Technology, S. f. V. (2019). Small object detection in unmanned aerial vehicle images using feature fusion and scaling-based single shot detector with spatial context analysis. 30(6), 1758-1770.
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft coco: Common objects in context. *European conference on computer vision*,
- Markom, M. A., Adom, A. H., Tan, E. S. M. M., Shukor, S. A. A., Rahim, N. A., & Shakaff, A. Y. M. (2015). A mapping mobile robot using RP Lidar scanner. 2015 IEEE International Symposium on Robotics and Intelligent Sensors (IRIS),
- Martinez- Alpiste, I., Casaseca- de- la- Higuera, P., Alcaraz- Calero, J. M., Grecos, C., & Wang, Q. J. J. o. F. R. (2020). Smartphone- based object recognition with embedded machine learning intelligence for unmanned aerial vehicles. 37(3), 404-420.
- Mendonça, R., Santana, P., Marques, F., Lourenço, A., Silva, J., & Barata, J. (2013). Kelpie: A ros-based multi-robot simulator for water surface and aerial vehicles. 2013 IEEE International Conference on Systems, Man, and Cybernetics,
- Meng, L., Li, L., & Veres, S. (2010). Aerodynamic parameter estimation of an unmanned aerial vehicle based on extended kalman filter and its higher order approach. 2010 2nd International Conference on Advanced Computer Control,
- Mettler, B. (2013). *Identification modeling and characteristics of miniature rotorcraft*. Springer Science & Business Media.
- Morrison, A., Tronstad, R., & Martinussen, E. S. J. D. C. (2013). Design notes on a lonely drone. 24(1), 46-59.
- Neto, A. M., Victorino, A. C., Fantoni, I., Zampieri, D. E., Ferreira, J. V., & Lima, D. A. (2013). Image processing using Pearson's correlation coefficient: Applications on autonomous robotics. 2013 13th International Conference on Autonomous Robot Systems,
- Prouty, R. W. (1995). *Helicopter performance, stability, and control*.
- Rajagopal, A., Joshi, G. P., Ramachandran, A., Subhalakshmi, R., Khari, M., Jha, S., Shankar, K., & You, J. J. I. A. (2020). A Deep Learning Model Based on Multi-Objective Particle Swarm Optimization for Scene Classification in Unmanned Aerial Vehicles. 8, 135383-135393.
- Rivera, Z. B., De Simone, M. C., & Guida, D. J. M. (2019). Unmanned ground vehicle modelling in Gazebo/ROS-based environments. 7(2), 42.

- Sabikan, S., & Nawawi, S. J. J. o. A. R. D. (2016). Open-source project (OSPs) platform for outdoor quadcopter. 24, 13-27.
- Shah, M. K. N., Dutt, M. B. J., Modh, H. J. I. j. o. E. d., & research. (2014). Quadrotor—an unmanned aerial vehicle. 2(1), 1299-1303.
- Swinney, C. J., & Woods, J. C. (2020). Unmanned Aerial Vehicle Flight Mode Classification using Convolutional Neural Network and Transfer Learning. 2020 16th International Computer Engineering Conference (ICENCO),
- Tayebi, A., & McGilvray, S. J. I. T. o. c. s. t. (2006). Attitude stabilization of a VTOL quadrotor aircraft. 14(3), 562-571.
- Topouzelis, K., Papakonstantinou, A., & Doukari, M. J. F. E. B. (2017). Coastline change detection using Unmanned Aerial Vehicles and image processing technique. 26, 5564-5571.
- Turing, A., & Haugeland, J. (1950). *Computing machinery and intelligence*. MIT Press Cambridge, MA.
- Ventura Diaz, P., & Yoon, S. (2018). High-fidelity computational aerodynamics of multi-rotor unmanned aerial vehicles. 2018 AIAA Aerospace Sciences Meeting,
- Vissiere, D., Bristeau, P.-J., Martin, A. P., & Petit, N. J. I. P. V. (2008). Experimental autonomous flight of a small-scaled helicopter using accurate dynamics model and low-cost sensors. 41(2), 14642-14650.
- Voulodimos, A., Doulamis, N., Doulamis, A., Protopapadakis, E. J. C. i., & neuroscience. (2018). Deep learning for computer vision: A brief review. 2018.
- Wu, Q., & Zhou, Y. (2019). Real-Time Object Detection Based on Unmanned Aerial Vehicle. 2019 IEEE 8th Data Driven Control and Learning Systems Conference (DDCLS),
- Xie, X., Yang, W., Cao, G., Yang, J., Zhao, Z., Chen, S., Liao, Q., & Shi, G. (2018). Real-time vehicle detection from uav imagery. 2018 IEEE Fourth International Conference on Multimedia Big Data (BigMM),
- Yaseen, M. U., Anjum, A., & Rana, O. (2018). Cloud-based scalable object detection and classification in video streams. 80, 286-298.
- Ye, D. H., Li, J., Chen, Q., Wachs, J., & Bouman, C. J. E. I. (2018). Deep learning for moving object detection and tracking from a single camera in unmanned aerial vehicles (UAVs). 2018(10), 466-461-466-466.
- Yuan, C., Ghamry, K. A., Liu, Z., & Zhang, Y. (2016). Unmanned aerial vehicle based forest fire monitoring and detection using image processing technique. 2016 IEEE Chinese Guidance, Navigation and Control Conference (CGNCC),
- Zeng, Y., Zhang, R., & Lim, T. J. J. I. C. M. (2016). Wireless communications with unmanned aerial vehicles: Opportunities and challenges. 54(5), 36-42.
- Zhang, Z., Cui, P., Zhu, W. J. I. T. o. K., & Engineering, D. (2020). Deep learning on graphs: A survey.
- Zhao, Z.-Q., Zheng, P., Xu, S.-t., Wu, X. J. I. t. o. n. n., & systems, l. (2019). Object detection with deep learning: A review. 30(11), 3212-3232.
- Zhou, D.-X. J. A., & analysis, c. h. (2020). Universality of deep convolutional neural networks. 48(2), 787-794.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Mehmet Bilge Han TAŞ
Doğum tarihi:	
Doğum Yeri:	
Uyruğu:	
Adres:	
Tel:	
E-mail:	
Eğitim	
Lise:	Erzincan Fen Lisesi
Lisans:	Erciyes Üniversitesi, Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü
Yüksek lisans:	Atatürk Üniversitesi, Fen Bilimleri Ens., Bilgisayar Mühendisliği Anabilim Dalı (2019 – 2021)
Yabancı Dil Bilgisi	
İngilizce:	İyi
Yayınlar ve Projeler	
1. BAP Projesi 2020 - Uçuşa ve Nesne Taşıma Özelliklerine Sahip İnsansız Hava Aracı" ve "Akıllı İlaç Kutusu"	
2. BAP Projesi 2021 - "Eğitim Amaçlı Otonom Araç Kiti" ve "Hedef Tespiti ve Takibi Yapabilen Döner Kanatlı İnsansız Hava Aracı"	
3. Bildiri (29. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı) – “Yapay Sinir Ağları ve Makine Öğrenmesi Yöntemleri ile Karşılaştırmalı Meme Kanseri Algılama” M.C. IRMAK, M.B.H TAŞ, S. TURAN, A. HAŞILOĞLU (2021) - Kabul edildi, basım aşamasında	