



**GÜNEŞ PANELLERİNİN DÖRT ROTORLU İHA  
KULLANILARAK TERMOGRAFI YÖNTEMİYLE  
DERİN ÖĞRENME TABANLI HATA TESPİT VE  
TEŞHİSİ**

**Barış KAYCI**

**2021  
YÜKSEK LİSANS TEZİ  
MEKATRONİK MÜHENDİSLİĞİ**

**Tez Danışmanı  
Dr. Öğr. Üyesi Batıkan Erdem DEMİR**

**GÜNEŞ PANELLERİNİN DÖRT ROTORLU İHA KULLANILARAK  
TERMOGRAFI YÖNTEMİYLE DERİN ÖĞRENME TABANLI HATA  
TESPİT VE TEŞHİSİ**

**Barış KAYCI**

**T.C.  
Karabük Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Mekatronik Mühendisliği Anabilim Dalında  
Yüksek Lisans Tezi  
Olarak Hazırlanmıştır**

**Tez Danışmanı  
Dr. Öğr. Üyesi Batıkan Erdem DEMİR**

**KARABÜK  
Nisan 2021**

Barış KAYCI tarafından hazırlanan “GÜNEŞ PANELLERİNİN DÖRT ROTORLU İHA KULLANILARAK TERMOGRAFI YÖNTEMİYLE DERİN ÖĞRENME TABANLI HATA TESPİT VE TEŞHİSİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Batıkan Erdem DEMİR .....  
Tez Danışmanı, Mekatronik Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Mekatronik Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 26/04/2021

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Prof. Dr. Raif BAYIR (KBÜ)	.....
Üye : Dr. Öğr. Üyesi Batıkan Erdem DEMİR (KBÜ)	.....
Üye : Dr. Öğr. Üyesi Aytaç ALTAN (BEÜ)	.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ .....  
Lisansüstü Eğitim Enstitüsü Müdürü

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

Barış KAYCI

## **ÖZET**

**Yüksek Lisans Tezi**

### **GÜNEŞ PANELLERİNİN DÖRT ROTORLU İHA KULLANILARAK TERMOGRAFI YÖNTEMİYLE DERİN ÖĞRENME TABANLI HATA TESPİT VE TEŞHİSİ**

**Barış KAYCI**

**Karabük Üniversitesi**

**Lisansüstü Eğitim Enstitüsü**

**Mekatronik Mühendisliği Anabilim Dalı**

**Tez Danışmanı:**

**Dr. Öğr. Üyesi Batıkan Erdem DEMİR**

**Nisan 2021, 95 sayfa**

Bu tez çalışmasında, güneş panellerinden elde edilen termal görüntüler kullanılarak panellerde oluşan hücre, modül ve panel hatalarının tespit edilmesi ele alınmıştır. Tez çalışması kapsamında dört rotorlu bir insansız hava aracı tasarlanmış ve araca termal kamera yerleştirilerek Karabük Üniversitesi Teknoloji Fakültesi binası üzerinde bulunan güneş panellerinin termal görüntüleri alınmıştır. Elde edilen termal görüntüler kullanılarak hücre hatası, modül hatası ve panel hatalarının olduğu bir termal veri seti oluşturulmuştur. Termal veri seti ile Yolov3 derin öğrenme tabanlı evrişimsel sinir ağı eğitilmiştir. Bu eğitim, gömülü yapay zeka özellikli bir bilgi işlem cihazı olan Nvidia Jetson TX2 cihazında gerçekleştirilmiştir. Yolov3 ağının eğitiminin tamamlanmasının ardından yapılan testlerde bahsedilen hataların başarıyla tespit edildiği sonucuna ulaşılmıştır.

**Anahtar Sözcükler :** Derin öğrenme, Yolov3 ağı, güneş paneli, termal kamera, hata tespit ve teşhis, İHA, termografi.

**Bilim Kodu** : 92906

## **ABSTRACT**

**M. Sc. Thesis**

# **DEEP LEARNING BASED FAULT DETECTION AND DIAGNOSIS OF SOLAR PANELS USING FOUR ROTOR UAV WITH TERMOGRAPHY METHOD**

**Barış KAYCI**

**Karabük University  
Institute of Graduate Programs  
Department of Mechatronic Engineering**

**Thesis Advisor:**

**Assist. Prof. Dr. Batıkan Erdem DEMİR**

**April 2021, 95 pages**

In this thesis, it is discussed to detect cell, module and panel errors in panels using thermal images obtained from solar panels. Within the scope of the thesis study, a four-rotor unmanned aerial vehicle was designed and a thermal camera was placed in the vehicle and thermal images of the solar panels on the Technology Faculty of Karabük University were taken. A thermal data set with cell error, module error and panel errors was created using the resulting thermal images. Yolov3 deep learning based convolutional neural network was trained with the thermal data set. This training was carried out on the Nvidia Jetson TX2 device, an embedded AI-enabled computing device. After the completion of the training of the Yolov3 network, it was concluded that the errors mentioned in the tests were successfully detected.

**Key Word** : Deep learning, Yolov3 network, solar panel, thermal camera, fault detection and diagnosis, UAV, thermography.

**Science Code** : 92906



## TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında şekillendiren sayın hocam Dr. Öğr. Üyesi Batıkan Erdem DEMİR'e sonsuz teşekkürlerimi sunarım.

Sevgili ailem annem Naciye KAYCI ve babam Yılmaz KAYCI'ya maddi ve manevi hiçbir yardımı esirgemedен yanımda oldukları için tüm kalbimle teşekkür ederim.

Bu zorlu süreçte yanımda olan ve yardımlarını esirgemeyen değerli arkadaşlarım Yük. Müh. Bahtiyar CERİT'e, Yük. Müh. Enes YİĞİT'e ve Müh. Furkan YALÇINKAYA'ya teşekkürü bir borç bilirim.

Yüksek lisans tez alıőmam, FYL-2019-2131 numaralı proje kapsamında Karabük Üniversitesi Bilimsel Araştırma Projeleri Komisyonu Birimi tarafından desteklenmiştir. Desteklerinden dolayı Karabük Üniversitesi Bilimsel Araştırma Projeleri Komisyonuna teşekkürlerimi sunarım.

## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ .....	xvi
SİMGELER VE KISALTMALAR DİZİNİ .....	xvii
BÖLÜM 1 .....	1
GİRİŞ .....	1
BÖLÜM 2 .....	5
LİTERATÜR ÇALIŞMASI.....	5
BÖLÜM 3 .....	9
FOTOVOLTAİK PANELLER VE PANELLERDEKİ ARIZALAR .....	9
3.1. FOTOVOLTAİK PANELLERİN TARİHÇESİ.....	9
3.2. FOTOVOLTAİK HÜCRENİN YAPISI .....	10
3.3. FOTOVOLTAİK HÜCRENİN ÇALIŞMASI.....	11
3.4. FOTOVOLTAİK HÜCRENİN SINIFLANDIRILMASI .....	13
3.4.1. Birinci Nesil.....	13
3.4.2. İkinci Nesil.....	13
3.4.3. Üçüncü Nesil .....	14
3.5. FOTOVOLTAİK PANEL YAPISI .....	15
3.6. FOTOVOLTAİK PANELLERDEKİ ARIZALAR.....	16
3.6.1. Kapsülleme Hatası .....	16
3.6.2. Arka Tabaka Yapışma Hatası .....	17

## Sayfa

3.6.3. Hücre Çatlaması.....	17
3.6.4. Ara Bağlantıların Kopması.....	18
3.6.5. Gölgeleme.....	18
3.6.6. Korozyon Hatası.....	19
3.6.7. Sıcak Nokta Hatası.....	19
3.6.8. Gerilim Kaynaklı Bozulma.....	20
3.6.9. Işık Kaynaklı Güç Bozulması.....	20
BÖLÜM 4.....	21
DÖRT ROTORLU İHA VE TERMAL KAMERALI SİSTEM.....	21
4.1. DÖRT ROTORLU İNSANSIZ HAVA ARACI.....	22
4.1.1. Dört Rotorlu İnsansız Hava Aracının Matematiksel Modellenmesi.....	25
4.1.1.1. Kinematik Model.....	26
4.1.1.2. Dinamik Model.....	27
4.1.2. Dört Rotorlu İnsansız Hava Aracının Donanımsal Yapısı.....	30
4.1.2.1. Dört Rotorlu İnsansız Hava Aracının Boyutsal Parametreleri.....	31
4.1.2.2. Dört Rotorlu İnsansız Hava Aracının Mekanik Yapısı.....	32
4.1.2.3. Dört Rotorlu İnsansız Hava Aracının Elektronik Donanımı.....	34
4.1.2.4. Dört Rotorlu İnsansız Hava Aracının Donanım Seçimi.....	40
4.1.2.5. Dört Rotorlu İnsansız Hava Aracının Yer İstasyonu ve Yazılımı.....	42
4.2. NVIDIA JETSON TX2 YAPAY ZEKA BİLGİSAYARI.....	43
4.3. FLIR DUO R TERMAL KAMERA.....	45
BÖLÜM 5.....	47
GÜNEŞ PANELLERİNİN TERMOGRAFI YÖNTEMİYLE DERİN ÖĞRENME TABANLI HATA TESPİT VE TEŞHİSİ.....	47
5.1. TERMOGRAFI.....	47
5.2. DERİN ÖĞRENME TABANLI GÖRÜNTÜ İŞLEME.....	48
5.2.1. Yapay Sinir Ağları.....	49
5.2.2. Makine Öğrenmesi.....	49
5.2.3. Derin Öğrenme.....	50
5.2.4. Derin Öğrenme Mimarileri.....	51

	<b><u>Sayfa</u></b>
5.2.4.1. Tekrarlayan Sinir Ağları .....	52
5.2.4.2. Uzun Kısa Süreli Bellek Ağları .....	52
5.2.4.3. Sınırlı Boltzmann Makineleri .....	53
5.2.4.4. Derin İnanç Ağları .....	54
5.2.4.5. Derin Oto Kodlayıcılar .....	54
5.2.4.6. Evrişimli Sinir Ağları.....	55
5.2.5. Derin Öğrenme Modelleri.....	60
5.2.5.1. LeNet Ağı.....	60
5.2.5.2. AlexNet Ağı .....	61
5.2.5.3. ZFNet Ağı .....	61
5.2.5.4. VGGNet Ağı .....	62
5.2.5.5. GoogLeNet Ağı.....	63
5.2.5.6. Microsoft ResNet Ağı.....	64
5.2.6. YoloV3 Ağı .....	65
5.2.6.1. YoloV3 Ağının Girişi .....	66
5.2.6.2. YoloV3 Ağında Nesne Tespiti.....	66
5.2.6.3. YoloV3 Ağında Sınır Çerçevesinin Tespiti .....	67
5.2.6.4. YoloV3 Mimarisi .....	69
5.3. DERİN ÖĞRENME TABANLI HATA TESPİT VE TEŞHİSİ .....	70
5.3.1. Veri Seti Oluşturulması .....	71
5.3.2. Veri Setinin Etiketlenmesi.....	73
5.3.3. Veri Setinin Eğitimi.....	74
BÖLÜM 6 .....	76
DENEYSEL ÇALIŞMALAR .....	76
6.1. DÖRT ROTORLU İNSANSIZ HAVA ARACI İLE UÇUŞ TESTLERİ.....	76
6.1.1. Dört Rotorlu İnsansız Hava Aracının Manuel Uçuş Testleri.....	77
6.1.2. Dört Rotorlu İnsansız Hava Aracının Otonom Uçuş Testleri.....	77
6.2. GÜNEŞ PANELLERİNDEKİ HATALARIN DERİN ÖĞRENME YÖNTEMİYLE TESPİT VE TEŞHİS DENEYLERİ .....	78
BÖLÜM 7 .....	87

	<b><u>Sayfa</u></b>
SONUÇLAR VE DEĞERLENDİRME .....	87
KAYNAKLAR .....	89
ÖZGEÇMİŞ .....	95

## ŞEKİLLER DİZİNİ

	<b><u>Sayfa</u></b>
Şekil 3.1. Geçiş bölgesi.....	10
Şekil 3.2. Fotovoltaik hücre çalışma prensibi.....	11
Şekil 3.3. Fotovoltaik hücre ve fotovoltaik panel.....	12
Şekil 3.4. Fotovoltaik panel ve fotovoltaik dizi.....	12
Şekil 3.5. PV modül katmanları.....	15
Şekil 3.6. Kapsülleme hatası.....	16
Şekil 3.7. Arka tabaka yapışma hatası.....	17
Şekil 3.8. Hücre çatlaması hatası.....	18
Şekil 3.9. Korozyon hatası.....	19
Şekil 4.1. Çalışmanın blok şeması.....	21
Şekil 4.2. X ekseninde sağ yönde yapılan hareket.....	23
Şekil 4.3. Y ekseninde yapılan ileri yönde yapılan hareket.....	23
Şekil 4.4. Z ekseninde saat yönünde yapılan hareket.....	24
Şekil 4.5. Yukarı ve aşağı yönlü hareket.....	24
Şekil 4.6. Dört rotorlu insansız hava aracı atalet ve gövde eksenleri.....	25
Şekil 4.7. Dört rotorlu insansız hava aracı üzerindeki kuvvetler.....	27
Şekil 4.8. Dört rotorlu insansız hava aracının teknik resmi.....	31
Şekil 4.9. Dört rotorlu insansız hava aracının SolidWorks tasarımı.....	32
Şekil 4.10. Gövdeye montajı yapılan karbon fiber borular.....	33
Şekil 4.11. Motor tutucu.....	33
Şekil 4.12. Montajı tamamlanan dört rotorlu insansız hava aracı.....	34
Şekil 4.13. Navio2 uçuş kontrol kartı.....	35
Şekil 4.14. FRISKY X8R kumanda alıcısı.....	35
Şekil 4.15. ALFA marka AWUS036ACH telemetri cihazı.....	36
Şekil 4.16. Tallysman Tw4721 GNSS anteni.....	36
Şekil 4.17. Matek marka güç dağıtım kartı.....	37
Şekil 4.18. Navio2 güç modülü.....	37
Şekil 4.19. EMAX marka BLHeli 25A model ESC.....	38
Şekil 4.20. SunnySky marka X3108S model 720kv BLDC motor.....	38

## Sayfa

Şekil 4.21. İki eksen gimbal.....	39
Şekil 4.22. Leopard Power marka 3S 11.1V 6200mAh 30C Li-po batarya.....	39
Şekil 4.23. Mission Planner programı.....	43
Şekil 4.24. Nvidia Jetson TX2 yapay zeka bilgisayarı.....	44
Şekil 5.1. Makine öğrenmesi teknikleri.....	49
Şekil 5.2. Derin öğrenme yapısı.....	50
Şekil 5.3. RNN yapısı.....	52
Şekil 5.4. LTSM yapısı.....	53
Şekil 5.5. RBM yapısı.....	53
Şekil 5.6. DBM yapısı.....	54
Şekil 5.7. Derin oto kodlayıcı yapısı.....	55
Şekil 5.8. Adım sayısı bire eşit olan sağa kayma örneği.....	56
Şekil 5.9. 4x4x1 boyutundaki giriş görüntüsünün konvolüsyon işlemi.....	57
Şekil 5.10. Tam bağlı katman yapısı.....	58
Şekil 5.11. Dropout yöntemi uygulanmamış ve uygulanmış yapay sinir ağı.....	59
Şekil 5.12. Örnek bir CNN yapısı.....	59
Şekil 5.13. LeNet mimarisi.....	60
Şekil 5.14. AlexNet mimarisi.....	61
Şekil 5.15. ZFNet mimarisi.....	62
Şekil 5.16. VGGNet mimarisi.....	62
Şekil 5.17. GoogLeNet mimarisi.....	63
Şekil 5.18. Inception modülü.....	64
Şekil 5.19. Residual blok yapısı.....	65
Şekil 5.20. YoloV3 ağının daha iyi tespit yapabilmesi için kullanılan 3 farklı boyutta tahmin.....	66
Şekil 5.21. Sınır çerçevesi içerik parametreleri.....	67
Şekil 5.22. Aynı nesneyi işaretleyen dört farklı sınır çerçevesi.....	68
Şekil 5.23. Farklı nesnelere ait sınır çerçeveleri.....	69
Şekil 5.24. YoloV3 mimarisi.....	70
Şekil 5.25. Panel hatası benzetimi.....	71
Şekil 5.26. Veri seti oluşturulurken kullanılan sistem.....	72
Şekil 5.27. Hücre hatası, modül hatsı ve panel hatasının benzetim görüntüsü.....	72
Şekil 5.28. Labeling veri etiketleme programı.....	73

## **Sayfa**

Şekil 6.1. Karabük Üniversitesi Teknoloji Fakültesi üzerinde bulunan güneş panelleri. ....	76
Şekil 6.2. Deneyleerde kullanılan ekipmanlar. ....	78
Şekil 6.3. Güneş panellerindeki hata tespit testi için oluşturulan otonom uçuş rotası.....	79
Şekil 6.4. Otonom uçuş rotası parametreleri.....	79
Şekil 6.6. Sağlam güneş panelinin görüntüsü. ....	82
Şekil 6.7. Hatalı güneş panelinin görüntüsü.....	82
Şekil 6.8. Güneş panelinde bulunan hücre hataları. ....	83
Şekil 6.9. Güneş panelinde bulunan hatalı sonuçlar. ....	83



## ÇİZELGELER DİZİNİ

### Sayfa

Çizelge 4.1. SunnySky marka X3108s model 720kv BLDC motor özellikleri. ....	40
Çizelge 4.2. 10x4.5” karbon pervane özellikleri.....	41
Çizelge 4.3. EMAX marka BLHeli model 25A ESC.....	41
Çizelge 4.4. Leopard Power marka 3S 11.1V 6200mAh 30C Li-po batarya.....	42
Çizelge 4.5. Nvidia Jetson TX2 yapay zeka bilgisayar teknik özellikleri. ....	44
Çizelge 4.6. FLIR marka DUO R model termal kamera teknik özellikleri. ....	46
Çizelge 6.1. Otonom uçuş sayısına göre gerçekleşen uçuş yüksekliği. ....	80
Çizelge 6.2. Deneysel çalışma sonucu oluşan hata matrisi.....	84
Çizelge 6.3. Yolov3 ağı başarımlar değerleri.....	86

## SİMGELER VE KISALTMALAR DİZİNİ

### SİMGELER

- a-Si : amorf silisyum  
C : kapasitenin x katı kadar akım miktarı  
CdTe : kadmiyum tellür  
 $F_T$  : toplam itki kuvveti  
GaAs : galyun arsenik  
 $H_i$  : hub kuvveti  
 $I_{xx}$  : x eksenindeki atalet momenti  
 $I_{yy}$  : y eksenindeki atalet momenti  
 $I_{zz}$  : z eksenindeki atalet momenti  
Li-Ion : lityum-iyon  
Li-Po : lityum-polimer  
mAh : bataryanın kapasite miktarını  
 $R_i$  : yuvarlanma momentini  
 $R_{x,y,z}$  : Rotasyon matrisi  
Si : silisyum  
S : bataryada kullanılan hücre sayısı  
 $T_i$  : pervanenin ürettiği itki kuvveti  
 $U_1$  : itki kuvvetini  
 $U_2$  : yuvarlanma kuvveti  
 $U_3$  : yunuslama kuvveti  
 $U_4$  : sapma kuvveti  
 $\Omega_i$  : pervanelerin açısal hızları  
 $\Theta$  : yunuslama açısı  
 $\Phi$  : yuvarlanma açısı  
 $\Psi$  : sapma açısı

## KISALTMALAR

- BLDC : Brushless Direct Current (Fırçasız Doğru Akım)
- CNN : Convolution Neural Network (Evrışimli Sinir Ağı)
- CPU : Central Process Unit (Merkezi İşlem Birimi)
- DAE : Deep Auto Encoder (Derin Oto-Kodlayıcılar)
- DBN : Deep Belief Network (Derin İnancı Ağları)
- DCNN: Deep Convolution Neural Network (Derin Evrişimli Sinir Ağı)
- ESC : Electronic Speed Controller (Elektronik hız denetleyicileri)
- EVA : Etilen Vinil Asetat
- FC : Fully Connected (Tam Bağlı Katman)
- GPS : Global Position System (Küresel Konumlandırma Sistemi)
- GPU : Graphics Processing Unit (Grafik İşlem Birimi)
- IMU : Inertial Measurement Unit (Ataletsel Ölçü Birimi)
- IoU : Interection Over Union (Birlik Üzerinden Kesişme)
- İHA : İnsansız Hava Aracı
- LTSM : Long Short-Term Memory Neural Network (Uzun Kısa Vadeli Hafıza Ağları)
- NMS : Non-Maximal Suppression (Maksimum Olmayan Baskı Eşiği)
- PV : Fotovoltaik (Photovoltaic)
- PVF : Polyvinyl Fluoride Film (Polivinil Florid Film)
- PWM : Pulse Width Modulation (Darbe Genişlik Modülasyonu)
- RBM : Restricted Boltzmann Machines (Sınırlı Boltzmann makineleri)
- ReLu : Rectified Linear Unit (Doğrusallaştırılmış Lineer Birim)
- RNN : Recurrent Neural Network (Tekrarlayan Sinir Ağı)
- UAV : Unmanned Aerial Vehicle (İnsansız Hava Aracı)
- USB : Universal Serial Bus (Evrensel Seri Veriyolu)

## BÖLÜM 1

### GİRİŞ

Sanayi devriminin ardından daha fazla değer kazanan enerji, ülkelerin kalkınması ve bireylerin yaşam kalitelerini yükseltmeyi sağlayan ana etkenlerdendir. Hızla artan nüfusla ve gelişen teknolojiyle hayatın her alanında kullanılan enerji, yaşantımızda öncelik bakımından üst sıralarda bulunmaktadır. Bundan dolayı enerjinin tüketimi ve üretimi önemli bir hale gelmiştir. Enerjinin üretimi sırasında fosil kaynakların kullanılması çevre kirliliğine sebep olmaktadır. İnsan sağlığının kötü etkilenmesi, enerji ihtiyacının artması ve fosil kaynakların azalmasından ötürü yeni enerji kaynakları aranmaktadır. Bu da enerjinin üretiminde yenilenebilir kaynakların kullanılması fikrini ortaya çıkarmıştır [1]. Yenilenebilir enerji kaynakları; rüzgâr, hidroelektrik, jeotermal ve güneş enerjisi olarak sınıflandırılmaktadır. Güneş enerjisi dünyamızdaki en büyük yenilenebilir enerji kaynaklarından biridir. Güneş enerjisi ile güneş kolektörleri vasıtasıyla çeşitli ısıtma uygulamalarının yapılabildiği gibi güneş panelleri vasıtasıyla elektrik enerjisi de üretilebilmektedir [2]. Fotovoltaik sistemlerle güneşin bulunduğu her yerde elektrik enerjisi üretilebilir. Fotovoltaik sistemlerin düşük verimi ve yüksek kurulum maliyetleri fotovoltaik sistemlerin dezavantajlarındandır. Fotovoltaik sistemlerdeki verim kayıplarını engellemek için fotovoltaik sistemlerin bakımlarının düzenli aralıklarla yapılması gerekmektedir. Özellikle sayıca fazla olan fotovoltaik panellerin testlerini tek tek yapmak oldukça zahmetli, zaman alıcı ve yüksek maliyetlidir. Bu yüzden fotovoltaik panellerin testlerinin daha kolay ve hızlı yapılabilmesi için termografi yöntemi kullanılmaktadır.

Termografi, enerji sektöründe özellikle de fotovoltaik sistemlerde hata analizi için kullanılan bir yöntemdir [3]. Termografi ölçümleri fotovoltaik modüle uygulanan harici bir akım veya ışık kaynağının neden olduğu sıcaklık farklılıklarını göstermektedir [4]. Bu sıcaklık farklılıkları termal kameralar aracılığıyla tespit edilmektedir. Bir termal kamera temelde her bir karede veya art arda gelen karelerde

radıyometrik sıcaklık verisi bulunduran bir video kayıt cihazıdır [3]. Fotovoltaik panellerin termal kamera aracılıđıyla termal görüntüsü incelenerek fotovoltaik panellerin kondüsyonu hakkında çıkarımlar yapılabilmektedir. Bu çıkarımların yapılması için termal görüntülerin uzman kişilerce analiz edilmesi gereklidir. Bu analizlerin maliyeti oldukça yüksektir. Bu çıkarımların maliyetini düşürmek için bilgisayar tabanlı yazılımların geliştirilmesi gerekmektedir. Geliştirilecek yazılımların termal görüntülerdeki arızaları tanınması ve arızaların sebeplerini bildirmesi gerekmektedir. Arızaların tespiti ve teşhisinde yapay zekadan faydalanılması yazılımın başarı oranını arttırmaktadır.

Yapay zekâ, bir görevin yapılması sırasında makinaların insan zekasını taklit etmesi olarak adlandırılabilir. Yapay zekada görevler yerine getirilirken, bilgiler toplanarak sistem kendini iyileştirmektedir. Yapay zekâ teknikleri olarak uzman sistemler, yapay sinir ağları, genetik algoritmalar, bulanık mantık, makine öğrenmesi, derin öğrenme gibi teknikler sistemlerin işlevselliklerini artırmakta ve insan hayatına kolaylıklar sağlamaktadırlar. Bu tekniklerden yapay sinir sağları insanlardaki öğrenme davranışını taklit etmektedir. Sistem tanıtılan örneklere göre durumlar arasındaki bağlantıyı kurmakta ve hiç görmediđi örnekler hakkında daha önceden kurulan bağlantıya göre sonuç üretmektedir [5]. Bu sayede yazılım farklı fotovoltaik panellerdeki hataları tespit edebilmektedir. Termal görüntülerin alınması sırasında insana dayalı iş gücünün kullanılması özellikle çok sayıdaki fotovoltaik panellere sahip sistemlerde uzun zaman almaktadır. Termal görüntülerin hızlı ve hatasız bir şekilde elde edilmesi için insansız hava araçları kullanılmaktadır.

Günümüzde teknolojinin gelişmesi ile tehlikeli veya hassas görevlerde insansız sistemler kullanılmaya başlanmıştır. İnsansız araçlar kullanım alanlarına göre kara, hava ve deniz olmak üzere üç ana gruba ayrılırlar. Bu grupta olan insansız hava araçları, bir İHA pilotu tarafından kontrol edilebilen veya içerisine önceden yüklenmiş olan uçuş programını takip ederek otonom olarak hareket edilebilen, üzerinde bir itki sistemi bulunan, gövdesi üzerine yerleştirilen çeşitli elektronik ekipman içeren ve yapacağı göreve göre faydalı yük taşıyabilen hava araçlarına verilen genel bir isimdir [6]. İnsansız hava araçları kullanım alanlarına göre sivil ve askeri alan olmak üzere ikiye ayrılırlar. Sivil alanlarda, tarım, havadan görüntüleme, sivil taşımacılık,

akademik çalışmalar olmak üzere çeşitli kullanım alanları bulunmaktadır. Askeri alanlarda, keşif ve gözetleme, saldırı, hedef benzetimi, elektronik harp ve özel görevler olmak üzere çeşitli alanlarda kullanılmaktadır [7]. Teknik özelliklerine göre sınıflandırılan insansız hava araçları sabit kanat ve döner kanat olmak üzere ikiye ayrılmaktadırlar. Sabit kanatlı insansız hava araçları uçaklara benzer yapıdadırlar. Uçaklardaki gibi kalkış ve iniş yapabilmek için bir piste ihtiyaç duyarlar. Ayrıca uçaklardaki gibi geniş ve uzun kanat yapısı vardır. Bu kanat yapısından dolayı fazla ağırlıkla az enerji harcayarak uzun uçuş sürelerine ulaşabilmektedirler. Fakat bu kanat yapılarından dolayı manevra kabiliyetleri daha düşüktür. Döner kanatlı insansız hava araçlarının dikey olarak kalkış ve iniş yapabilmek, havada sabit bir şekilde durabilme ve hızlı manevra yapma gibi özelliklere sahiptir. Buna karşın karmaşık ve zor kontrol edilebilmesi ve sabit kanatlı insansız hava araçlarına göre daha az yük kapasitesi ve daha az uçuş süresi gibi dezavantajları vardır [8]. Döner kanatlı İHA'lar 3, 4, 6 veya 8 rotorlu olabilmektedirler. Döner kanatlı insansız hava araçları rotor sayısına göre isimlendirilmektedir. Üç rotorlu İHA'lar tri rotor, dört rotorlu İHA'lar quadrotor, altı rotorlu İHA'lar hexarotor ve sekiz rotorlu olan İHA'lar octorotor olarak isimlendirilmektedir [9].

Bu tezin amacı insansız hava aracı ile derin öğrenme yaklaşımı kullanarak güneş panellerinin sağlamlık kontrolünün yapılmasıdır. Bu çalışmada insansız hava aracı ile güneş panellerinin termal görüntüleri alınarak güneş panelleri üzerindeki hatalar ve hataların sebeplerinin tespiti yapılacaktır. Hata veya hataların tespit edilebilmesi için derin öğrenme tabanlı veri seti eğitimi yapılmıştır. Bu çalışmada Nvidia Jetson TX2 geliştirme kartı kullanılarak termal kamera ile elde edilen güneş paneli görüntülerindeki hataları tespit ve teşhis eden bir ağ geliştirilmiştir.

Bu tez çalışması ile bir insansız hava aracı kullanılarak fotovoltaik panellerin sağlamlık kontrolü çok daha kısa zamanda ve düşük maliyetlerle yapılabilecektir. Geliştirilen yazılım ile fotovoltaik panellerde hata veya hataların tespiti ve hataların neden kaynaklandığı sorusunun cevapları alınabilmektedir.

Bu tez çalışmasının ikinci bölümünde literatürde yapılmış çalışmalara yer verilmiştir. İnsansız hava aracı ve derin öğrenme hakkında yapılmış akademik çalışmalar yer

almaktadır. Tez çalışmasının üçüncü bölümünde güneş panelleri açıklanmakta ve güneş panellerinde oluşan hatalar hakkında bilgiler verilmektedir. Tezin dördüncü bölümünde güneş panellerinin termal görüntülerinin elde edilmesinde kullanılan dört rotorlu İHA ve termal kamera ve Nvidia Jetson TX2 yapay zeka bilgisayarı açıklanmaktadır. Beşinci bölümde güneş panellerinden elde edilen termal görüntülerin incelenmesinde kullanılan termografi yöntemi, güneş panellerindeki hataların tespit ve teşhisinde kullanılan derin öğrenme yöntemi ve derin öğrenmede kullanılmak üzere oluşturulan veri seti ve eğitimi açıklanmaktadır. Altıncı bölümde yapılan deneysel çalışmalar açıklanmaktadır. Sonuçlar ve değerlendirme bölümünde çalışmanın performansı ile ilgili yorumlara yer verilmektedir. Ayrıca bu konuda gelecekte yapılacak çalışmalar için önerilere yer verilmektedir.

## BÖLÜM 2

### LİTERATÜR ÇALIŞMASI

Fotovoltaik panellerde oluşan hatalar, fotovoltaik sistemlerin ürettiği gücü düşürmektedir. Fotovoltaik sistemlerdeki güç kayıplarını engellemek için hatalı panellerin tespit edilmesi gerekmektedir. Hatalı fotovoltaik panellerin tespitinde elektriksel, görsel veya termal yöntemler kullanılmaktadır. Bu yöntemlerle alakalı uluslararası alanda çeşitli akademik çalışmalar yapılmaktadır.

Fotovoltaik panellerde termal görüntü analizi alanında yapılan akademik çalışmalar çerçevesinde, Higuchi ve Babasaki'nin yapmış oldukları çalışmada arızalı güneş panellerini tespit etmek için çeşitli yöntemleri karşılaştırmışlardır. Bu yöntemlerden en verimlisinin İHA ile yapılan yöntem olduğunu keşfetmişlerdir. İHA ile çeşitli panel arızalarını içeren termografik görüntüleri elde ederek bu görüntüleri derin öğrenme metodu ile incelemektedirler. İHA olarak DJI marka Inspire 1 model İHA kullanılmıştır. Termal kamera olarak DJI marka Zenmuse-xt model termal kamera kullanılmıştır. Derin öğrenme metodu olarak SSD (Single Shot MultiBox Detector - Tek Atış Çoklu Kutu Algılama) metodunu kullanmışlardır. Yapılan çalışma sonucunda %49,11'lik başarı oranı elde edilmiştir [10].

Pierdicca ve ekibi yapmış oldukları çalışmada güneş panellerinin arızalarını tespit etmek için derin öğrenme metodu kullanmışlardır. Derin öğrenme metodu olarak DCNN (Deep Convolution Neural Network - Derin Konvolüsyon Sinir Ağları) kullanmışlardır. DCNN hücrelerin bozulması hakkında bilgi vermeyi amaçlamaktadır. Görüntülerdeki anormalliği tespit gösteren resimleri etiketlemişler ve VGG-16 ağı ile eğitim gerçekleştirmişlerdir. Eğitilen ağın başarı oranı %70 olarak ölçülmüştür. Yapılan çalışmayla birlikte "Fotovoltaik Görüntü Veri Seti" oluşturulmuştur. Yapılan çalışmada Sky Robotic marka SR-SF6 model İHA ve Flir marka TAU2 model termal kamera kullanılmıştır [11].



Carletti ve ekibi yapmış oldukları çalışmada arızalı güneş panellerini tespit etmek için model tabanlı bir yaklaşım önermektedirler. Bu yaklaşım renk bilgilerini kullanmadan tesisin yapısal özelliklerini çıkararak, değişken hava ve aydınlatma koşullarında güneş panellerini tespit etmektedir. Tespit edilen panellerde küresel sıcak nokta algılama tekniği kullanılarak, görüntülerdeki sıcak noktanın geçmişini göz önünde bulundurularak olası hata hakkında nihai karar veren algoritma geliştirmişlerdir [12].

Li ve ekibi yaptıkları çalışmada büyük ölçekli güneş paneli tarlalarının denetimi sırasında modüllerin operasyonel durumunu değerlendirmek için derin öğrenme tabanlı hata teşhis işlevine sahip bir sistem geliştirmektedirler. Geliştirilen bu sistemde derin öğrenme metodu olarak CNN (Convolutional Neural Network - Evrişimli Sinir Ağları) tabanlı bir yapı kullanılmaktadır. Çalışmanın sonucunda toz, gölgelenme, enkapsülan, delaminasyon, ızgara çizgisi korozyonu, salyangoz izleri ve sararma hatalarının tespiti yapılmaktadır. Yapılan bu çalışmada DJI marka Matrix 100 model İHA ve DJI marka Zenmuse X3 model kamera kullanılmıştır [13].

Wei ve ekibi yaptıkları çalışmada güneş panellerindeki sıcak nokta ve yansıtıcı bölge hatalarını tespit etmek için iki yaklaşım önermektedir. Klasik dijital görüntü işleme teknolojisi, sıcak noktaları tespit etmek için esas olarak Hough hat dönüşümü ve Canny operatörünü kullanmaktadır. Yansıtıcı bölge hataları ise klasik dijital görüntü işleme yöntemiyle tespit edilmesinin zor olmasından ötürü yansıtıcı hatalarının tespiti için Faster-RCNN derin öğrenme metodu kullanmaktadır. Yapılan çalışma sonucunda klasik dijital görüntü işleme başarımları %89,96, Faster-RCNN derin öğrenme metoduyla %95,15 başarımları elde edilmektedir [14].

Akram ve ekibi yaptıkları çalışmada termal görüntülerdeki güneş paneli kusurlarının izole derin öğrenme ve geliştirme model transfer derin öğrenme teknikleri kullanılarak otomatik tespiti yapılmaktadır. Normal çalışan ve arızalı modüllerin termal görüntülerini içeren bir termal veri seti toplanmakta ve toplanan verilerle ağların eğitimi yapılmaktadır. İzole edilmiş öğrenilmiş bir model, ortalama %98,67 doğruluk sağlayan bir CNN kullanılarak sıfırdan eğitilmektedir. Transfer öğreniminde ise temel bir model kullanılarak %99,23 doğruluk elde edilmektedir [15].

Diaz ve ekibi yapmış oldukları çalışmada İHA üzerine takılan bir termal kamera ile güneş panellerinin otomatik arıza teşhis yöntemi önermektedirler. Bu çalışmada ilk olarak İHA ile alınmış termal görüntülerdeki güneş panelinin tespiti yapılmaktadır. Güneş panellerinin tespitinde biri klasik diğeri derin öğrenme tabanlı iki yöntem kullanılmaktadır. İlk yöntemde birkaç ön işleme tekniği kullanılarak termal görüntülerin düşük kontrastı düzeltilmektedir. İkinci yöntemde ise güneş panelini tanımlamak için R-CNN tabanlı sinir ağı kullanılmaktadır [16].

Herraiz ve ekibi yaptıkları çalışmada İHA'ya yerleştirilmiş bir termal kameradan gelen verileri kullanarak güneş panellerindeki arızaların tespiti için bir metodoloji sunmaktadır. Sıcak noktaları tespit etmek, güneş panellerini ve panellerin yerlerini belirlemek için R-CNN tabanlı bir algılama yapısı oluşturulmaktadır. Çalışmanın sonucunda %91,67 başarı oranıyla sıcak noktaların tespiti yapılmıştır. Bu çalışmada DJI marka S900 model İHA ve WORKSWELL marka WIRIS model termal kamera kullanılmaktadır [17].

Henry ve ekibi yaptıkları çalışmada bir güneş paneli tarlasındaki arızalı güneş panellerinin otomatik tespiti ve lokalizasyonu için otonom bir İHA tabanlı termografi sistemi önerilmektedir. İHA sisteminde termal ve gündüz kameradan oluşan çift kamera kullanılmaktadır. Önerilen İHA sistemi otomatik uçuş rotası planlama algoritmaları kullanılarak manuel kontrole ihtiyaç duymadan otonom olarak uçuş yapmaktadır. Buna ek olarak sistem, hatalı güneş panellerinin konumunu tam olarak tespit etmektedir. Yapılan çalışmada FLIR marka Vue Pro R model termal kamera ve yazarların kendi geliştirdiği bir İHA kullanılmaktadır [18].

Xie ve ekibi yapmış oldukları çalışmada güneş panelindeki anormallikleri tespit etmek için İHA'dan alınan görüntülerin görüntü işleme operatörlerinden, Sobel operatörü ve Canny operatörünü kullanarak inceleme yapan bir algoritma geliştirilmiştir. Derin öğrenme metodu uygulanarak güneş panellerindeki arızalar tespit edilmektedir. Bu çalışmada Sobel operatörü, görüntüdeki güneş panellerini tespit etmek amaçlı olarak kullanılmıştır. Canny operatörü, Sobel operatörünü tamamlayıcı olarak daha küçük boyutlu güneş panellerini tespit etmek için kullanılmıştır. Derin öğrenme metodu olarak CNN kullanılmıştır. Derin öğrenme metodu kullanılarak görüntülerdeki güneş

paneli hatalarını tespit edilmektedir. Yapılan çalışmalar sonucu %90,91 başarı elde edilmiştir [19].

Venkatesh ve Sugumaran'ın yapmış oldukları çalışmada güneş panellerindeki hataları CNN derin öğrenme metoduyla tespit etmektedirler. Yapılan çalışma VGG-16 ağı kullanılarak eğitim gerçekleştirilmiştir. Çalışmada 6 adet panel arıza sınıflandırması dikkate alınmaktadır. Bunlar, yanık izleri, delaminasyon, renk bozulması, cam kırılması, salyangoz izi ve sağlam paneldir. Yapılan çalışmanın sonucunda %95,4 sınıflandırma başarısı elde edilmektedir [20]

Kaycı ve Demir'in yapmış oldukları çalışmada güneş panellerindeki hataların tespit ve teşhisinde derin öğrenme metodu kullanılmaktadır. Derin öğrenme metodu olarak Yolov3 ağı kullanılmaktadır. Yapılan çalışmada FLIR marka DUO R termal kamera kullanılarak termal veri seti oluşturulmuştur. Termal veri seti kullanılarak Yolov3 ağının eğitimi Nvidia Jetson TX2 yapay zeka bilgisayarında eğitilmektedir. Yapılan çalışmada hücre hatası, panel hatası ve modül hatası olmak üzere 3 adet panel hatası tespit edilmektedir [21].

Bu tez çalışmasında güneş panellerinin termal görüntülerinin elde edilmesi için Dört rotorlu İHA tasarlanmakta ve üretilmektedir. Bunun yanı sıra güneş panellerindeki hataların tespit ve teşhisinde Yolov3 ağı kullanılmaktadır. Ayrıca hataların tespit ve teşhisinin yapılmasında ve Yolov3 ağının eğitiminde Nvidia Jetson TX2 yapay zeka bilgisayarı kullanılmaktadır. Literatürde daha önce Nvidia Jetson TX2 yapay zeka bilgisayarı ile termal görüntülerde hata tespit ve teşhisi bulunmamaktadır. Tez çalışmasının bu özellikleri literature yenilik getirmektedir. Bunun yanı sıra güneş panellerinin termal görüntülerinin alınmasında İHA kullanılması ve güneş panellerindeki hataların termal görüntüye bağlı olarak tespit ve teşhis edilmesi, sanayi odaklı çalışmalara da katkı sağlamaktadır.

## BÖLÜM 3

### FOTOVOLTAİK PANELLER VE PANELLERDEKİ ARIZALAR


Güneş panelleri, güneş enerjisini elektrik enerjisine dönüştüren sistemlerdir. Fotovoltaik (Photovoltaic – PV) panel olarak da adlandırılan güneş panelleri hücrelerden oluşmaktadır. Fotovoltaik hücre bir diğer adıyla güneş pili, yarı iletken bir diyot gibi çalışmakta ve güneş ışınlarını elektrik enerjisine çevirmektedir.

#### 3.1. FOTOVOLTAİK PANELLERİN TARİHÇESİ

1839 yılında Edmond Becquerel, iki metal elektrottan oluşan bir elektrolitik hücre ile deneyler yaparken fotovoltaik etkiyi keşfetmiştir. Bu deneyin sonucunda bazı maddelerin özellikle de platinin, güneş ışınlarına maruz kaldığında küçük miktarlarda elektrik akımı ürettiğini gözlemlemiştir. 1873 yılında İngiliz mühendis Willoughby Smith, yüzeyin aydınlatılmasının ardından elektriksel iletkenliğini değiştiren selenyumun elementinin foto iletkenliğini keşfetmiştir. On yıl sonra Charles Fritts, pratik uygulamalar için selenyum kullanarak %1 verime sahip ilk güneş pilini icat etmiştir. 1941 yılında Russel Ohl selenyumdan daha verimli olan ilk silikon güneş pilini üretti ve patentini almıştır. Rusell Ohl'nin bu buluşu Bell laboratuvarında çalışan Gerald Pearson, Calvin Fuller ve Daryl Chapin tarafından geliştirildi. Bu gelişim sonucunda bir radyo vericisine yeterli enerjiyi sağlayabilen ilk fotovoltaik hücre üretilmiştir. Birkaç yıl içinde verimi %15 olan silikon bazlı fotovoltaik hücreler geliştirildi [22]. Fotovoltaik panellerin ilk uygulaması 1958 yılının mart ayında ilk güneş enerjisi ile çalışan Vanguard 1 uydusunda yapılmıştır [23]. 1973 yılında meydana gelen petrol krizinden dolayı alternatif enerji kaynaklarına olan ilgi artmıştır. Bundan dolayı fotovoltaik hücrelerle ilgili çalışmalar artarak, fotovoltaik hücrelerin üretimi hızlandırılmıştır. 1985 yılında New South Wales Üniversitesinde %20 verimlilikle çalışan fotovoltaik hücreler geliştirilmiştir. 2000'li yıllarda yapılan çalışmalarla fotovoltaik hücrelerin verimi %40'a kadar yükseltilmiştir [24].

### 3.2. FOTOVOLTAİK HÜCRENİN YAPISI

Günümüzde kullanılan çoğu elektronik ürünler gibi fotovoltaik hücreler de yarı iletken maddelerden yapılmaktadırlar. Fotovoltaik hücre üretmek için en elverişli olan maddeler silisyum, galyum arsenit, kadmiyum tellürdür. Fotovoltaik hücrelerde kullanılan yarı iletkenlerin enerji dönüşümünü gerçekleştirebilmesi için p veya n tipi olarak katkılanmaları gerekmektedir. Bu katkılama işleminde yarı iletkeninin p veya n tipi olmasını katkı maddesi belirlemektedir [25]. Katkı maddesinin eklenmesiyle oluşan p tipi yarı iletkenlerde elektron eksikliği oluşur ve buna “hol” denilmektedir. Bundan dolayı P tipi yarı iletkenlerin pozitif yüke sahip olduğu kabul edilir. N tipi yarı iletkenlerde ise katkı maddesinin eklenmesinden sonra elektron fazlalığı oluşur ve bu durumda n tipli yarı iletken negatif olarak yüklenir [26].




Şekil 3.1. Geçiş bölgesi.

P ve n tipi yarı iletkenlerin bir araya gelmesiyle yarı iletken eklemler oluşmaktadır. P ve n tipi yarı iletkenlerin birleştirilmeden önceki elektriksel durumları nötrdür. PN eklemine güneşten gelen fotonlar düştüğünde n tipindeki yarı iletken p tipi yarı iletkene doğru elektron geçişi olmaktadır. Bu geçiş her iki tarafın elektriksel yük dengesinin oluşmasına kadar devam etmektedir. PN eklem bölgesinde p bölgesinde negatif n bölgesinde pozitif yükler birikmektedir. Bu yük birikmesiyle oluşan bölgeye “yükten arındırılmış bölge” veya “geçiş bölgesi” denilmektedir. Şekil 3.1’de geçiş bölgesi verilmiştir [5]. Pozitif ve negatif yüklerin birikmesinden dolayı bir elektrik alan oluşmaktadır. Bu alanın adına “yapısal elektriksel alan” denilmektedir [27].


### 3.3. FOTOVOLTAİK HÜCRENİN ÇALIŞMASI

Güneş enerjisini elektrik enerjisine dönüştürmek için fotovoltaik hücreler kullanılmaktadır. Fotovoltaik hücrelerin enerji dönüşümünü gerçekleştirebilmesi için iki aşamalı fotovoltaik dönüşümün gerçekleşmesi gerekmektedir. İlk aşamada güneşten gelen fotonlar PN eklem bölgesine ulaştığında elektron-hol çiftlerini oluştururlar. İkinci aşamada ise oluşturulan elektron-hol çiftleri birbirinden ayrılarak enerji dönüşümünü gerçekleştirmiş olurlar [25].




Şekil 3.2. Fotovoltaik hücre çalışma prensibi.

Fotovoltaik hücrenin üzerine düşen foton üst tabakadan geçerek PN eklem bölgesine gelmektedir. Eklem bölgesine düşen foton burada elektronları uyarmaktadır. Uyarılan negatif yüklü elektronlar, pozitif yüklü boşluk bırakarak çoğunlukta oldukları bölgelere hareket ederler. Bu şekilde negatif (-) yüklü elektronlar n tipi yarı iletken, pozitif (+) yüklü boşluklar p tipi yarı iletken toplanmaktadır. Bu toplanma iki yarı iletken arasında bir gerilim üretmektedir [25]. Fotovoltaik hücrenin bir elektrik devresine bağlanmasıyla toplanan elektronlar n tipi yarı iletken p tipi yarı iletken doğru tek yönlü hareket ederler. Bu da doğru akımı (DA) oluşturur [28]. Şekil 3.2’de bir fotovoltaik hücrenin çalışma prensibi gösterilmiştir.



Şekil 3.3. Fotovoltaik hücre ve fotovoltaik panel.

Bir fotovoltaik hücreden elde edilen enerjinin az olmasından ötürü bir güneş panelinde birden fazla fotovoltaik hücre kullanılmaktadır. Fotovoltaik hücrelerin seri veya paralel bağlanmasıyla modüller, modüllerin kendi arasında birleştirilmesiyle fotovoltaik paneller oluşturulmaktadır. Şekil 3.3'te fotovoltaik hücre ve panel gösterilmiştir. Fotovoltaik paneller birbirlerine seri veya paralel bağlanarak PV dizilerini oluştururlar. PV dizilerinin oluşturulmasıyla yüksek güçte elektrik enerjisinin üretimi gerçekleştirilebilmektedir [29]. Şekil 3.4'te fotovoltaik panel ve fotovoltaik dizi gösterilmiştir.



Şekil 3.4. Fotovoltaik panel ve fotovoltaik dizi.

### 3.4. FOTOVOLTAİK HÜCRENİN SINIFLANDIRILMASI

Fotovoltaik hücreler sınıflandırılırken üretim sırasında kullanılan malzemelere göre sınıflandırılabileceği gibi kullanılan teknolojiye göre de sınıflandırılabilmektedir. Teknolojik gelişmeye göre göre; birinci nesil (kristal silisyum, galyum arsenik), ikinci nesil (ince film) ve üçüncü nesil (organik boya duyarlı, organik polimer) olmak üzere üç sınıfta incelenebilmektedir.

#### 3.4.1. Birinci Nesil

Birinci nesil fotovoltaik hücrelerin üretiminde silisyum (Si) ve galyum arsenik (GaAs) kullanılmaktadır. Silikon olarak da bilenen silisyumun, hammadde sıkıntısının olmaması, kristal yapısının dayanıklı olması ve zehirli bir madde olmamasından dolayı fotovoltaik hücrelerin üretiminde sıklıkla kullanılmaktadır. Kristal silisyum, tek kristal silisyum (mono-crystalline) ve çoklu kristal silisyum (poly-crystalline) olmak üzere iki çeşidi bulunmaktadır. Tek kristal silisyumdan üretilen fotovoltaik hücrelerin verimi %15 ile %20 arasındadır. 20 yıllık çalışma süresi sonrasında fotovoltaik hücrenin verimi %7 azalmaktadır. Üretiminde saf kristaller kullanıldığı için üretim maliyeti yüksektir. Çoklu kristal silisyumdan üretilen fotovoltaik hücrelerin verimi %12 ile %16 arasındadır. Üretiminde homojen kristal yapı kullanılmadığından üretim maliyeti ucuzdur. 20 yıllık çalışma süresi sonrasında verimi %14 azalmaktadır. Galyum arsenik yapısı kullanılarak üretilen fotovoltaik hücreler galyum ve arsenik elementlerinden oluşmaktadır. Silisyuma göre daha ince yapılıdır. Yeryüzünde galyum elementi silisyum elementi kadar çok bulunmadığından fotovoltaik hücrelerin üretiminde daha az tercih edilmektedir. GaAs kullanılarak üretilen fotovoltaik hücrelerin radyasyona ve sıcaklığa karşı dayanıklı olması sebebiyle daha fazla uzay uygulamalarında kullanılmaktadır. GaAs yapılı fotovoltaik hücrelerin verimi %22 ile %25 arasındadır [30].

#### 3.4.2. İkinci Nesil

İkinci nesil olarak adlandırılan ince film yapılı fotovoltaik hücreler, geniş yüzeylerin üzerine yarı iletkenin kaplanmasıyla elde edilmektedir. Geniş yüzey üzerine kaplanan



yarı iletkenin kalınlığı bir milimetre ile milimetrenin milyonda biri aralığında olduğundan ince film yapıllı fotovoltatik hücreler esnek bir yapıya sahiptirler. Birinci nesil fotovoltatik hücrelerle karşılaştırıldıklarında, kalınlık olarak daha ince olmalarına karşın güneş ışını absorpsiyonu katsayısı daha fazladır. Bunu güneş ışını emilimi daha yüksek olan maddeler kullanılarak sağlamaktadırlar. İnce film fotovoltatik hücrelerin güneş ışını emme oranı çok yüksek olmasına karşın fotovoltatik hücrenin çıkış akımı düşüktür. Cam, paslanmaz çelik, plastik gibi birçok malzeme üzerine ince film yapıllı fotovoltatik hücreler kaplanabilmektedir. İnce film yapıllı fotovoltatik hücrelerin verimi %5 ile %8 arasındadır [31]. Bu hücrelerde daha çok amorf-silisyum (a-Si), kadmiyum tellür (CdTe) ve bakır, iridyum ve selenyum elementlerinin birleşmesiyle oluşan CuInSe<sub>2</sub> (CIS) kullanılmaktadır [30].


### 3.4.3 Üçüncü Nesil

İnorganik malzemelerle üretilen fotovoltatik hücreler teknolojik açıdan gelişmiş olsalar da üretim maliyetleri son derece yüksektir. Bu sebeple araştırmacılar, inorganik fotovoltatik hücrelerin yerini alabilecek organik ve polimer yapıllı fotovoltatik hücreler üzerine yönelmişlerdir. Üretimleri sırasında çevreye daha az zarar vermesi, hafif ve esnek bir yapıya sahip olmaları ve üretim maliyetlerinin düşük olması üçüncü nesil fotovoltatik hücrelerin avantajlarındandır. Fakat inorganik fotovoltatik hücrelere göre çok daha düşük verime sahip olduklarından inorganik fotovoltatik hücrelerin yerini alabilecek konuma yükselememiştir [32].

Üçüncü nesil fotovoltatik hücreler boya duyarlı fotovoltatik hücreler ve organik fotovoltatik hücreler olmak üzere iki sınıfta incelenmektedir. Boya duyarlı fotovoltatik hücreler fotosentezden esinlenerek geliştirilmiştir. Güneş ışığının soğurulmasıyla boya duyarlı fotovoltatik hücreler içlerinde bulunan boyar maddeler aracılığıyla enerji üretmektedir. Organik fotovoltatik hücreler, iki metal arasına yerleştirilen organik malzemeler kullanılarak üretilmektedir. Yarı iletken polimerlerin kullanılması organik fotovoltatik hücrelerin istenilen özelliğe göre değiştirilebilmeleri, üretimin ucuz ve kolay olmasını ve fotovoltatik hücrenin hafif olmasını sağlamaktadır [30].

### 3.5. FOTOVOLTAİK PANEL YAPISI

PV panellerin uzun yıllar boyunca çeşitli iklim şartlarında çalışmasını sağlamak için endüstriyel kapsülleme uygulamaları kullanılmaktadır. Kapsülleme ile PV hücrelerden oluşturulmuş yapı darbelerden, nemden ve oksitlenmeden korunmakta ve yapının elektriksel izolasyonu da sağlanmaktadır. PV paneller, en üst katmanda güneş ışınının geçişine izin veren cam, ikinci katmanda EVA, üçüncü katmanda PV hücre, dördüncü katmanda EVA ve en alt katmanda arka levha olmak üzere beş katmandan oluşmaktadır. PV panellerin en üst katmanında 2mm veya 3mm kalınlığında temperlenmiş beyaz cam kullanılmaktadır. Cam sayesinde pv hücre darbelerle karşı korunmaktadır. İkinci ve dördüncü katmada kullanılan EVA (Etilen Vinil Asetat) kapsülleme malzemesi olarak kullanılmaktadır. EVA, 0.5mm ile 0.7 mm kalınlığında, PV hücreyi cam ile arka levha arasına sıkıştıran plastik bir malzemedir. Arka levha tabakası olarak 0.5mm kalınlığında PVF (Polyvinyl Fluoride Film) kullanılmaktadır. Oluşturulan katmanları bir arada tutmak ve yapıyı darbelerden korumak için alüminyum çerçeve ve elektriksel bağlantıların yapılabilmesi için bağlantı kutusu kullanılmaktadır [33]. Şekil 3.5'te PV modülün katmanları gösterilmektedir [30].



Şekil 3.5. PV modül katmanları.

### 3.6. FOTOVOLTAİK PANELLERDEKİ ARIZALAR

Fotovoltaik panellerin güç çıkışlarının toplamı fotovoltaik dizinin toplam gücünü oluşturmaktadır. Fotovoltaik dizinin öngörülen güç çıkışını, her bir fotovoltaik panelin verimi etkilemektedir. Fotovoltaik panelin verimini geçici veya kalıcı arızalar etkilemektedir [34]. Bir PV modül arızası, modülün gücünü tersine döndürülemeyecek kadar düşüren veya modülün üzerinde güvenlik sorunu teşkil eden bir etkidir. Bu etkiler dışındaki diğer kozmetik sorunlar modül arızaları olarak değerlendirilmemektedir [4]. Geçici arızalara örnek olarak panelin üzerine düşen gölge veya panelin üzerinde biriken kar verilebilmektedir. Kalıcı arızalar; kapsülleme hatası, arka tabaka yapışma hatası, hücre çatlama, ara bağlantıların kopması, gölgelenme, korozyon, sıcak nokta, gerilim kaynaklı bozulma, ışık kaynaklı güç bozulması olarak sınıflandırılmaktadır.

#### 3.6.1. Kapsülleme Hatası

Kapsülleme hatası, kapsülleme malzemesi ile fotovoltaik hücre arasında oluşan kontaminasyon, tuz birikimi, nemlenme veya dış etkenler nedeniyle meydana gelmektedir. Ayrıca nemli ve sıcak koşullarda daha fazla görülen delaminasyon ve renk değişimlerinden de kaynaklanmaktadır [35]. Bu hatanın sonucunda kapsülleme malzemesi ile fotovoltaik hücre birbirinden ayrılarak fotovoltaik panelin geri dönülemez şekilde güç kaybetmesine neden olmaktadır. Şekil 3.6'da kapsülleme hatası görüntüsü verilmektedir [4].



Şekil 3.6. Kapsülleme hatası.

### 3.6.2. Arka Tabaka Yapışma Hatası


Arka tabaka, bir panelin elektronik bileşenlerini dış etkenlerden ve yüksek DC gerilimden koruyan bir yapıdır. Arka tabaka hataları delaminasyon etkisiyle oluşmaktadır. Bu hatanın sonucunda fotovoltaik panelin elektronik bileşenleri açığa çıkmakta ve panelin izolasyon güvenilirliği tehlikeye düşmektedir [35]. Şekil 3.7’de arka tabaka yapışma hatası görüntüsü verilmektedir [4].



Şekil 3.7. Arka tabaka yapışma hatası.

### 3.6.3. Hücre Çatlaması

Fotovoltaik panelin kullanımı sırasında her an oluşabilecek bir hatadır. Panelin üretim, nakliye ve montaj sırasında meydana gelen titreşim, taşıma sırasındaki dikkatsizlik veya panelin üzerine düşürülen sert cisimler tarafından oluşmaktadır [35]. Şekil 3.8’de hücre çatlaması hatası görüntüsü verilmektedir [4].



Şekil 3.8. Hücre çatlaması hatası.

#### 3.6.4. Ara Bağlantıların Kopması


Modül ara bağlantısı ve hücre ara bağlantı şeridi arasındaki zayıf lehimleme bu hatanın en temel sebebidir. Nakliye sırasında oluşan gerilmeler, sıcak noktalar, termal döngü veya tekrarlanan mekanik stres zayıf ara bağlantı noktalarının kopmasını sağlar. Bu hata, kısa devre veya açık devre olan hücrelere ve direnç artışına neden olmaktadır.

#### 3.6.5. Gölgeleme

İki tür gölgeleme bulunmaktadır. İlk tür gölgeleme sert gölgelendirme olarak isimlendirilmektedir. Fotovoltaik panellerin katı bir malzeme ile gölgelemesi sonucunda oluşmaktadır. Örneğin binalar, ağaçlar, toz vb. İkinci tür gölgeleme ise yumuşak gölgeleme olarak adlandırılmaktadır [35]. Yumuşak gölgelendirme bulutlu hava veya yoğun kirlilik sebebiyle oluşmaktadır [34]. İlk tür gölgeleme gerilim düşüşüne neden olurken ikinci gölgeleme ise akım düşüşüne neden olmaktadır. Bu gerilim ve akım düşüşleri panelin performansını etkilemektedir. Ayrıca gölgeli hücreler üretilen akıma karşı direnç gibi davranarak ısınıp sıcak noktaya dönüşmektedirler [35].

### 3.6.6. Korozyyon Hatası

Laminat kenar, nemin panelin içersine girmesine ve korozyona sebep olmaktadır. Korozyyon fotovoltaik hücrenin metalik bağlantılarına zarar vererek kaçak akıma ve performans düşüşüne neden olmaktadır [35]. Şekil 3.9’da korozyyon hatası görüntüsü verilmektedir [4].



Şekil 3.9. Korozyyon hatası.

### 3.6.7. Sıcak Nokta Hatası

Sıcak nokta, bir modülde seri bağlı olan fotovoltaik hücrelerden en az bir tanesinin düşük akım ürettiği veya hiç akım üretmediği durumlarda oluşur. Fotovoltaik panellerde görülen en yaygın arıza türüdür [34]. Sıcak noktalar Fotovoltaik paneli bozmakta ve panel dizisinin performansını düşürmektedir. Gölgeleme, baypas diyot arızası ve elektriksel özellikler arasındaki uyumsuzluk sıcak noktaların oluşmasını sağlamaktadırlar.

Sıcak nokta hataları hücre hatası, modül hatası ve panel hatası olarak sınıflandırılmaktadır. Hücre hatası güneş paneli üzerindeki bir hücrenin aşırı ısınması durumunda gerçekleşmektedir. Modül hatası, güneş panelindeki paralel bağlı modüllerin aşırı ısınması durumunda gerçekleşmektedir. Panel hatası ise güneş panelindeki bütün hücrelerin aşırı ısınması durumunda gerçekleşmektedir.

### **3.6.8. Gerilim Kaynaklı Bozulma**

Yalnızca kristal silikon panellerde meydana gelmekte ve modül performansının kademeli olarak düşmesine yol açmaktadır. Çoğu fotovoltaik panel sistemindeki kaçak akımlardan kaynaklanmaktadır.

### **3.6.9. Işık Kaynaklı Güç Bozulması**

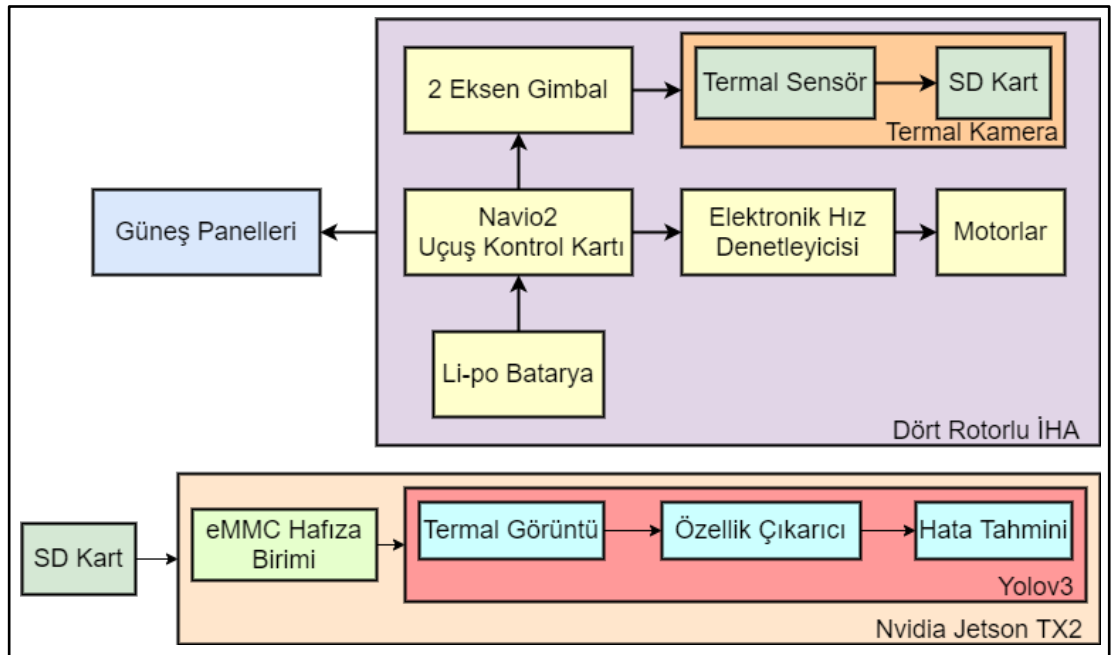
Bir fotovoltaik hücrenin p-n bağlantısının sonucu olarak fiziksel reaksiyonun neden olduğu doğal bir bozulmadır. Kristal silisyum yapıları fotovoltaik hücrelerin veriminde bir kayıp olarak yansıtılmaktadır [35].

## BÖLÜM 4

### DÖRT ROTORLU İHA VE TERMAL KAMERALI SİSTEM

Bu tez çalışmasında güneş panellerinin dört rotorlu bir İHA kullanılarak termografi yöntemiyle derin öğrenme tabanlı hata tespit ve teşhisi yapılmaktadır. Güneş panellerindeki hataların tespit ve teşhis edilmesinde termal görüntüler kullanılmaktadır. Güneş panellerinin termal görüntülerinin elde edilmesi için dört rotorlu bir İHA kullanılmaktadır.

Tasarım ve üretimi tez çalışması kapsamında gerçekleştirilen dört rotorlu İHA'ya bir adet gimbal ile bir adet termal kamera monte edilerek güneş panellerinin termal görüntüleri elde edilmektedir. Ayrıca termal kamera aracılığıyla elde edilen görüntüler ile güneş paneli sıcak nokta arızaları veri seti oluşturulmaktadır. Veri setinin oluşturulmasının ardından derin öğrenmede kullanılan Yolov3 ağıının eğitimi yapılmaktadır. Tez çalışmasının blok şeması Şekil 4.1'de verilmektedir.



Şekil 4.1. Çalışmanın blok şeması.




Bu bölümde dört rotorlu İHA'nın tasarım ve üretim aşamalarından, Yolov3 ağının eğitiminin yapıldığı Nvidia Jetson TX2 yapay zeka bilgisayarından ve güneş panellerinin termal görüntüsünün elde edildiği FLIR DUO R termal kameradan bahsedilecektir.

#### **4.1. DÖRT ROTORLU İNSANSIZ HAVA ARACI**


Dört rotorlu insansız hava araçlarının, arama kurtarma, sınır güvenliği, tarımsal uygulamalar, insan sağlığını tehdit edebilecek uygulamalar, nesne tespiti ve nesnenin takibi gibi oldukça fazla kullanım alanı bulunmaktadır [36]. Dört rotorlu insansız hava aracı, birbirlerine karşı simetrik olarak yerleştirilen dört rotora sahip hava araçlarına verilen bir isimdir. Dört rotorlu insansız hava aracının dinamik yapısı gereği, yüksek itki kuvvetine ve yüksek manevra kabiliyetine sahiptir. Ayrıca dikey iniş ve kalkış yapabilme, havada asılı kalabilme ve düşük hızlarda hareket edebilme gibi özellikleri de bulunmaktadır [37]. Bu avantajlarının dışında dört rotordan oluşan dinamik yapısı sebebiyle, her bir rotoru hareket ettiren motorların hız kontrolünün sağlanması sistem denetiminin zorlaşmasını neden olmaktadır [36].

Dört rotorlu insansız hava araçlarında kullanılan motorların hareket yönleri karşılıklı olarak terstir. Bunun sebebi motorların karşılıklı momentlerinin sıfıra eşitlenerek dört rotorlu insansız hava aracının kendi ekseninde dönmesini engellemektir. Dört rotorlu insansız hava araçlarının hareketi motorların dönüş hızlarının değişimiyle sağlanmaktadır. X ekseninde herhangi bir yönde hareket sağlamak için, istenilen hareket yönündeki motorların hızlarının azaltılması veya istenilen hareketin karşı yönündeki motorların hızlarının artırılması gerekmektedir [37]. Şekil 4.2'de X ekseninde sağ yöndeki hareketin benzetimi verilmektedir. X ekseninde sağ yönde hareket sağlayabilmek için M2 ve M3 motorlarının dönüş hızlarının sabit olduğu durumda M1 ve M4 motorlarının dönüş hızlarının azaltılması veya M1 ve M4 motorlarının dönüş hızlarının sabit olduğu durumda M2 ve M3 motorlarının dönüş hızlarının artırılması gerekmektedir. Y ekseninde ve Z eksenindeki istenilen hareketler de X eksenindeki hareket sistemiyle aynı şekilde sağlanmaktadır. Aynı şekilde yükselme ve alçalma hareketleri de motor dönüş hızlarının artırılıp azaltılmasıyla sağlanmaktadır.



Şekil 4.2. X ekseninde sağ yönde yapılan hareket.


Y ekseninde ileri yönlü bir hareket yapılmak istenirse; M1 ve M3 dönüş hızları sabit tutularak M2 ve M4 motorların dönüş hızlarının artırılması veya M2 ve M4 motorlarının dönüş hızları sabit tutularak M1 ve M3 motorların dönüş hızlarının artırılması gerekmektedir. Şekil 4.3'te Y ekseninde ileri yönde yapılan hareketin benzetimi verilmektedir.



Şekil 4.3. Y ekseninde yapılan ileri yönde yapılan hareket.

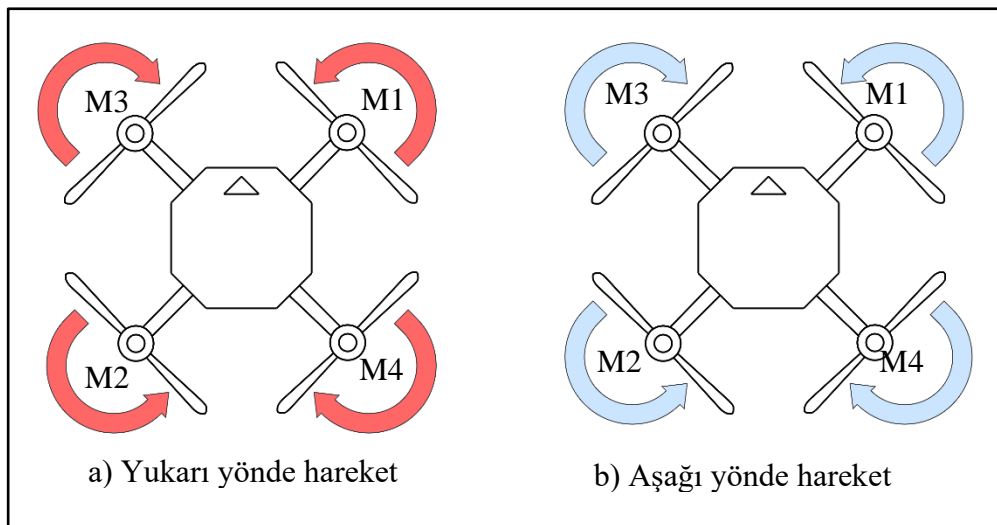
Z ekseninde saat yönünde bir hareket yapılmak istenirse; M1 ve M2 motorların dönüş hızları sabit tutularak, M3 ve M4 motorların dönüş hızları artırılması veya M3 ve M4 motorların dönüş hızları sabit tutularak, M1 ve M2 motorların dönüş hızlarının

azaltılması gerekmektedir. Şekil 4.4'te Z ekseninde saat yönünde yapılan hareketin benzetimi verilmektedir.



Şekil 4.4. Z ekseninde saat yönünde yapılan hareket.

X, Y ve Z ekseninin sabit olduğu yukarı yönlü veya aşağı yönlü bir hareket yapılmak istenirse; yukarı yönlü hareket için bütün motorların dönüş hızının artırılması, aşağı yönlü bir hareket içinse bütün motorların dönüş hızının azaltılması gerekmektedir. Şekil 4.5'te yukarı yönlü ve aşağı yönlü hareketin benzetimi verilmektedir.

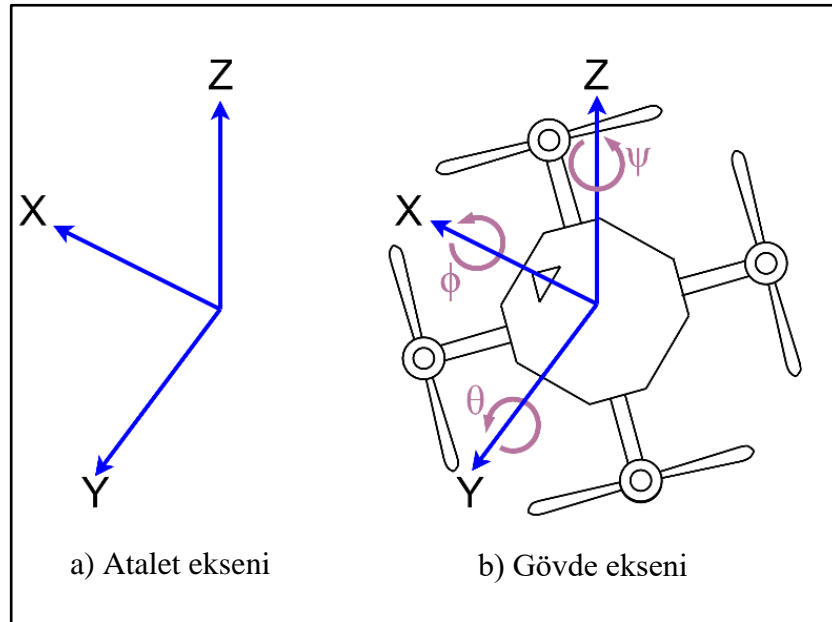


Şekil 4.5. Yukarı ve aşağı yönlü hareket.

#### 4.1.1. Dört Rotorlu İnsansız Hava Aracının Matematiksel Modellenmesi

Dört rotorlu insansız hava aracı matematiksel olarak modellenirken, İHA üç boyutlu ekseninde hareket eden bir cisim olarak kabul edilmektedir. İHA'nın üzerindeki kuvvetler bu kabul temelinde elde edilmektedir. Dört rotorlu insansız hava aracının matematiksel modeli, kinematik ve dinamik modellerden elde edilmektedir. Elde edilen matematiksel model zamanla değişen sistem davranışlarını açıklamak için kullanılmaktadır [36].

Dört rotorlu insansız hava aracında altı serbestlik derecesi bulunmaktadır. Bulunan bu dereceler; üç boyutlu uzayda yapılan doğrusal hareketleri gösteren x, y, z eksenleri ile Euler açıları olarak da bilinen açısal hızları gösteren yuvarlanma ( $\phi$  - Roll ), yunuslama ( $\theta$  - Pitch) ve sapma ( $\psi$  - Yaw) eksenleridir [38]. X ekseninde oluşan açısal harekete yuvarlanma, y ekseninde oluşturulan harekete yunuslama ve z ekseninde oluşan harekete sapma hareketi denilmektedir. Şekil 4.6'da dört rotorlu insansız hava aracının atalet ve gövde eksenleri verilmektedir.



Şekil 4.6. Dört rotorlu insansız hava aracı atalet ve gövde eksenleri.

Bir nokta çevresinde serbest olarak dönen katı cisimlerin üç boyuttaki yönelimi ve konumu Euler açıları ile belirtilmektedir. Dört rotorlu insansız hava aracının atalet

ekseni ve gövde eksenindeki ilişki Euler açılarıyla açıklanmaktadır. Matematiksel modelin oluşturulmasında Euler açılarından faydalanılmaktadır. Matematiksel model oluşturulurken; İHA'nın simetrik ve rijit bir yapıda olduğu, İHA'nın ağırlık merkezi ile gövde merkezinin aynı noktada olduğu, itkinin ve sürüklenme kuvvetinin kullanılan pervanenin hızlarının karesi ile doğru orantılı olduğu kabul edilmektedir.

#### 4.1.1.1. Kinematik Model

Gövde ekseninden ölçülen kuvvetler (örneğin pervanelerin ürettiği itki kuvveti) ile ataletsel eksen üzerinden ölçülen kuvvetlerin (örneğin İHA'nın konumu) arasında bir ilişki kurulması rotasyon matrisi ile gerçekleştirilmektedir. Rotasyon matrisi, dört rotorlu insansız hava aracının dinamik modelinin çıkarılmasında kullanılmaktadır [37]. Bu matris  $R_{x,y,z}$  olarak, x, y ve z eksenlerindeki dönme sırasıyla,  $R_x(\phi)$ ,  $R_y(\theta)$ ,  $R_z(\psi)$  olarak ifade edilmektedir. Eşitliklerde kullanılan c ve s simgeleri sırasıyla cosinüs ve sinüsü tanımlanmaktadır. Bu matematiksel eşitlikler Eşitlik 4.1 Eşitlik 4.2, Eşitlik 4.3, Eşitlik 4.4, ve Eşitlik 4.5'te verilmektedir.

$$R_x(\phi) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & c\phi & -s\phi \\ 0 & s\phi & c\phi \end{bmatrix} \quad (4.1)$$

$$R_y(\theta) = \begin{bmatrix} c\theta & 0 & s\theta \\ 0 & 1 & 0 \\ -s\theta & 0 & c\theta \end{bmatrix} \quad (4.2)$$


$$R_z(\psi) = \begin{bmatrix} c\psi & -s\psi & 0 \\ s\psi & c\psi & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (4.3)$$

$$R_{x,y,z} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & c\phi & -s\phi \\ 0 & s\phi & c\phi \end{bmatrix} \cdot \begin{bmatrix} c\theta & 0 & s\theta \\ 0 & 1 & 0 \\ -s\theta & 0 & c\theta \end{bmatrix} \cdot \begin{bmatrix} c\psi & s\psi & 0 \\ s\psi & c\psi & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (4.4)$$

$$R_{x,y,z} = \begin{bmatrix} c\theta c\psi & c\psi s\theta s\phi - s\psi c\phi & 0 \\ c\theta s\psi & s\psi s\theta s\phi + c\psi c\phi & 0 \\ -s\theta & c\theta s\phi & c\theta c\phi \end{bmatrix} \quad (4.5)$$

#### 4.1.1.2. Dinamik Model

Dört rotorlu insansız hava aracının hareketi sırasında rotorun dönüş yönüne ters yönde momentler ve z ekseninde itki kuvvetleri oluşmaktadır. Bu momentin dengelenmesi için rotorlar karşılıklı olarak zıt yönlerde döndürülmektedir. Şekil 4.7’de 1 ve 3 numaralı rotorlar saat yönünde döndürülürken, 2 ve 4 numaralı rotorlar saatin tersi yönde döndürülmektedir. Şekil 4.7’de dört rotorlu bir insansız hava aracı üzerindeki kuvvetler verilmektedir. Şekilde M ifadesi ters yönde uygulanan momenti,  $\Omega$  ifadesi rotorun açısal hızını, F ifadesi pervanelerin itki kuvvetini ve G ifadesi dört rotorlu insansız hava aracının ağırlığını ifade etmektedir.



Şekil 4.7. Dört rotorlu insansız hava aracı üzerindeki kuvvetler.

Dört rotorlu insansız hava aracının toplam kaldırma kuvveti Eşitlik 4.6’da verilmektedir. Bu eşitlikte  $F_T$  toplam itki kuvvetini,  $k_n$  itki faktörü sabiti ve  $\Omega_i$  ise pervanelerin açısal hızlarını ifade etmektedir [38].

$$F_T = k_n \sum_{i=1}^4 \Omega_i^2 \quad (4.6)$$

Pervanelerin ürettiği itki kuvvetini hesaplamak için Eşitlik 4.7’den faydalanılmaktadır. Bu eşitlikte  $T_i$  pervanelerin ürettiği itki kuvvetini,  $k_t$  aerodinamik katsayısını ifade etmektedir.

$$T_i = k_t \Omega_i^2 \quad (4.7)$$

Hub kuvveti, pervanelere yatayda etki eden kuvvetlere verilen isimdir [37]. Hub kuvveti Eşitlik 4.8'de verilmektedir. Bu eşitlikte  $H_i$  hub kuvvetini,  $k_h$  aerodinamik katsayısı ifade etmektedir.

$$H_i = k_h \Omega_i^2 \quad (4.8)$$

Rotor mili üzerinde, pervanelerin üzerine uygulanan aerodinamik kuvvetlerin etkisinden dolayı sürüklenme momenti oluşmaktadır [37]. Eşitlik 4.9 da sürüklenme momenti verilmektedir. Bu eşitlikte  $Q_i$  sürüklenme momentini,  $k_q$  aerodinamik sabiti ifade etmektedir.

$$Q_i = k_q \Omega_i^2 \quad (4.9)$$

X eksenindeki uçuşlarda, ileri yönde itkiyi sağlayan pervanelerin, geri yönde itkiyi sağlayan pervaneden daha fazla itki kuvveti uygulanması durumunda pervanelerde yuvarlanma momenti oluşmaktadır [37]. Yuvarlanma momenti Eşitlik 4.10'da verilmektedir. Bu eşitlikte  $R_i$  yuvarlanma momentini,  $k_r$  aerodinamik sabiti ifade etmektedir.

$$R_i = k_r \Omega_i^2 \quad (4.10)$$

Atalet momenti, dört rotorlu insansız hava aracının açısal hıza karşı direnci olarak tanımlanmaktadır. Atalet momenti 3x3 matris ile ifade edilmektedir. Eşitlik 4.11'da atalet momenti matrisi verilmiştir. Bu eşitlikte  $I_{xx}$  x eksenindeki,  $I_{yy}$  y eksenindeki ve  $I_{zz}$  z eksenindeki atalet momentini ifade etmektedir.

$$I = \begin{bmatrix} I_{xx} & 0 & 0 \\ 0 & I_{yy} & 0 \\ 0 & 0 & I_{zz} \end{bmatrix} \quad (4.11)$$

Dört rotorlu bir insansız hava aracında dört tane kontrol girdisi bulunmaktadır. Bu

girdiler  $U_1$ ,  $U_2$ ,  $U_3$  ve  $U_4$  olarak isimlendirilmektedir.  $U_1$  girdisi itki kuvvetini  $U_2$  yuvarlanma kuvvetini,  $U_3$  yunuslama kuvvetini ve  $U_4$  sapma kuvvetini ifade etmektedir [37]. Eşitlik 4.12’de  $U_1$ , Eşitlik 4.13’te  $U_2$ , Eşitlik 4.14’te  $U_3$  ve Eşitlik 4.15’te  $U_4$  girdilerinin matematiksel eşitliği verilmektedir.

$$U_1 = F_1 + F_2 + F_3 + F_4 \quad (4.12)$$

$$U_2 = F_4 - F_2 \quad (4.13)$$

$$U_3 = F_3 - F_1 \quad (4.14)$$

$$U_4 = T_2 + T_4 - T_1 - T_3 \quad (4.15)$$

Eşitlik 4.16’de dört rotorlu insansız hava aracına etki eden giriş kuvvetlerinin matematiksel eşitliği verilmektedir. Bu eşitlikte  $b$  itki faktörünü ve  $d$  sürüklenme faktörünü ifade etmektedir.

$$\begin{bmatrix} U_1 \\ U_2 \\ U_3 \\ U_4 \end{bmatrix} = \begin{bmatrix} b & b & b & b \\ 0 & -b & 0 & b \\ b & 0 & -b & 0 \\ -d & d & -d & d \end{bmatrix} \cdot \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} \quad (4.16)$$

Yukarıdaki eşitliklerden faydalanılarak dört rotorlu insansız hava aracı sisteminin Newton-Euler yaklaşımıyla matematiksel denklemleri oluşturulmaktadır. Eşitlik 4.17’de bu denklemler verilmektedir.

$$\left\{ \begin{array}{l} \ddot{x} = (c\psi s\theta s\phi + s\psi c\phi) \cdot \frac{U_1}{m} \\ \ddot{y} = (s\psi s\theta c\phi - s\psi c\phi) \cdot \frac{U_1}{m} \\ \ddot{z} = g - (c\theta c\phi) \cdot \frac{U_1}{m} \\ \ddot{\phi} = \dot{\psi} \dot{\theta} \left( \frac{I_{yy} - I_{zz}}{I_{xx}} \right) - \frac{J}{I_{xx}} \dot{\theta} (-\Omega_1 + \Omega_2 - \Omega_3 + \Omega_4) + \frac{L}{I_{xx}} U_2 \\ \ddot{\theta} = \dot{\psi} \dot{\phi} \left( \frac{I_{zz} - I_{xx}}{I_{yy}} \right) - \frac{J}{I_{yy}} \dot{\phi} (-\Omega_1 + \Omega_2 - \Omega_3 + \Omega_4) + \frac{L}{I_{yy}} U_3 \\ \ddot{\psi} = \dot{\theta} \dot{\phi} \left( \frac{I_{xx} - I_{yy}}{I_{zz}} \right) - \frac{1}{I_{zz}} U_4 \end{array} \right. \quad (4.17)$$



#### 4.1.2. Dört Rotorlu İnsansız Hava Aracının Donanımsal Yapısı

Dört rotorlu insansız hava araçları, bir gövde üzerine çeşitli elektronik ekipmanların monte edilmesiyle oluşturulmaktadır. Bu yapıda itki kuvvetini sağlayan parçalara pervane denilmektedir. İtke kuvvetinin oluşması için pervanelerin hareket ettirilmesi gerekmektedir. Bunun için motorlar kullanılmaktadır. Motorların belirli devirlerde döndürülmesiyle itki kuvvetinin şiddeti ayarlanabilmektedir. Bu sayede insansız hava aracının hareketi sağlanmaktadır. Motorların devir ayarlarının yapılabilmesi için elektronik hız denetleyicileri kullanılmaktadır. Elektronik hız kontrolcülerini uçuş kontrol kartından gelen sinyaller aracılığıyla motorların devirlerini ayarlamaktadır.

Uçuş kontrol kartı ise dört rotorlu insansız hava aracının beyni olarak kabul edilmektedir. Uçuş kontrol kartları üzerlerindeki çeşitli sensörlerden aldığı verilerle insansız hava aracının hareketini sağlamaktadır. Bu yapının enerjisi bir batarya aracılığıyla sağlanmaktadır.

Dört rotorlu İHA'nın tasarımı gerçekleştirilirken İHA'nın maksimum uçuş ağırlığı dikkate alınmıştır. Maksimum uçuş ağırlığı, dört rotorlu İHA'nın otonom uçuş görevini yaparken üzerinde bulundurduğu ekipmanların ağırlığının toplamına eşittir. Ekipmanların toplam ağırlığı elektronik tartıda tartılmak üzere maksimum uçuş ağırlığı 2.45kg ölçülmektedir.


Dört rotorlu İHA'nın gövdesi tasarlanırken, motordan motora olan çap değerine dikkat edilmektedir. Motordan motora olan çapın artmasıyla daha geniş pervanelerin kullanılması, böylece daha fazla ağırlığın kaldırılması mümkün olmaktadır. Dört rotorlu İHA'nın maksimum uçuş ağırlığı 2.45kg'dır. Bu uçuş ağırlığına en uygun olan motordan motora çapın 450mm olduğu bir gövde tasarımı yapılmıştır. Yapılan tasarım 12 inç boyutuna kadar olan pervaneleri desteklemektedir. Bu sayede farklı boyutlarda pervanelerin kullanılması mümkün olmaktadır.

Tasarlanan gövdenin üretiminde kullanılacak malzemelerde hafiflik ve yüksek dayanım özelliklerinin yanı sıra malzemenin işlenmesinin de kolay olması beklenmektedir. Bu özelliklere bakıldığında plastik ve karbon fiber materyalleri öne

çıkılmaktadır. Plastik gövdenin üretim zorluğundan dolayı karbon fiber materyal tercih edilmektedir. Karbon fiber levha ve boruların kullanıldığı gövdede, 3B yazıcıdan üretilen plastik parçalar da kullanılmaktadır. 3B yazıcı sayesinde parçaların üretim maliyeti düşürülmekte ve üretim hızı arttırılmaktadır.

#### 4.1.2.1. Dört Rotorlu İnsansız Hava Aracının Boyutsal Parametreleri

Tasarımı gerçekleştirilen dört rotorlu İHA'nın motordan motora olan çapı 450mm, eni 36,7cm boyu 36,7cm ve yüksekliği GPS anteni dahil 44,1cm'dir. Şekil 4.8'de dört rotorlu İHA'nın teknik resmi verilmektedir. Şekil 4.8'de dört rotorlu İHA'nın önden, yandan, üstten ve perspektif görüntüsü verilmektedir. Dört rotorlu İHA'nın tasarımı SolidWorks katı modelleme programıyla yapılmıştır. Şekil 4.9'da dört rotorlu İHA'nın SolidWorks tasarımı verilmektedir.



Şekil 4.8. Dört rotorlu insansız hava aracının teknik resmi.




Şekil 4.9. Dört rotorlu insansız hava aracının SolidWorks tasarımı.

#### 4.1.2.2. Dört Rotorlu İnsansız Hava Aracının Mekanik Yapısı

Maksimum uçuş ağırlığı 2.45kg olan dört rotorlu İHA'nın uçuş sırasında herhangi bir olumsuzlukla karşılaşmaması için gövde yapısının rijit olması gerekmektedir. Rijit bir gövde için kullanılan plastik parçalar ve karbon fiber materyaller birbirlerine civata ve somun kullanılarak bağlanmıştır. Bu sayede gövdenin rijitliği artarken, kullanılan parçalarda oluşan olumsuzluk durumlarında parçalar kısa sürede değiştirilebilmektedir.

Dört rotorlu İHA'nın gövdesi 2,5mm kalınlığında karbon fiber levhadan üretilmiştir. Motorların takıldığı kollar ise 12mm çapındaki karbon fiber borulardan üretilmiştir. Karbon fiber borular gövdeye 3B yazıcıdan üretilen plastik parçalar ile sabitlenmektedir. Şekil 4.10'da gövdeye montajı yapılan karbon fiber boruların görüntüsü verilmektedir.



Şekil 4.10. Gövdeye montajı yapılan karbon fiber borular.

Dört rotorlu İHA’da kullanılan motorların kollara montajı için karbon fiber levhadan motor tutacakları yapılmıştır. Yapılan motor tutacakları plastik parçalar aracılığıyla kollara monte edilmektedir. Şekil 4.11’de motor tutucu görüntüsü verilmektedir. Montajı tamamlanan dört rotorlu insansız hava aracı şekil 4.12’de verilmektedir.




Şekil 4.11. Motor tutucu.



Şekil 4.12. Montajı tamamlanan dört rotorlu insansız hava aracı.


#### 4.1.2.3. Dört Rotorlu İnsansız Hava Aracının Elektronik Donanımı

Dört rotorlu İHA'nın elektronik donanımında; uçuş kontrol kartı, kumanda alıcısı, telemetri, GPS anteni, güç dağıtım kartı, güç modülü, ESC, motor, gimbal ve batarya bulunmaktadır. Bu tez çalışmasında uçuş kontrol kartı olarak Navio2 tercih edilmiştir. Navio2 uçuş kontrol kartı üzerinde yüksek çözünürlüklü barometre ve iki adet IMU sensör bulunmaktadır. Ayrıca GPS, GLONAS, Beidou, Galileo ve SBAS uydularına bağlanabilen GPS modülü ve harici anten konektörü bulunmaktadır. Navio2 uçuş kontrol kartının kumandadan gelen verileri alabilmesi için bir adet alıcı girişi bulunmaktadır. Bu giriş PPM ve SBUS protokollerini desteklemektedir. Navio2 uçuş kontrol kartında servo motorları veya ESC'leri kontrol etmek için 14 kanal PWM çıkışı bulunmaktadır. Bunlara ek olarak ADC, I2C ve UART gibi geliştirme portlarına sahiptir. Navio2 uçuş kontrol kartı Raspberry Pi ile çalışmaktadır. Bu sayede yüksek hızlı işlem kabiliyetine sahiptir. Şekil 4.13'te Navio2 uçuş kontrol kartı gösterilmektedir.



Şekil 4.13. Navio2 uçuş kontrol kartı.

Uçuş kontrol kartına kumandadan gelen hareket bilgilerini aktarmak için kumanda alıcıları kullanılmaktadır. Kumanda alıcıları, üzerinde bulan kanal sayısına, haberleşme protokollerine ve haberleşme menzillerine göre sınıflandırılmaktadırlar. Bu tez çalışmasında FRISKY firmasının ürettiği X8R model kumanda alıcısı kullanılmıştır. X8R, SBUS haberleşme protokolünü desteklemektedir. Bu sayede tek kablo üzerinden 16 kanal bilgisi gönderilebilmektedir. Ayrıca 1,5km haberleşme menzili ve üzerinde 8 kanal çıkışı bulunmaktadır. Şekil 4.14'te FRISKY firmasının ürettiği X8R model kumanda alıcısı verilmektedir.



Şekil 4.14. FRISKY X8R kumanda alıcısı.

Uçuş kontrol kartından yer istasyonuna bilgi aktarılması için telemetri kullanılmaktadır. Kablosuz olarak haberleşen telemetri cihazları uçuş sırasında İHA'nın bilgilerine kullanıcının erişebilmesini sağlamaktadır. Ayrıca yer istasyonundan İHA'ya konum veya görev bilgisi göndermek için de kullanılmaktadır. Telemetri cihazları kablosuz olarak haberleştiklerinden bu haberleşmenin şifreli olarak yapılması gerekmektedir. Şifresiz olarak yapılan haberleşme hem İHA için hem

kullanıcı için tehlike arz etmektedir. Bu tez çalışmasına ALFA marka AWUS036ACH model 2.4GHz bandında çalışan telemetri cihazları kullanılmaktadır. Bu cihazlar USB (Universal Serial Bus – Evrensel Seri Veriyolu) arayüzü ile çalışabilmektedir. Ayrıca şifreli haberleşme yapan bu cihazlar telemetri veri güvenliğini de sağlamaktadırlar. Şekil 4.15’te ALFA marka AWUS036ACH model telemetri cihazı verilmektedir.




Şekil 4.15. ALFA marka AWUS036ACH telemetri cihazı.

GPS, GLONAS, Beidou ve Galileo uydularının sinyallerini alabilmek için GNSS antenleri kullanılmaktadır. Bu tez çalışmasında Tallysman marka Tw4721 model GNSS anteni kullanılmaktadır. Tallysman Tw4721 GNSS anteni 1,8V ile 16V çalışma gerilimi aralığına sahiptir. En düşük 10mA, en yüksek 15mA akım ihtiyacı olan bu anten yüksek sinyal gürültü bastırma oranına sahiptir. Şekil 4.16’de Tallysman marka Tw4721 model GNSS anteni verilmektedir.




Şekil 4.16. Tallysman Tw4721 GNSS anteni.

Güç dağıtım kartları, ESC'lerin enerji girişlerinin bağlandığı ve harici olarak farklı gerilimlerde çıkışları bulunan kartlara denilmektedir. Bataryadan gelen gerilimin ESC'lere eşit olarak dağıtılmasını ve üzerinde bulunan filtre devreleri ile ESC kaynaklı oluşan parazitleri engellemektedir. Bu tez çalışmasında Matek marka güç dağıtım kartı kullanılmaktadır. Şekil 4.17'de Matek marka güç dağıtım kartı verilmektedir.



Şekil 4.17. Matek marka güç dağıtım kartı.

Güç modülü, Navio2 uçuş kontrol kartı için gerekli olan enerjiyi sağlanmasında kullanılmaktadır. Farklı seviyelerdeki giriş gerilimlerine karşı sabit gerilim çıkışı verebilmektedir. Giriş gerilimi 12V ile 25,2V aralığında olan güç modülü sabit olarak 5V-2,25A güç çıkışı verebilmektedir. Şekil 6.18'de Navio2 güç modülü verilmektedir.



Şekil 4.18. Navio2 güç modülü.

ESC'ler BLDC motorları kontrol etmek için kullanılmaktadırlar. Uçuş kontrol kartından gelen PWM sinyaline göre BLDC motor devrini ayarlamaktadırlar. Bu tez



alışmasında EMAX firmasının üretmiş olduđu BLHeli 25A model ESC'ler kullanılmıştır. Bu ESC'lerin neden seçildiđi Dört Rotorlu İnsansız Hava Aracının Donanım Seçimi bölümünde detaylı olarak anlatılmaktadır. Şekil 4.19'de EMAX marka BLHeli 25A model ESC verilmektedir.



Şekil 4.19. EMAX marka BLHeli 25A model ESC.


BLDC motorlar pervaneleri döndürerek bir itki kuvveti elde edilmektedir. Bu itki kuvveti ile dört rotorlu İHA'nın hareketi sağlanmaktadır. Bu tez çalışmasında SunnySky firmasının üretmiş olduđu X3108s model BLDC motorlar kullanılmaktadır. Bu motorların neden seçildiđi Dört Rotorlu İnsansız Hava Aracının Donanım Seçimi bölümünde detaylı olarak anlatılmaktadır. Şekil 4.20'te SunnySky marka X3108S model 720kv BLDC motor verilmektedir.



Şekil 4.20. SunnySky marka X3108S model 720kv BLDC motor.

Dört rotorlu İHA'lara takılan kameralarda, uçuş sırasında oluşan titremeden kaynaklı görüntülerde bozulma meydana gelmektedir. Bu bozulmaları engellemek için gimballer kullanılmaktadır. Gimballer üzerlerine takılan kameradaki titreşimleri engellemek ve kamerayı istenilen açılarda hareket ettirmek için kullanılan cihazlar

olarak adlandırılmaktadır. Gimballer iki veya üç eksenli olarak üretilmektedirler. Üzerinde bulunan kontrol kartı sayesinde, uçuş kontrol kartından bağımsız veya uçuş kontrol kartıyla birlikte kullanılabilir. Bu tez çalışmasında iki eksen gimbal kullanılmıştır. 3S veya 4S Li-po batarya ile çalışabilmesi, üzerinde fırçasız motorlar bulunması ve alüminyum yapısından dolayı tercih edilmiştir. Şekil 4.21’te iki eksen gimbal verilmektedir.



Şekil 4.21. İki eksen gimbal.

Dört rotorlu İHA’nın hareketi için gerekli enerjiyi sağlayan yapıya batarya denilmektedir. Dört rotorlu İHA’nın motorlarının devamlı yüksek akım ihtiyacından ötürü Li-po bataryalar tercih edilmektedir. Li-po bataryalar, diğer bataryalara göre kapasitelerinin üzerinde anlık olarak yüksek akım verebildiklerinden İHA’larda sıklıkla tercih edilmektedirler. Bu tez çalışmasında Leopard Power marka 3S 11.1V 6200mAh Li-po batarya kullanılmaktadır. Şekil 4.22’te Leopard Power marka 3S 11.1V 6200mAh 30C Li-po batarya verilmektedir.



Şekil 4.22. Leopard Power marka 3S 11.1V 6200mAh 30C Li-po batarya.

#### 4.1.2.4. Dört Rotorlu İnsansız Hava Aracının Donanım Seçimi

Dört rotorlu İHA'nın donanımlarının seçimi tasarım bölümünde elde edilen ağırlık bilgisine göre yapılmaktadır. Hesaplanan toplam ağırlığın 2.45kg olması sebebiyle motor başına 0.61kg itme kuvvetine ihtiyaç duyulmaktadır. Bu denklem Eşitlik 4.18'de verilmektedir.

$$\text{Kol başına düşen itki} = \frac{\text{toplam uçuş ağırlığı}}{\text{motor sayısı}} \quad (4.18)$$

Motor başına düşen itki kuvvetini hesaplanmasının ardından dört rotorlu İHA'nın motor seçimi yapılmaktadır. Motor seçimi yapılırken kullanılacak bataryanın en düşük gerilimine göre hesap yapılması gerekmektedir. İHA'da elektronik yapının da desteklediği 3S Li-po batarya kullanılacağından, 11.1V gerilim değerinde %50 gaz seviyesinde 0.61kg itki kuvvetini veren motorlar araştırılmaktadır. Araştırma sonucunda SunnySky firmasının ürettiği X3108s marka 720kv BLDC motorlar seçilmektedir. Çizelge 4.1'de SunnySky marka X3108s model 720kv BLDC motorun özellikleri verilmektedir.

Çizelge 4.1. SunnySky marka X3108s model 720kv BLDC motor özellikleri.

Pervane(inç)	Gaz Seviyesi	Volt(V)	Amper(A)	İtki(g)
10x4.5	%0	11.1V	1	200
10x4.5	%50	11.1V	7	600
10x4.5	%100	11.1V	15	950
12x3.8	%0	11.1V	1	230
12x3.8	%50	11.1V	10	750
12x3.8	%100	11.1V	21	1200

Çizelge 4.2'ye göre SunnySky marka X3108s model 720kv BLDC motor 11.1V gerilimde %50 gaz seviyesinde 10x4.5" pervane ile kullanıldığı takdirde 0.6kg itki kuvveti elde edilmektedir. Kullanılacak pervanenin materyali karbon fiber olarak seçilmiştir. Bunun sebebi plastik pervanelerin yüksek hızlarda ve ağırlıklarda esneme

yapmasıdır. Esneme yapan plastik pervanenin kırılma uğrama olasılığı yüksek olmaktadır. Çizelge 4.3'te 10x4.5" karbon pervanenin özellikleri verilmektedir.

Çizelge 4.2. 10x4.5" karbon pervane özellikleri

Ağırlık	9gr	Merkez Delik Çapı	6mm
Çap	10"	Merkez Delik Kalınlığı	10mm
Eğim	4.5"	Uzunluk	255mm
Materyal	Karbon	Balans Durumu	Balanslı

Çizelge 4.3. EMAX marka BLHeli model 25A ESC.

Çalışma Gerilim Aralığı	7.4V-21V	BEC Çıkışı	5V-2A
Devamlı akım	25A	Ağırlık	28gr
Anlık akım	30A (10s)	Programlanabilme	Evet

Dört rotorlu İHA'da kullanılacak ESC'lerin seçiminde SunnySky marka X3108s model 720kv BLDC motorun çektiği maksimum akım olan 21A değeri dikkate alınmıştır. Ayrıca SunnySky marka x3108s model 720kv BLDC motorların çalışma aralığı olan 11.1V ile 21V değerleri de dikkate alınmıştır. Bu değerlere göre EMAX marka BLHeli Model 25A ESC'ler seçilmektedir. Çizelge 4.4'te EMAX marka BLHeli Model 25A ESC verilmektedir.

Dört rotorlu İHA'da kullanılacak olan Li-po bataryanın seçiminde SunnySky marka X3108s model 720kv BLDC motorların anlık çektikleri akım ve uçuş süresi dikkate alınmıştır. Otonom olarak yapılacak uçuşların ortalama 10dk olacağı öngörülmektedir. Bataryanın kapasitesi hesaplama formülü Eşitlik 4.19'da verilmektedir. Hesaplanan bataryanın kapasite değeri 4.66Ah olarak hesaplanmıştır. Uçuş sırasında batarya kapasitesinin tamamı kullanılamamaktadır. Batarya kapasitesinin %20 si kullanılmadığından hesaplanan kapasite değeri %20 ile çarpılarak gerçek batarya kapasitesi bulunmuş olmaktadır.

$$\text{Batarya kapasitesi} = \frac{\text{Uçuş süresi}}{60} \times (\text{devamlı akım} \times \text{motor sayısı}) \quad (4.19)$$

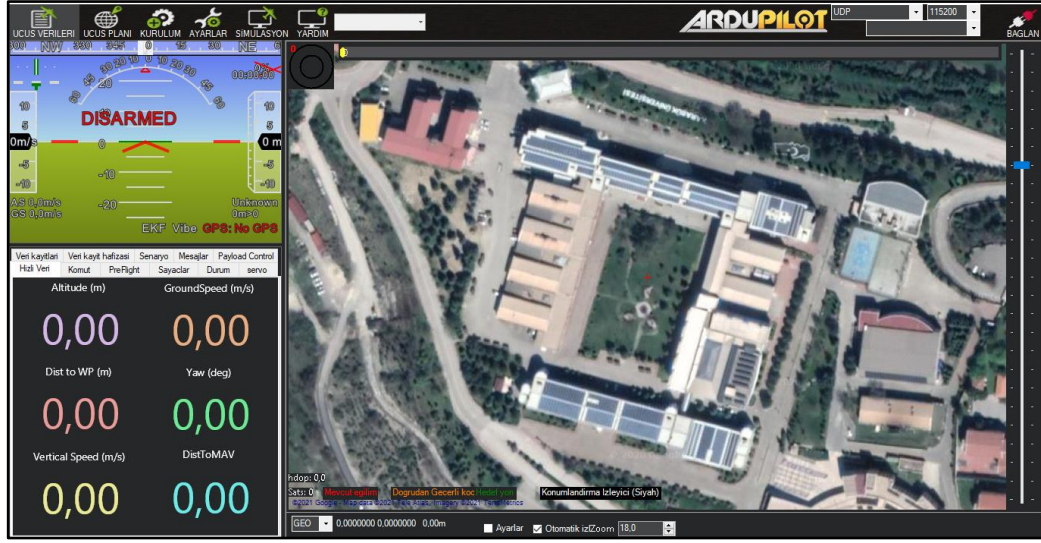
Dört rotorlu İHA ile 10dk otonom uçuş süresi elde edebilmek için en az 5.6Ah'lik bir batarya kapasitesi kullanılması gerekmektedir. Ayrıca bataryanın verebileceği anlık akım motorların çektiği anlık akımı karşılayabilmelidir. Bunun için anlık olarak minimum 84A akım verebilen bir batarya seçilmesi gerekmektedir. Bataryanın gerilimi motorların, ESC'lerin, gimbalin ve güç modülünün desteklediği gerilim olan 11.1V olması gerekmektedir. Bu özelliklere dayanarak Leopard Power marka 3S 11.1V 6200mAh 30C Li-po batarya tercih edilmiştir. Çizelge 4.5'te Leopard Power marka 3S 11.1V 6200mAh 30C Li-po batarya özellikleri verilmektedir.

Çizelge 4.4. Leopard Power marka 3S 11.1V 6200mAh 30C Li-po batarya.

Batarya kapasitesi	6200mAh	Türü	Li-po
Hücre sayısı	3S1P	Şarj oranı	1-2C
Devamlı deşarj akımı	186A	Ağırlık	450g
Patlama akımı	372A (5s)	Konektör Tipi	XT60

#### 4.1.2.5. Dört Rotorlu İnsansız Hava Aracının Yer İstasyonu ve Yazılımı

Dört rotorlu İHA'nın uçuş parametre ayarlarını yapabilmek için yer istasyonu yazılımı kullanılmaktadır. Ayrıca yer istasyonu anlık olarak uçuş bilgilerini de gösterebilmektedir. Dört rotorlu İHA'da kullanılan Navio2 uçuş kontrol kartı, Ardupilot tabanlı açık kaynak kodlu yazılım ile çalışmaktadır. Yazılım ayarlarının yapılabilmesi Mission Planner programı kullanılmaktadır. Mission Planner programı aracılığıyla gövde tipi, motor sayısı, ESC kalibrasyonu ve kumanda kalibrasyonu gibi ayarlar yapılabilmektedir. Bunların yanı sıra otonom olarak görev planlayabilme, otonom uçuş rotası oluşturma ve oluşturulan otonom uçuş rotasını simule edebilmek için uçuş simülasyonu gibi özellikleri bulunmaktadır. Şekil 4.23'te Mission Planner programının ekran görüntüsü verilmektedir.



Şekil 4.23. Mission Planner programı.

Tez çalışması kapsamında üretilen dört rotorlu İHA'nın elektronik ve mekanik ürün maliyeti 8.000TL ve termal kameranın fiyatı ise 13.900TL'dir. Toplam olarak 21.900TL maliyetle termal kameraya sahip dört rotorlu İHA üretilmektedir. Piyasa araştırması sonucu dört rotorlu ve termal kameraya sahip DJI marka Mavic 2 Enterprise Dual model İHA'nın fiyatı 35.000TL'den başladığı görülmektedir. Bu fiyatlandırmalar doğrultusunda bu tür çalışmalarda profesyonel olarak kullanılan termal kameralı İHA'lara göre daha düşük maliyetle dört rotorlu termal kameralı bir İHA'nın üretimi gerçekleştirilmiştir.

## 4.2. NVIDIA JETSON TX2 YAPAY ZEKA BİLGİSAYARI

Nvidia Jetson TX2 yapay zeka bilgisayarı görüntü sınıflandırma, nesne algılama ve ses işleme gibi birden çok sinir ağının paralel çalışmasına izin veren küçük, güçlü bir bilgisayardır. Gömülü uygulamalar, derin öğrenme, IoT, bilgisayarlı görü ve daha fazlası için geliştirilmiştir. Nvidia Jetson TX2'yi aynı CUDA çekirdeklerini kullanan GeForce etkin grafik işlemcisi (Graphics Processing Unit- GPU) ile kullanmak, uygulamalar için çok güçlü bir geliştirme ortamı oluşturmaktadır. Ayrıca Nvidia Jetson TX2 işletim sisteminin CPU (Central Process Unit – Merkezi İşlem Birimi) tarafından başlatılabildiği ve CUDA uyumlu GPU'nun karmaşık makine öğrenme görevlerini hızlandırmak için programlanabildiği bir CPU-GPU heterojen mimarisine sahiptir [39].

Çizelge 4.5. Nvidia Jetson TX2 yapay zeka bilgisayarı teknik özellikleri.

CPU	2 GHz Arm Cortex-A57 (quad-core) + 2GHz Nvidia Denver2 (dual core)
GPU	256-core Pascal @ 1300 MHz
Hafıza	8GB 128-bit LPDDR4 @ 1866 MHz
Depolama	32GB eMMC 5.1
Ethernet	10/100/1000 Base-T Ethernet

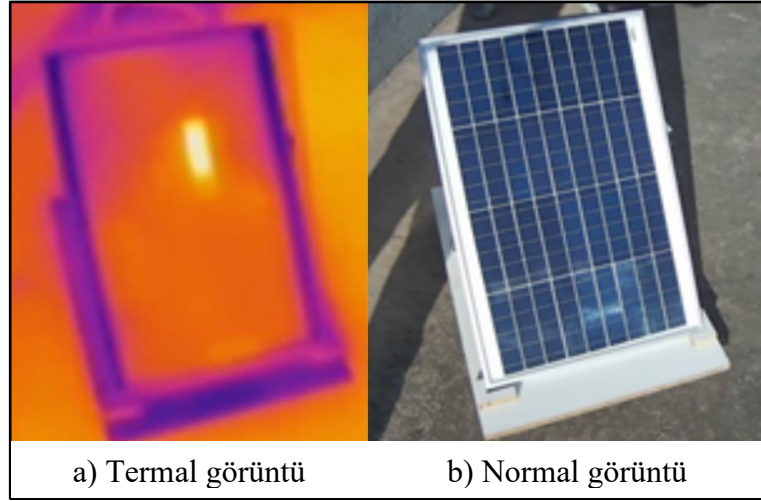
Nvidia Jetson TX2 yapay zeka bilgisayarı üzerinde Ubuntu 18.04 işletim sistemi çalışmaktadır. Çizelge 4.6’de Nvidia Jetson TX2 yapay zeka bilgisayarı teknik özellikleri verilmektedir [40]. Bu tez çalışmasında Yolov3 ağını eğitmek ve güneş panellerindeki hataları tespit ve teşhis etmek için kullanılmaktadır. Şekil 4.24’te Nvidia Jetson TX2 yapay zeka bilgisayarı verilmektedir.



Şekil 4.24. Nvidia Jetson TX2 yapay zeka bilgisayarı.

### 4.3. FLIR DUO R TERMAL KAMERA

Termografi yöntemi ile PV paneller üzerindeki hataların tespiti rahatlıkla yapılabilmektedir. Termografik ölçümler termal kameralar aracılığıyla yapılmaktadır. Termal kameralar nesnelere yayılan 8 um ile 14um dalga boyuna sahip gözle görülemeyen ısı enerjisini tespit eden ve bunları gözle görünür hale getiren cihazlardır. Termal kameralarla nesnelere yüzeylerindeki sıcaklık farklılıkları ölçülebilmektedir. Termal kameralarla elde edilen görüntülerde sıcaklığın yüksek olduğu noktalar sarı renk tonuyla, sıcaklığın düşük olduğu noktalar mavi renk tonuyla gösterilmektedir. Şekil 4.25'te termal kamera ile çekilen bir görüntü verilmektedir.



Şekil 4.25. Termal kamera ile elde edilmiş bir görüntü.

Bu tez çalışmasında FLIR marka DUO R model termal kamera tercih edilmiştir. FLIR DUO R üzerinde hem termal hem de gündüz kamerası olmak üzere iki kamera bulundurmaktadır. Bu sayede elde edilen görüntüler hem termal görüntü hem de normal görüntü olarak kaydedilmektedir. FLIR DUO R termal kamera üzerinde bulunan termal sensörün çözünürlüğü 160x120 pikseldir. Buna karşın gündüz kamerasının çözünürlüğü 1920x1080 pikseldir. Mikro HDMI dijital görüntü çıkışıyla anlık görüntü alınabilmektedir. Ayrıca termal kamera üzerinde bulunan mikro SD kart yuvası ile elde edilen görüntüler mikro SD karta kaydedilerek depolanabilmektedir [21]. Şekil 4.26'da FLIR DUO R termal kamera verilmektedir. Çizelge 4.6'da FLIR marka DUO R model termal kameranın teknik özellikleri verilmektedir.





Şekil 4.26. FLIR DUO R termal kamera.

Çizelge 4.6. FLIR marka DUO R model termal kamera teknik özellikleri.

Termal Görüntüleyici	Uncooled VOx Microbolometer
Sensör Çözünürlüğü	160x120
Lens	57°x44°
Spektral Bant	7.5-13.5µm
Termal Kare Oranı	7.5Hz (NTSC), 8.3Hz (PAL)
Gündüz Kamera Çözünürlüğü	1920x1080
Gündüz Kamera Görüş Açısı	90°
Giriş Gerilimi	5-26VDC
Ağırlık	84gr
Boyutlar	41x59x29.6mm
Depolama	Mikro SD Kart

## BÖLÜM 5

### GÜNEŞ PANELLERİNİN TERMOGRAFI YÖNTEMİYLE DERİN ÖĞRENME TABANLI HATA TESPİT VE TEŞHİSİ

Bu çalışmada güneş panellerindeki hataları, havadan görüntü olarak tespit ve teşhis edebilmek için dört rotorlu bir İHA'dan yararlanılmaktadır. Aracın alt kısmına yerleştirilen gimble bağlı olan bir termal kamera ile güneş panellerinin görüntüleri alınmaktadır. Termal kamera aracılığıyla elde edilen görüntülerden güneş paneli sıcak nokta hatalarına yönelik veri seti oluşturulmakta ve etiketleme işlemi yapılmaktadır. Bunlar hücre, modül ve panel hatalarıdır. Bu hataların derin öğrenme yöntemi ile tespit edilmesi için Yolov3 ağından yararlanılmaktadır. Oluşturulan veri setiyle Yolov3 ağının eğitimi yapılmakta ve eğitim sonucunda ağın test işlemleri gerçekleştirilmektedir. Elde edilen termal görüntüler eğitimi tamamlanan YoloV3 ağına verilerek görüntülerdeki hatalar tespit ve teşhis edilmektedir.

#### 5.1. TERMOGRAFI

PV sistemlerin maliyetlerini düşürmenin temel faktörlerinden biri, PV panellerin güvenilirliğini ve hizmet ömrünü artırmaktır. PV panellerin güvenilirliğini ve hizmet ömrünü artırmak için düzenli aralıklarla bakımların yapılması ve hatalı panellerin sistemden uzaklaştırılması gerekmektedir. PV panellerdeki hataların tespitinde elektriksel, görsel veya görüntü tabanlı yöntemler kullanılmaktadır. Görsel yöntemde bir PV panelin kapsülleme hatası, arka tabaka yapışma hatası, hücre çatlaması, korozyon hatası, cam kırılması gibi gözle görünen hataların tespiti yapılmaktadır. Elektriksel yöntemde ara bağlantıların kopması, gölgelenme, kısa veya açık devre olan paneller gibi gözle görünemeyen hataların tespitinde kullanılmaktadır. Görüntü tabanlı yöntemde ise termal görüntüler kullanılarak sıcak nokta hatalarının tespiti yapılmaktadır. Termografi, PV panellerin karakteristik özelliklerinin hızlı, temassız ve gerçek zamanlı olarak yapılan tahribatsız bir ölçüm tekniğidir. Termografi ölçümleri

harici bir akımın veya PV paneline ışık uygulanmasının neden olduğu sıcaklık farklılıklarını gösterir. Karanlıkta yapılan ölçümlerde PV panele harici akım verilerek paneldeki hatalar tespit edilmektedir. Aydınlıkta yapılan ölçümler genellikle güneş ışığı altında yapılmaktadır. PV panele uygulanan güneş ışığı panel üzerinde homojen olmayan sıcaklık artışına neden olmaktadır. Sıcaklık artışının olduğu bölgeler incelenerek paneldeki hataların tespiti yapılmaktadır. PV panel üzerindeki homojen olmayan sıcaklık dağılımını termal kameralar aracılığıyla ölçülebilmektedir.

Aydınlıkta yapılacak termografi ölçümleri minimum 700W/m<sup>2</sup> ışınım değerinde ve düşük rüzgâr hızında yapılmalıdır. Ayrıca termal kamera PV panele 90 derece açı ile bakmalıdır. Bunun sağlanamadığı durumlarda 60 dereceden düşük olmamak şartıyla 90 dereceye yakın açılar kullanılmalıdır [4].

## **5.2. DERİN ÖĞRENME TABANLI GÖRÜNTÜ İŞLEME**

İnsanların gündelik yaşamlarında kullandıkları akıl ve zeka kelimeleri genellikle birbirlerinin yerine kullanılmaktadır. Toplumda akıl kelimesi, insanların zeka düzeylerini belirten bir terim olarak kullanılmaktadır. Halbuki akıl, düşünme anlama ve kavrama gücü olarak nitelendirilmektedir. Zeka ise akıl yürütme, objektif gerçekleri algılama ve sonuç çıkarma yeteneği olarak nitelendirilmektedir. Yapay zeka ise insansız bir sistemin, insana özgü olan çözüm yolu bulma, geçmişteki deneyimlerden öğrenme gibi niteliklerini kullanarak görevleri tamamlama yeteneği olarak tanımlanmaktadır.

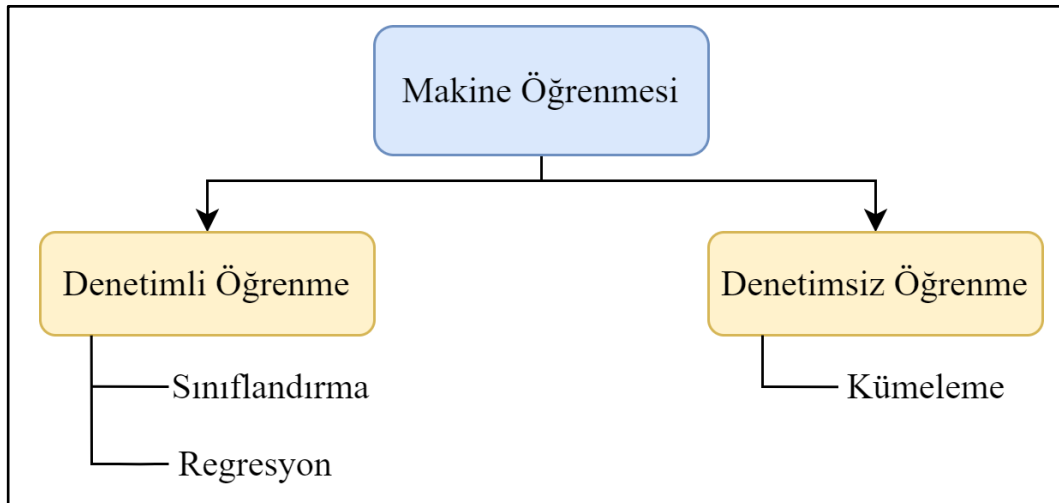
Yapay zeka mekatronik, bilgisayar, elektronik, kontrol, yazılım, gibi disiplinlerin ortak çalışma alanıdır. Teknolojinin gelişmesi ve bu gelişme ile açığa çıkan yeni ihtiyaçlar doğrultusunda yapay zekaya olan ilgi artmaktadır. Yapay zeka uygulamalarının en başında bir uzmana gerek kalmadan çıkarım yapan yazılımlar bulunmaktadır. Bu yazılımlar sayesinde iş gücünden tasarruf edilmektedir [41]. Günümüzde yaşanan problemlerin çok çeşitli olması sebebiyle yapay zekanın farklı teknolojileri kullanılmaktadır. Bu teknolojilerden yaygın olarak kullanılanlar, uzman sistemler, bulanık mantık, yapay sinir ağları ve makine öğrenmesidir [42].

### 5.2.1. Yapay Sinir Ağları

Öğrenme işlemini gerçekleştiren bilgisayar sistemleri olarak nitelendirilen yapay sinir ağları, öğrenmeyi örnekler aracılığıyla gerçekleştirmektedir. Yapay sinir ağları, yapay sinir hücreleri ile birbirlerine bağlı yapılardan oluşmaktadır. Bu yapıdaki her bağlantının bir ağırlık değeri bulunmaktadır. Bu değerlerde ağırlık sahip olduğu bilgiler saklanmaktadır. Ağırlık oluşturulmasında hangi yapının kullanılacağı, hangi parametrelerin seçileceği gibi bilgilerin bir standardının olmaması veya sorunların sadece sayısal bilgiler ile gösterilmesine rağmen yapay sinir ağlarına olan ilgi gittikçe artmaktadır [5].

### 5.2.2. Makine Öğrenmesi

Bir problemin belirli bir algoritma ile çözülmesinin mümkün olmadığı durumlarda kullanılmaktadır. Makine öğrenimi modelleri girdiler ile çıktılar arasındaki ilişkileri bularak sonuç üretmektedirler. Model tanıma, sınıflandırma problemleri ve veri madenciliği gibi durumlarda makine öğrenimi kullanılmaktadır. Makine öğrenmesinde öğrenme veri setleri aracılığıyla yapılmaktadır. Bu nedenle doğru verileri seçmek ve bunları uygun şekilde hazırlamak, sorunun etkili bir şekilde çözülmesini sağlamak için kritiktir [43]. Şekil 5.1’de makine öğrenmesi teknikleri verilmektedir.




Şekil 5.1. Makine öğrenmesi teknikleri.

### 5.2.3. Derin Öğrenme

İnsanlar kavramları ham, doğal durumunda bulunan verilerden öğrenmektedirler. Örneğin bir çocuğa birkaç kedi resmi gösterildiğinde bir süre sonra kedileri tanımayı öğrenecektir. Derin öğrenme alanının birincil odak noktası sonuçlara varmak için kullanılacak uygun veri temsillerini öğrenmektir. Derin öğrenmedeki “derin” kelimesi, kavramların hiyerarşisini doğrudan ham verilerden öğrenme fikrini ifade etmektedir [44].

Makine öğrenmesinin bir sınıfı olan derin öğrenmenin temel yapısı yapay sinir ağı üzerine kurulmuştur. Şekil 5.2’de derin öğrenmenin yapısı verilmektedir. Derin öğrenmede giriş katmanları, gizli katmanlar ve çıkış katmanları bulunmaktadır. Sıralı olan her katman bir önceki katmanın çıkışı, bir sonraki katmanın girişi olarak kullanılmaktadır. Makine öğrenmesi algoritması ile derin öğrenme algoritması arasındaki fark makine öğrenmesinin yanlış bir tahminde bulunması durumunda, mühendis sonuca müdahale ederek gerekli ayarlamaları yapmaktadır. Fakat derin öğrenmede tahminin doğruluğu algoritmalar tarafından belirlenmektedir [45].



Şekil 5.2. Derin öğrenme yapısı.

Derin öğrenme yöntemleri denetimli öğrenme ve denetimsiz öğrenme olarak ikiye ayrılmaktadır. Denetimsiz öğrenmede veri setindeki verilerle ilgili bir etiket bulunmamaktadır. Öğrenme etiketsiz verilerle gerçekleştirilmektedir. Denetimli

öğrenmede ise veri setindeki veriler çıktılarda görülmesi istenen sonuçlara göre etiketlenmektedir [46].

1965 yılında ilk öğrenme algoritması Ivakhnenko ve Lapa tarafından geliştirilmiştir. Yapılan çalışmada her katman için en iyi özellikler oransal metotla seçilmiş ve bir sonraki katmana iletilmiştir. Ağı eğitimi için en küçük kareler metodu kullanılmıştır. 1979 yılında Fukushima tarafından omurgalı canlıların sinir sisteminden esinlenerek “Neokognitron” adında ilk derin öğrenme mimarisini geliştirmiştir. Bu mimaride denetimsiz öğrenme metodu kullanılmaktadır [47].

1989 yılında Yann Lecun ve arkadaşları “LeNet” isimli ağı ilk prototipini geliştirmişlerdir. Bu ağ posta kutusu üzerinde yazılan rakamları tanımak için kullanılmıştır. 1995 yılında Geoffrey ve arkadaşları tarafından denetimsiz sinir ağı için “uyan-uyu” algoritması geliştirmişlerdir. Tanıma bağlantıları, girdiyi ardışık gizli katmanların girişlere dönüştürmektedir. Üretici bağlantıları ise gizli katmanların girişlerini tekrardan oluşturmaktadır. Uyanma aşamasında nöronlar tanıma bağlantıları tarafından yönlendirilmektedir. Üretici bağlantılar alt katmandaki girdilerini yeniden oluşturmak için uyarılmaktadırlar. Uyku aşamasında ise nöronlar üretici bağlantılar tarafından yönlendirilmekte, tanıma bağlantıları ise üst katmandaki doğru aktivite vektörünü üretme olasılığını arttırmak için uyarılmaktadır [48].

2006 yılında Geoffrey Hinton yaptığı çalışmada el yazısı rakamlarda, öğrenilmiş bir üretici modelin sınıflandırma sırasında ayırmacı öğrenme yöntemlerinden daha iyi performans gösterdiğini kanıtlamaktadır.

#### **5.2.4. Derin Öğrenme Mimarileri**

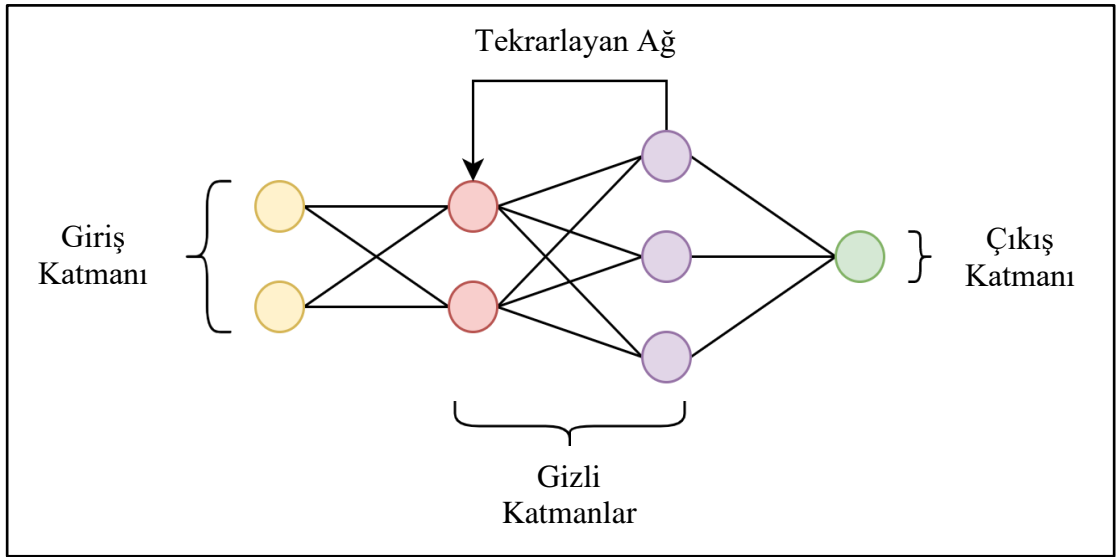
Derin öğrenmenin uygulanacağı her problemin aynı olmamasından dolayı problemlerin çeşitlerine göre yapay sinir ağı kullanılmaktadır. Seçilecek yapay sinir ağı modeli kullanılan yere ve amaca göre çeşitlilik göstermektedir [49].

Bu modeller evrişimli sinir ağı, tekrarlayan sinir ağı (Recurrent Neural Network-RNN), uzun kısa vadeli hafıza ağı (Long Short-Term Memory Neural Network-

LTSM), derin inanç ağıları (Deep Belief Network- DBN) ve derin oto-kodlayıcılar (Auto Encoder) olmak üzere sınıflandırılabilirler.

#### 5.2.4.1. Tekrarlayan Sinir Ağları

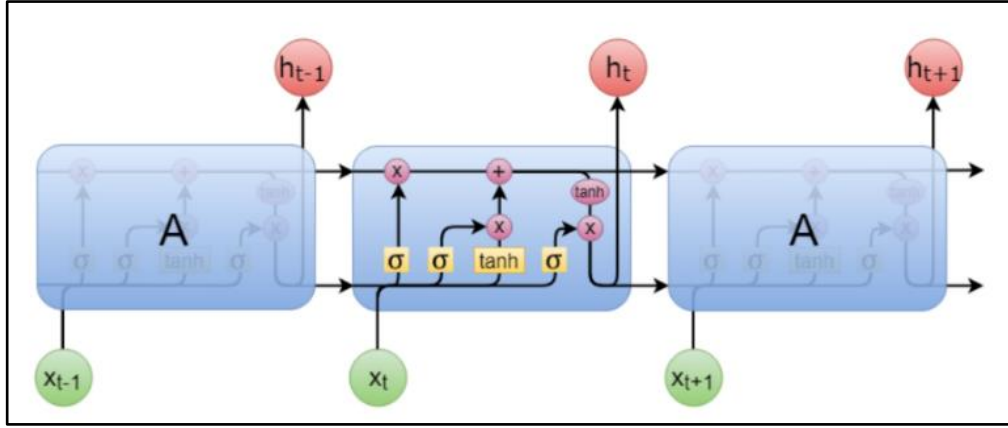
Tekrarlayan sinir ağıları (Recurrent Neural Network- RNN) 1990 yılında Jeff Elman tarafından tasarlanmıştır [47]. RNN'ler sıralı veya zamanlama modellerini öğrenmek için tasarlanmıştır. RNN geri besleme bağlantıları olan bir sinir ağıdır [50]. Şekil 5.3'te RNN yapısı verilmiştir. RNN'lerde girdi verileri işlenirken ağı hafızasındaki verilerden faydalanmaktadır. Bu sinir ağı daha çok el yazısı tanıma ve konuşma gibi uygulamalarda kullanılmaktadır. RNN'ler eğitilirken geri yayılım kullanılmaktadır [51].



Şekil 5.3. RNN yapısı.

#### 5.2.4.2. Uzun Kısa Süreli Bellek Ağları


Uzun kısa süreli bellek ağıları (Long Short-Term Memory Network- LSTM) ilk olarak 1990 ortalarında kullanılmaya başlanmıştır. LSTM'ler uzun vadeli bağımlılıkları öğrenebilmektedir. Bu sayede RNN'lerdeki uzun vadeli bağımlılıkların aktarımı sırasındaki sorunları ortadan kaldırmak için tasarlanmıştır. Şekil 5.4'da LSTM yapısı verilmektedir [52].



Şekil 5.4. LSTM yapısı.

### 5.2.4.3. Sınırlı Boltzmann Makineleri

Sınırlı Boltzmann makineleri (Restricted Boltzmann Machines- RBM), doğrusal olmayan işlem birimi katmanına sahip standart bir ileri beslemeli sinir ağı olarak adlandırılmaktadır. Düğümlerin ve kenarların sırasıyla nöronlara ve sinaptik bağlantılara karşılık geldiği stokastik bir sinir ağıdır. Gözlenebilir verileri temsil eden görünebilir birimlerden ve gözlenen değişkenler arasındaki bağımlılıkları yakalamak için  $n$  sayıda gizli birimden oluşmaktadır. Bir RBM'nin grafiğinin yalnızca gizli katmanı ile görünür değişken katmanı arasında bağlantı bulunmaktadır [53]. Şekil 5.5'te RBM yapısı verilmektedir.




Şekil 5.5. RBM yapısı.



#### 5.2.4.4. Derin İnanç Ağları

Verilerin özelliklerinin yakalanmasında tek bir gizli RBM katmanı kullanılması en iyi yöntem olarak değerlendirilemez. RBM'in eğitiminin ardından öğrenilen özellikler ikinci bir RBM için giriş olarak kullanılabilir. Bu şekilde katman katman öğrenme sistemi derin inanç ağlarını (Deep Belief Networks- DBN) oluşturmaktadır. DBN, üç adet RBM katmanı ile elde edilmektedir. Şekil 5.6'de DBN'nin yapısı verilmektedir.




Şekil 5.6. DBN yapısı.

İlk RBM giriş katmanındaki verilerle eğitildikten sonra bu RBM'nin çıktısı ile bir sonraki RBM eğitilmektedir. Eğitimin tamamlanmasının ardından son RBM katmanı bir önceki RBM katmanının çıktısıyla eğitilmektedir. Son RBM katmanının özellikleri tüm eğitim sisteminin öğrenilmiş özelliklerini taşımaktadır [54].

#### 5.2.4.5. Derin Oto Kodlayıcılar

Oto kodlayıcılar giriş katmanlarının ve çıkış katmanlarının özelliklerinin aynı olduğu çok katmanlı yapılardır. Derin oto kodlayıcılar (Deep Auto Encoder- DAE) ise özneliklerin daha az kullanılarak başarı oranının daha yüksek olmasını hedefleyen bir yöntemdir. Bir oto kodlayıcının, kodlayıcı ve kod çözücü olmak üzere iki katmanı

vardır. Şekil 5.7’da DAE yapısı verilmiştir. Kodlayıcı katmanda, giriş katmanından alınan veriler daha küçük yapılara bölünerek şifrelenir. Kod çözücü katmanda ise şifrelenen yapıların şifresi çözülerek alınan giriş verileri tekrardan oluşturulur. DAE’ler daha çok veri sıkıştırma işlemlerinde kullanılmaktadırlar [55].



Şekil 5.7. Derin oto kodlayıcı yapısı.

#### 5.2.4.6. Evrişimli Sinir Ağları


Evrişimli sinir ağları derin öğrenmenin temel mimarisi olarak kabul edilmektedir. CNN’lerin giriş verileri genellikle görüntü ve video verileridir. Bunun sebebi CNN’lerin görüntü sınıflandırma üzerine yoğunlaşmasından kaynaklanmaktadır [56]. Son yıllarda bilgisayarlı görü alanında sıklıkla kullanılmaya başlanmıştır. CNN, konvolüsyon (Convolution), havuzlama (Pooling), doğrusallaştırılmış lineer birim (Rectified Linear Unit-Relu), tam bağlı katman (Fully Connected - FC), düzleme (Flattening) ve softmax birimlerinden oluşmaktadır [57].

##### 5.2.4.6.1. Giriş Katmanı

CNN’lerin eğitilmesi için girdi verilerine ihtiyaç duyulmaktadır. Girdi verileri giriş katmanından ağa verilmektedir. Girdi olarak verilen görüntülerin çözünürlüğü ağın başarısında kritik öneme sahiptir. Girdi görüntüsünün çözünürlüğü arttıkça eğitim süresi uzamakta ve ağın bellek ihtiyacı artmaktadır. Ayrıca ağın başarı oranı da artmaktadır. Girdi görüntüsünün çözünürlüğü azaldıkça eğitim süresi ve bellek ihtiyacı azalmaktadır. Fakat girdi görüntüsünün çözünürlüğünün azalması ağın başarı oranını düşürmektedir.

### 5.2.4.6.2. Konvolüsyon Katmanı

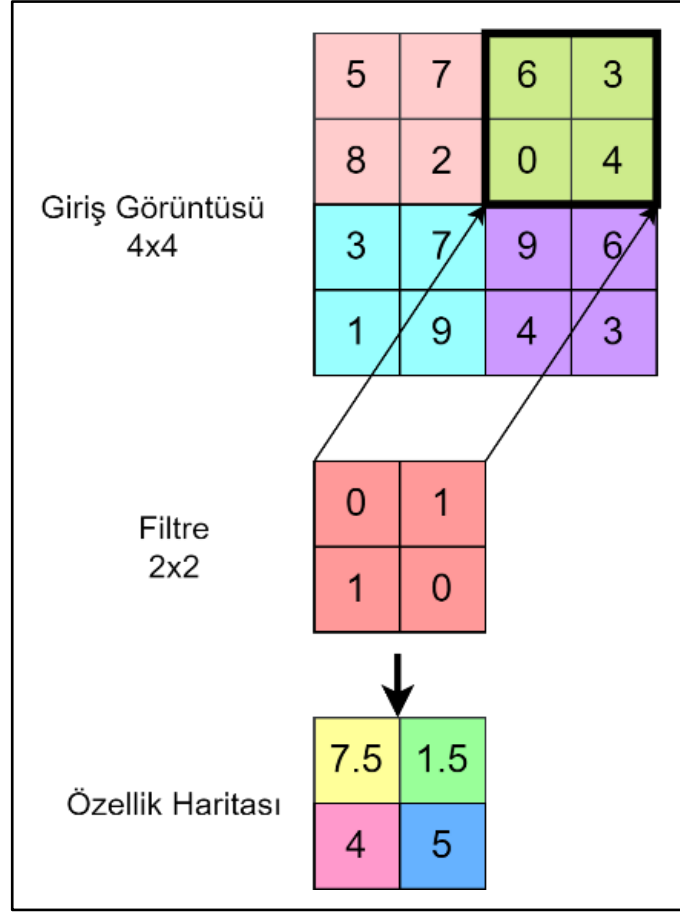
CNN'lerin temel yapısını oluşturan konvolüsyon katmanı dönüşüm katmanı ismiyle de bilinmektedir. Dönüşüm işlemi bir filtrenin bütün görüntünün üzerinde dolaştırılmasıyla yapılmaktadır. Bu filtreler 2x2, 3x3, 4x4 gibi boyutlarda olabilmektedirler. Filtre uygulaması işleminde bir önceki katmandan gelen veriler kullanılmaktadır. Gelen veriler üzerine filtre işlemi uygulanarak çıkış verisi oluşturulmaktadır. Konvolüsyon işleminde, gelen veriler ilk olarak matrise dönüştürülmektedir. Eğer giriş görüntüsü siyah beyaz ise  $A \times A \times 1$  boyutunda, eğer giriş görüntüsü renkli bir görüntü ise  $A \times A \times 3$  boyutunda matrisleri oluşturmaktadır. Matrislerin oluşturulmasından sonra matrisler üzerine filtre uygulanmaktadır. Uygulanan filtre belirli adım (stride) sayısı ile sağa veya sola kaydırılmaktadır. Şekil 5.8'da adım sayısı ile sağa kaydırılan bir filtre örneği verilmektedir.



Şekil 5.8. Adım sayısı bir'e eşit olan sağa kayma örneği.

Kaydırma esnasında matrisin sınırlarına ulaşıldığında, filtre bir basamak aşağı kaydırılarak uygulanmaya devam edilmektedir. Filtre işlemine matrislerin sonuna gelene kadar devam edilmektedir. Filtre uygulanırken matris içerisindeki renk bilgileri ile filtre üzerindeki katsayıların çarpılıp, çarpımların toplanmasıyla özellik haritası oluşturulmaktadır. Özellik haritasındaki değerler giriş görüntüsündeki yoğunluğu sağlayabilmesi için normalize edilmektedir.

Normalize işlemi özellik haritasındaki değerler ile filtre katsayılarının toplamının bölümüne eşit olmaktadır. Özellik haritasında, filtrelere özgü özellikler keşfedilmektedir. CNN'lerin eğitimi sırasında filtrelerin katsayıları değiştirilerek görüntünün hangi bölgesinin önemli olduğu belirlenmektedir. Şekil 5.9'da  $4 \times 4 \times 1$  boyutundaki bir giriş görüntüsünün konvolüsyon işlemi verilmiştir [56]. Bu işlemde filtre  $2 \times 2$  ve adım sayısı 2 olarak seçilmiştir.



Şekil 5.9. 4x4x1 boyutundaki giriş görüntüsünün konvolüsyon işlemi.

#### 5.2.4.6.3. Doğrusallaştırılmış Lineer Birim

Bu katman konvolüsyon katmanından hemen sonra gelmektedir. Aktifleştirme katmanı olarak bilinen ReLu, konvolüsyon katmanın çıkışındaki matriste bulunan negatif değerleri sıfıra eşitlemekte ve pozitif değerleri korumaktadır. ReLu'nun amacı ağı daha hızlı ve daha etkili eğitiminin sağlanmasıdır. Ayrıca CNN'lerde çoğunlukla görüntü işlendiğinden matris değerleri 0-255 aralığında olması gerekmektedir [57].


#### 5.2.4.6.4. Havuzlama Katmanı

ReLu katmanından hemen sonra gelen havuzlama katmanı bir sonraki katman için çıkış görüntüsünün genişlik ve yükseklik değerlerini düşürmektedir. Yapılan işlem sonucunda ağı derinlik boyutu değişmemektedir. Havuzlama katmanında örnek azaltma (down-sampling) işlemi yapılmaktadır. Örnek azaltma işleminin sonucunda

bir sonraki katman daha az hesaplama yapmaktadır. Ayrıca işlem sonucu bilgi kaybını da beraberinde getirdiğinden ağız ezber yapma olasılığını önlemektedir. Havuzlama katmanında uygulanan filtreler maksimum değer alma, minimum değer alma ve değerlerin ortalamasını alma olarak ayrılmaktadır. Bu filtrelerden maksimum değer alma işlemi daha performanslı olduğundan tercih edilmektedir [56].

#### 5.2.4.6.5. Tam Bağlı Katman

Bu katmanda ağız çıkışındaki son görüntü matrisi vektöre dönüştürülmektedir. Bu sayede görüntü, yapay sinir ağı girişine uygun şekilde dönüştürülmektedir. Bu işlem sonucu üretilen vektörlerdeki her bir değer yapay sinir ağı için öznelik oluşturmaktadır.

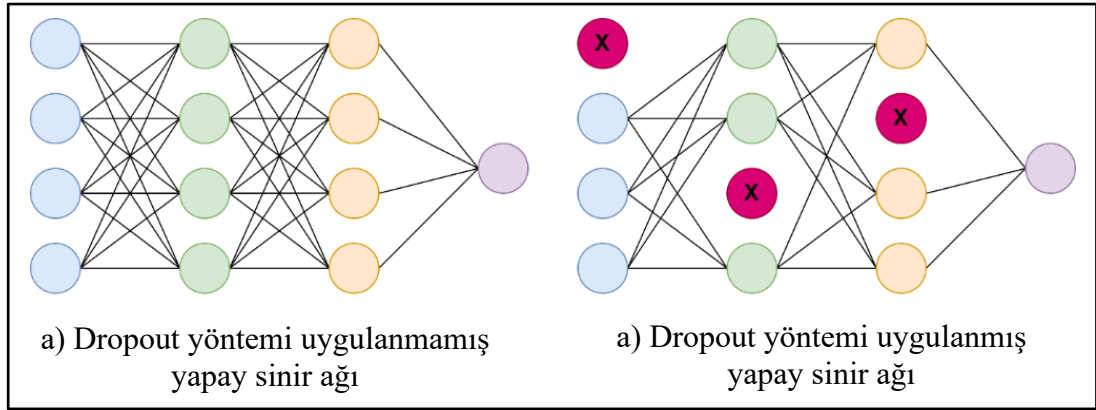


Şekil 5.10. Tam bağlı katman yapısı.

Bu yapıya adını veren tam bağlı ifadesi, FC yapısında bulunan her nöronun kendilerinden sonraki FC yapısındaki her bir nöronla arasında bağlantı olmasından gelmektedir. Bu şekilde her nöronun birbiriyle bağlı olması çok fazla sayıda parametrenin ayarlanmasını gerektirmektedir. Bunu önlemek için Dropout yöntemi kullanılmaktadır [57]. Şekil 5.10'de tam bağlı katman yapısı verilmiştir.

#### 5.2.4.6.6. Dropout Yöntemi


Bu yöntemde benzer nöronlar yapay sinir ağı modelinden kaldırılarak hem eğitimin hızlandırılması hem de ağı ezber yapmasının önüne geçilmiş olmaktadır. Şekil 5.11’de dropout yöntemi uygulanmamış ve dropout yöntemi uygulanmış yapay sinir ağı verilmektedir.



Şekil 5.11. Dropout yöntemi uygulanmamış ve uygulanmış yapay sinir ağı

#### 5.2.4.6.7. Sınıflandırma Katmanı

Tam bağlı katmandan hemen sonra gelen sınıflandırma katmanında nesnelerin sınıflandırılması yapılmaktadır. Sınıflandırma katmanının çıkış değeri sınıflandırılacak nesne sayısıdır. Örneğin görüntüde üç farklı nesne tanımlanacaksa sınıflandırma katmanının çıkış değeri 3’e eşittir. Şekil 5.12’de örnek bir CNN modeli verilmektedir.



Şekil 5.12. Örnek bir CNN yapısı.


Sınıflandırma yapılırken softmax fonksiyonu kullanılmaktadır. Sınıflandırmada sonucunda her nesne 0 ile 1 aralığında bir değere sahip olmaktadır. 1 değerine en yakın olan nesne ağı tahmin ettiği nesne olarak kabul edilir [56].

### 5.2.5. Derin Öğrenme Modelleri

Derin öğrenmenin popüler olması 2012 yılında yapılmış olan ImageNet yarışmasına dayanmaktadır [58]. Bu yarışmada nesne tanımak için çeşitli algoritmalar birbirleriyle kıyaslanmıştır. Yarışmada derin öğrenme modelleri, diğer nesne tanıma algoritmalarına göre nesne tanımda oldukça başarılı sonuçlar ortaya koyması nedeniyle ön plana çıkmıştır [49]. 2012 ile 2015 yılları arasında yarışmayı kazanan derin öğrenme modelleri, derin öğrenmede oldukça önemli bir yere sahiptir [56]. Bunlar; AlexNet, ZFNet, VGGNet, GoogLeNet, Microsoft ResNet'dir [59]. Ayrıca bunların dışında R-CNN, Fast R-CNN, SSD ve Yolo gibi modellerde bulunmaktadır.

#### 5.2.5.1. LeNet Ağı


1998 yılında Yann LeCun ve arkadaşları tarafından banka çekleri ve posta zarfları üzerindeki numaraları tanımak için geliştirilmiştir [60]. LeNet adı verilen bu ağ ilk evrişimli yapay sinir ağı olarak nitelendirilmektedir. LeNet ağı 0 ile 9 arasındaki rakamları tanımaktadır. Şekil 5.13'te LeNet mimarisi verilmektedir. Veri tabanı olarak MNIST veri tabanı kullanılmıştır. LeNet mimarisinde, konvolüsyon, alt örnekleme ve tam bağlı katmanları bulunmaktadır [49].



Şekil 5.13. LeNet mimarisi.

### 5.2.5.2. AlexNet Ağı

2012 yılında ImageNet yarışmasında birinci olan AlexNet, Alex Krizhevsky ve arkadaşları tarafından geliştirilmiştir [61]. Hata oranı %15,3 olan AlexNet, bu başarısı sayesinde derin öğrenme modelleri arasında tanınırlığını arttırmıştır. 8 katmandan oluşan AlexNet'in ilk beş katmanı konvolüsyon, son üç katmanı ise tam bağlı katmanlardır. Her konvolüsyon katmanının ardından ReLu fonksiyonu uygulanmaktadır [49]. AlexNet mimarisinde girişi resmi 224x224 piksel boyutlarındadır. Adım kayma sayısı 4 piksel ve filtre boyutu 11x11 piksel olarak seçilmiştir. AlexNet mimarisi 1000 nesneyi sınıflandırabilmektedir [56]. AlexNet mimarisinde bulunan iki ayrı konvolüsyonel ağın bulunmasından ve ağın içinde bulunan verilerin miktarının fazla olmasından dolayı işlem süresi standart bir işlemciyle oldukça uzun zaman almaktadır. Bunu engellemek için GPU (Graphical Processing Unit- Grafik İşlem Birimi) kullanılmaktadır [49]. Şekil 5.14'da AlexNet mimarisi verilmiştir [61].



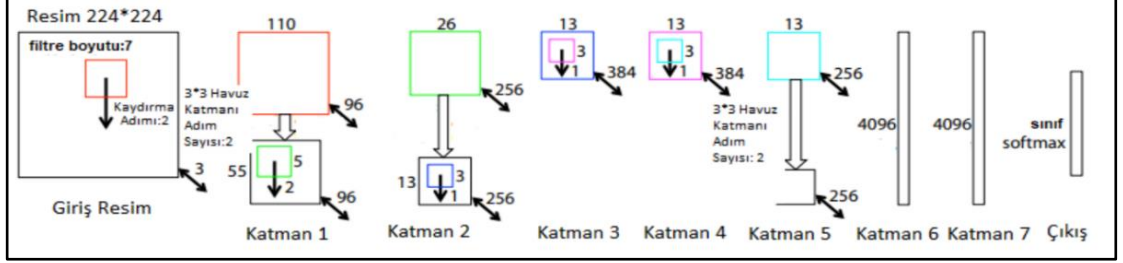
Şekil 5.14. AlexNet mimarisi.

### 5.2.5.3. ZFNet Ağı

2013 yılında ImageNet yarışmasının birincisi olan ZFNet, Matthew Zeiler ve Rob Fergus tarafından geliştirilmiştir. AlexNet üzerine geliştirilen ZFNet'in hata oranı %11,2 olarak tespit edilmiştir. AlexNet'in giriş katmanındaki filtre boyutu 11x11 piksel olarak kullanılmakta ZFNet'te ise 7x7 piksel olarak kullanılmıştır. Ayrıca adım kayma sayısı da AlexNet'e göre azaltılarak ZFNet'te adım kayma sayısı 2 olarak kullanılmıştır. Bu değişikliklerle ilk konvolüsyon katmanında daha küçük filtre



kullanılarak, giriş resminde daha çok piksel bilgisinin bozulmadan kullanılmasını sağlamıştır [56]. Şekil 5.15’de ZFNet mimarisi verilmektedir [58].



Şekil 5.15. ZFNet mimarisi.

#### 5.2.5.4. VGGNet Ağı

2014 yılında düzenlenen ImageNet yarışmasının ikincisi olan VGGNet, Simonyan ve Zisserman tarafından geliştirilmiştir [62].

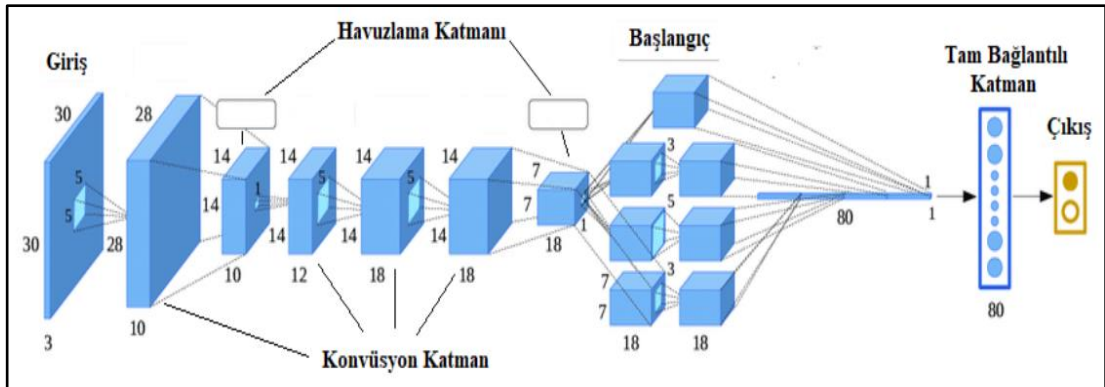
ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 <b>LRN</b>	conv3-64 <b>conv3-64</b>	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 <b>conv3-128</b>	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 <b>conv1-256</b>	conv3-256 conv3-256 <b>conv3-256</b>	conv3-256 conv3-256 conv3-256 <b>conv3-256</b>
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 <b>conv1-512</b>	conv3-512 conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 conv3-512 <b>conv3-512</b>
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 <b>conv1-512</b>	conv3-512 conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 conv3-512 <b>conv3-512</b>
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Şekil 5.16. VGGNet mimarisi.

VGGNet'in hata oranı %7,3 olarak tespit edilmiştir. VGGNet'in 6 farklı modeli bulunmaktadır. Bu modellerin birbirinden farkı konvolüsyon katman sayılarıdır. Bu modeller 11, 13, 16 ve 19 konvolüsyon katmanından oluşmaktadır. Bu modellerden VGG-16 ve VGG-19 modelleri diğer modellere göre daha fazla tercih edilmektedir. Şekil 4.18'de VGGNet mimarisi verilmiştir. Diğer mimarilere göre VGGNet'te 2x2 ve 3x3 piksellik filtreler uygulanmaktadır [49]. Şekil 5.16'da VGGNet mimarisi verilmektedir.

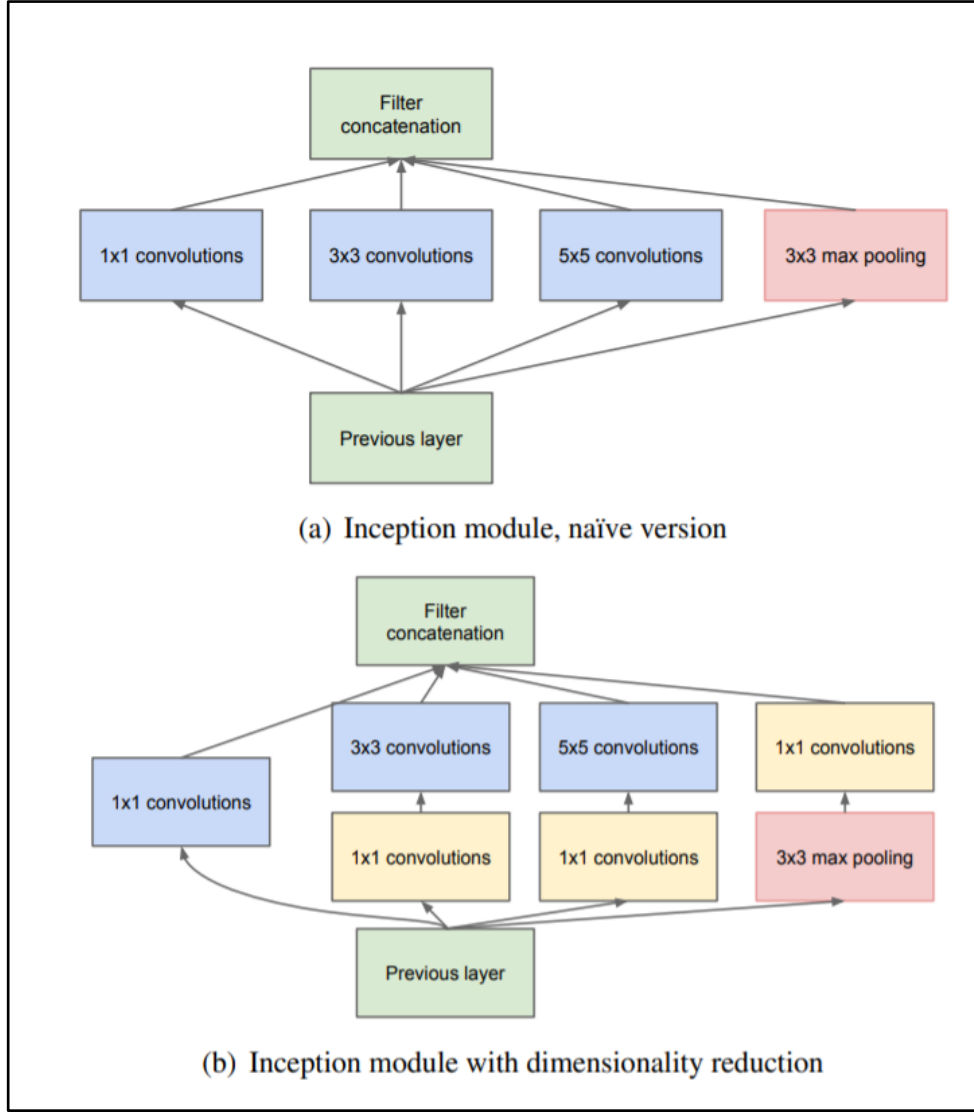
### 5.2.5.5. GoogLeNet Ağı

2014 yılında düzenlenen ImageNet yarışmasının birincisi olan GoogLeNet, Szegedy ve arkadaşları tarafından geliştirilmiştir [63]. GoogLeNet'in hata oranı %5,7 olarak tespit edilmiştir. GoogLeNet'te bulunan 22 katman, sayı olarak diğer mimarilere oldukça yüksektir. Fakat katman sayısının artırılması ve veri küme sayısının fazla olması sınıflandırma işlemi performansını da arttırmaktadır. Yüksek boyutlu girdilerin aşırı yüklenmesini engellemek için çeşitli filtreler kullanılmıştır [58]. Inception modülü olarak adlandırılan bu yapıda 1x1, 3x3 ve 5x5 piksellik filtreler kullanılmaktadır [49]. Şekil 5.17'de GoogLeNet mimarisi verilmektedir [58].



Şekil 5.17. GoogLeNet mimarisi.

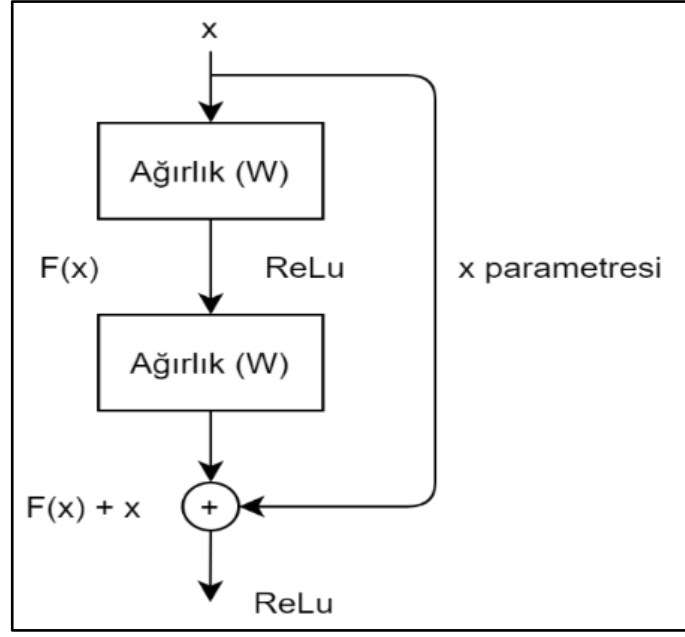
Şekil 5.18'de Inception modülü verilmektedir [63]. Diğer mimarilerden farklı olarak oluşturulan katmanlar üst üste yığılmaktansa, paralel bir şekilde bağlanmıştır. Bu sayede yüksek bellek boyutu ihtiyacını ve uzun süren işlem zamanını azaltmayı hedeflemektedirler.



Şekil 5.18. Inception modülü.

#### 5.2.5.6. Microsoft ResNet Ağı

2015 yılında düzenlenen ImageNet yarışmasının birincisi olan Microsoft ResNet, Kaiming He ve arkadaşları tarafından geliştirilmiştir [64]. 152 katmandan oluşan Microsoft ResNet diğer derin öğrenme mimarilerine göre oldukça yüksek sayıda katman bulundurmaktadır. Microsoft ResNet'in hata oranı %3,6 olarak tespit edilmiştir. Hata oranının bu kadar düşük olmasının sebebi Microsoft ResNet mimarisinde kullanılan "Residual" bloklardır. Residual bloklar, girişe uygulanan "x" değerini fonksiyon sonunda elde edilen "F(x)" değeri ile toplayan ve sonraki katmana ileten yapıya verilen isimdir. Şekil 5.19'da Residual blok yapısı verilmektedir.



Şekil 5.19. Residual blok yapısı.

### 5.2.6. YoloV3 Ağı

YoloV3 Joseph Redmon ve Ali Farhadi tarafından geliştirilen bir nesne algılama algoritmasıdır [65]. Yolo diğer nesne tespit algoritmalarına göre yeni bir yöntem getirmektedir. Bu yöntemde sınır çerçeveleri, sınıf olasılıklarının tahmini ve güven oranı gibi diğer işlemler bir regresyon sorunu olarak ele alınmaktadır. Yolo mimarisinde görüntüye bir kez bakılarak nesnelere ve nesnelere konumları tespit edilmektedir. Aynı zamanda bir CNN ağı ile görseldeki tüm nesnelere sınır çerçeveleri ve nesnelere sınıf olasılıkları tahmin edilmektedir [46].

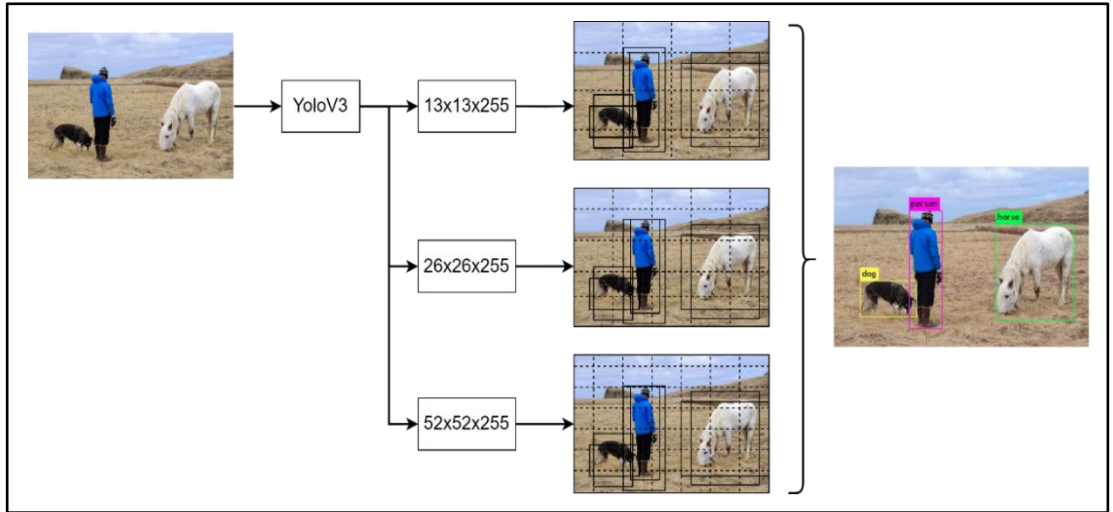
Bu tez çalışmasında derin öğrenme yöntemi olarak Yolov3 ağı kullanılmıştır. Yolov3 ağı, COCO veri seti ile kullanıldığında 22ms süre ve 28,2 mAP (Mean Average Precision – Ortalama Kesinlik Hassasiyeti) değerine sahiptir. Bu değerlere bakıldığında Yolov3 ağı 22ms sürede görüntüleri işlemekte ve bu süredeki görüntü sınıflandırma başarısı 28,2 mAP değerindedir. Aynı veri setinin kullanıldığı SSD ağı 61ms işlem süresi 28 mAP değeri, RetinaNet 73ms işlem süresi ve 32,5 mAP değerine sahiptir [65]. Diğer derin öğrenme modelleriyle karşılaştırıldığında, görüntüleri yüksek hızda ve yüksek hassasiyetle sınıflandırmasından dolayı Yolov3 ağı tercih edilmiştir.

### 5.2.6.1. YoloV3 Ağının Girişi

YoloV3 ağının giriş görüntüsünün boyutu 32 sayısının katları olarak belirlenmektedir. Görüntü derinliği olarak eğer görüntü siyah beyaz ise 1, eğer görüntü renkli ise 3 olmaktadır. Bunun sebebi ise R, G, B renk kanallarıdır [66].

### 5.2.6.2. YoloV3 Ağında Nesne Tespiti

YoloV3 ağı, girişteki görüntüleri  $A \times A$  olarak kare hücelere bölmektedir. Eğer tespit edilecek nesnenin merkezi bölünen bu kare hücelerden herhangi birinin içinde ise o hücre, nesnenin tespitinden sorumlu olmaktadır. Her hücre sınır çerçevelerini belirleyerek bu çerçeveler için güven skoru tahmin etmektedir. Tahmin edilen güven skoru, 0 ile 1 aralığında değer almaktadır. Bu değer o sınır çerçevesindeki nesnenin tahmin oranını göstermektedir [46].



Şekil 5.20. YoloV3 ağının daha iyi tespit yapabilmesi için kullanılan 3 farklı boyutta tahmin.

Şekil 5.20’de YoloV3 ağının daha iyi tespit yapabilmesi için kullanılan 3 farklı boyutta tahmin örneği gösterilmiştir. Nesnelerin daha iyi tahmin edilebilmesi için YoloV3 ağında 3 farklı boyutta tahmin yapılmaktadır. Ağa giren görüntü ilk olarak 13x13x255 olan ölçeklendirme işleminden geçer. Böylelikle büyük nesnelerin tahmini yapılmaktadır. Orta ölçekli nesneler ise 26x26x255 olan ikinci ölçeklendirme işlemi

ile tespit edilir. 52x52x255 olan, küçük nesnelere algılamak için kullanılan üçüncü ölçeklendirme işleminden sonra nesnelere sınıflandırma işlemi yapılmaktadır [66].

Şekil 5.20'deki örnekte YoloV3 ağının girişine 416x416x3 boyutunda görüntü verilmektedir. Görüntüde tanınacak nesne sayısı 3 olduğundan her bir hücrede 3 adet sınır çerçevesi tahmin edilmektedir. Ağın çıkışında her bir sınır çerçevesinin değeri verilmektedir. Bu örnekteki şekilde sınır çerçeveleri için 85 değer alınmaktadır. Bu değerlerde sınır çerçevesinin Tx, Ty, Tw, Th bilgileri ile P güven skor değeri ve sınıf olasılık değerleri bulunmaktadır. Şekil 5.21'de sınıf çerçevesi içerik parametreleri gösterilmiştir. Her bir sınır çerçevesi için bu değer ayrı ayrı elde edilmektedir. Şekil 4.22'deki örnekte COCO veri seti kullanıldığından sınıf olasılık değeri 80 olmaktadır. Bu değer tahmin edilecek sınıf sayısına göre değişkenlik göstermektedir. Hücre derinlik değeri ise sınıf olasılık değerinin tahmin edilecek nesne sayısı ile çarpımı sonucunda elde edilmektedir. Bu örnekteki hücre derinlik değeri  $85 \times 3 = 255$  olarak hesaplanmıştır.




Şekil 5.21. Sınır çerçevesi içerik parametreleri.

Sınır çerçevesi içerik parametrelerinden Tx sınır çerçevesinin x eksenindeki merkez koordinat değerini, Ty sınır çerçevesinin y eksenindeki merkez koordinat değerini, Tw sınır çerçevesinin genişlik değerini, Th sınır çerçevesinin yükseklik değerini, P güven skorunu ve C sınıf olasılık değerini ifade etmektedir.

### 5.2.6.3. YoloV3 Ağında Sınır Çerçevesinin Tespiti

YoloV3 ağında 13x13, 26x26 ve 52x52 boyutlarında çıkışlar alınmaktadır. Önceki örnekte 3 farklı nesne tespit edileceği için ağın çıkışında toplamda 10647 adet sınır çerçevesi tahmini yapılmaktadır. Bu sayı  $3 \times (13^2 + 26^2 + 52^2) = 10647$  işlemiyle bulunmaktadır. Bu işlemde 3 sayısı tespiti yapılacak nesne sayısını, 13, 26 ve 52

sayıları filtre boyutlarını belirtmektedir. Bu sonuca göre 10647 sınır çerçevesinin hepsi doğru tahmin olmamakla birlikte aynı nesne birden fazla sınır çerçevesiyle işaretlenmiş olabilmektedir. Bunu engellemek için sınır kutularının her birinde olan güven skoru değerine bakılmaktadır. Güven skoru eşik değerinin altında kalan sınır çerçeveleri elenmektedir. Geriye kalan sınır çerçevelerine NMS (Non-Maximal Suppression- Maksimum Olmayan Baskı Eşiği) uygulanmaktadır. Şekil 5.22’de aynı nesneyi işaretleyen dört farklı sınır çerçevesi verilmektedir.




Şekil 5.22. Aynı nesneyi işaretleyen dört farklı sınır çerçevesi.

NMS algoritması, aynı nesneyi çok sayıda sınır çerçevesinin algıladığı durumlarda kullanılmaktadır. Şekil 5.22’deki örnekte aynı nesneyi 0.98, 0.78, 0.62 ve 0.58 güven skoru ile işaretleyen 4 farklı sınır çerçevesi bulunmaktadır. Güven skorlarından en yüksek değeri seçebilmek için IoU (Intersection Over Union- Birlik Üzerinden Kesişme) değeri hesaplanmaktadır. Hesaplanan IoU değeri eşik değerinden büyükse güven skoru düşük olan sınır çerçevesi elenmektedir. IoU değeri, sınır çerçevelerinin kesişim ve birleşim değerlerinin oranı olarak ifade edilmektedir [66]. Eşitlik 5.1’de IoU formülü verilmektedir.

$$\text{IoU} = \frac{\text{sınır çerçevelerinin kesişim değeri}}{\text{sınır çerçevelerinin birleşim değeri}} \quad (5.1)$$

Hesaplanan IoU değeri eşik değerinden küçük çıkarsa sınır çerçeveleri arasında eleme yapılamamaktadır. Şekil 5.23'te bu durumla ilgili bir örnek verilmektedir. Bu şekilde bütün güven skorları birbirleri ile karşılaştırılarak aynı nesneyi işaretleyen sınır çerçeveleri elenmiş olmaktadır. Kalan sınır çerçeveleri çıkış olarak kullanıcıya verilmektedir.



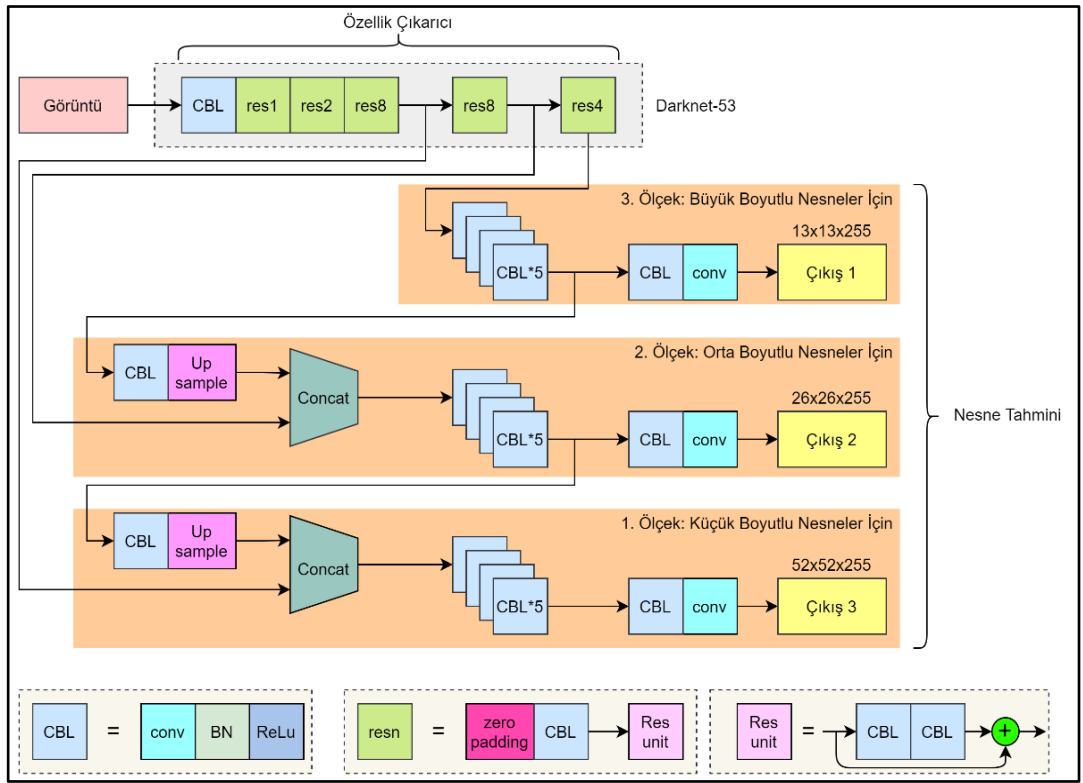
Şekil 5.23. Farklı nesnelere ait sınır çerçeveleri.

#### 5.2.6.4. YoloV3 Mimarisi

YoloV3 mimarisini geliştiren yazılımcılar tarafından yayınlanan YoloV3 çalışmasında Darknet-53 isimli bir özellik çıkarıcısı tanıtılmıştır [65]. Darknet-19 ve ResNet'in harmanlanmasıyla oluşturulan Darknet-53, adından da anlaşıldığı gibi 53 katmandan oluşmaktadır. Darknet-53 konvolüsyon, Residual ve birleşim (concatenation) katmanlarından oluşmaktadır. Konvolüsyon katmanında, 1x1 ve 3x3 boyutlarında filtreler kullanılmaktadır. Konvolüsyon katmanlarının her birinin sonrasında yığın



normalleştirme (Batch Normalization) ve ReLu işlemleri yapılmaktadır. Yığın normalleştirme katmanında konvolüsyon katmanından gelen verilerin ölçeklenmesi ve belirli bir aralığa sığdırılmasıyla verilerin düzenlenmesi sağlanmaktadır. ReLu katmanında, sıfırdan küçük değerlerin sıfıra eşitlenmesi işlemi yapılmaktadır. Residual katmanında, Residual blokların kullanılmasıyla ağız ezberleme yapması engellenmiş olmaktadır. Birleşim katmanında ise katman girişindeki 2 farklı çıkış birleştirilerek tek çıkış elde edilmektedir [66]. Şekil 5.24'te YoloV3 mimarisi verilmektedir.




Şekil 5.24. YoloV3 mimarisi.

### 5.3. DERİN ÖĞRENME TABANLI HATA TESPİT VE TEŞHİSİ

Güneş panellerindeki hücre hatası, modül hatası ve panel hatasının derin öğrenme tabanlı tespit ve teşhisinde güneş panellerinin termal görüntüleri kullanılmaktadır. Termal görüntülerdeki hatalar YoloV3 ağı ile incelenerek hatalı paneller ve panellerin hataları tespit edilmektedir. YoloV3 ağının görüntülerdeki hataları tespit edebilmesi için termal görüntülerin bulunduğu veri seti oluşturulması gerekmektedir.

### 5.3.1. Veri Seti Oluşturulması

Derin öğrenme mimarilerinin görüntülerdeki nesnelere tanımlayabilmeleri için nesnelere oluşturulan veri setlerine ihtiyaç duyulmaktadır. Bu tez çalışmasında güneş panellerindeki hücre hatası, modül hatası ve panel hatasının tespitinin yapılacağından dolayı bu hataları içeren veri setine ihtiyaç duyulmaktadır. Bu hataları içeren veri setini oluşturmak için bu hataları içeren güneş panellerine ihtiyaç duyulmaktadır. Bu hataları içeren güneş panellerinin bulunamamasından dolayı bir güneş paneli üzerinde bu hataların benzetimi yapılmaktadır. Şekil 5.25'te panel hatasının benzetimi verilmektedir.



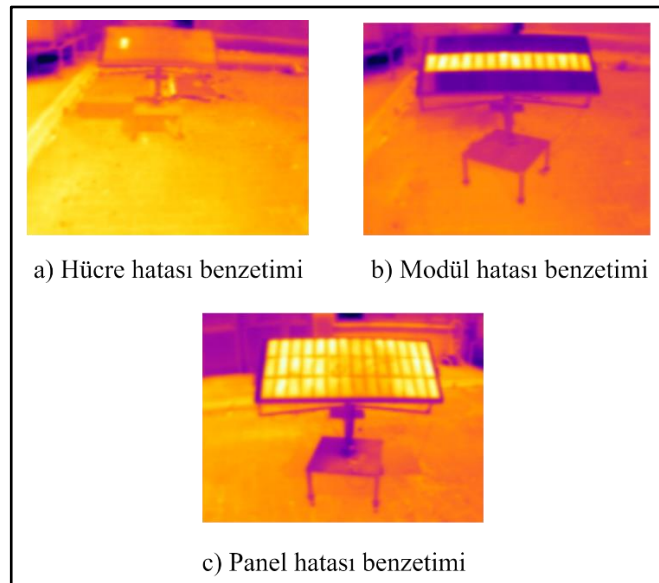
Şekil 5.25. Panel hatası benzetimi.

Güneş paneli üzerindeki hücre hatası, modül hatası ve panel hatasının termal görüntülerinin elde edilebilmesi için termal kamera kullanılması gerekmektedir. Şekil 5.25'te görüldüğü üzere panel hatasının benzetimi yapılan bir adet güneş paneli panel hatasının benzetiminin termal görüntüsünün elde edilebilmesi için bir adet termal kamera ve termal kameranın sabit tutulabilmesi için bir adet tripod kullanılmaktadır. Veri seti oluşturulurken elde edilen görüntüler güneş ışınlarının güneş paneli üzerinde dik açıyla geldiği saat aralığı olan 11:30 ile 15:30 aralığında rüzgârsız, bulutsuz ve güneşli havalarda elde edilmiştir. Şekil 5.26'da veri seti oluşturulurken kullanılan sistemin görüntüsü verilmektedir. Şekil 5.26'da kullanılan sistemde bir adet tripod, tripod üzerine sabitlenmiş FLIR DUO R termal kamera ve termal kameranın çalışması için gerekli enerjisi sağlayan bir adet taşınabilir güç kaynağı kullanılmıştır.



Şekil 5.26. Veri seti oluşturulurken kullanılan sistem


Termal kamera aracılığıyla benzetimi yapılan hataların termal görüntülerinin elde edilmesinin ardından veri setinin etiketlenmesi işlemine geçilmektedir. Şekil 5.27’de hücre hatası, modül hatsı ve panel hatasının benzetim görüntüsü verilmektedir.



Şekil 5.27. Hücre hatası, modül hatsı ve panel hatasının benzetim görüntüsü.

### 5.3.2. Veri Setinin Etiketlenmesi


Yolov3 ağıının veri setindeki görüntüleri tanımlayabilmesi için veri setinde kullanılan görüntülerin sınıflandırılması gerekmektedir. Bu sınıflandırma işlemine etiketleme adı verilmektedir. Veri setinin etiketlenmesi sırasında Labelimg isimli program kullanılmıştır. Labelimg açık kaynak kodlu bir veri etiketleme programıdır. Görüntülerdeki nesnelerin işaretlenerek açıklama yazıldığı sınırlayıcı kutuları kullanmaktadır [67]. Bu program aracılığıyla Yolov3 ağıının girişine uygun formatta görüntüler etiketlenmektedir. Şekil 5.28’de Labelimg isimli programın ekran görüntüsü verilmektedir. Bu program aracılığıyla veri setindeki görüntülerde bulunan arızaların olduğu pikseller işaretlenerek, işaretlenmiş hataların hangi hata olduğu yazılmaktadır. Etiketlemenin bitmesinin ardından Yolov3 ağıının eğitim işlemine geçilmektedir.



Şekil 5.28. Labelimg veri etiketleme programı.

### 5.3.3. Veri Setinin Eğitimi

Veri seti etiketleme işleminin ardından Yolov3 ağının eğitim işlemi yapılmaktadır. Yolov3 ağının eğitimi Nvidia Jetson TX2 yapay zeka bilgisayarı üzerinde yapılmıştır. Derin öğrenme mimarileri eğitim seti, eğitimi doğrulayacak doğrulama veri setine ve oluşturulan modelin test edilmesi için test veri setine ihtiyaç duymaktadır. Nvidia Jetson TX2 yapay zeka üzerinde eğitimi yapılan Yolov3 ağını eğitilmek için 162 adet görüntü kullanılmaktadır. Bu görüntülerden 144 adeti eğitim, 18 adeti test için kullanılmaktadır. Test için kullanılan görüntüler veri seti içerisinde rastgele olarak seçilmiştir. Test için kullanılan görüntülerden 8 adeti hücre hatası, 6 adeti modül hatası ve 4 adeti panel hatasından oluşmaktadır. Eğitim için kullanılan görüntülerden 72 adeti hücre hatası, 54 adeti modül hatası ve 36 adeti panel hatasından oluşmaktadır. Eğitim ve doğrulama veri setinde kullanılan görüntüler termal veri setindeki 162 adet görüntüden kullanılmaktadır.



Şekil 5.29. Yolov3 ağının eğitim aşamasında oluşan hata oranı grafiği.

Şekil 5.29'da Yolov3 ağının eğitim aşamasında oluşan hata oranı grafiği verilmektedir. Bu grafiğin y eksenini hata oranını, x eksenini ise eğitimin adım sayısını göstermektedir. Bu grafiğe göre eğitimin başında %18'den fazla olan kayıp oranı eğitimin 3000. adımında %0.1014 değerine kadar düşmektedir. Derin öğrenme mimarilerinde bir ağın eğitiminin tamamlandığının anlaşılması için kayıp oranının %1'den az olması gerekmektedir. Bu yüzden ağın eğitimi 3000 adımda tamamlanmaktadır. Bu eğitimin süresi yaklaşık olarak 96 saat sürmektedir. Ağın eğitimi sırasında ilk 1000 adıma kadar her 100 adımda bir ağırlık dosyaları kaydedilmektedir. 1000 adım sonrasında ise her 1000 adımda bir olarak ağırlık dosyaları kaydedilmektedir.

## BÖLÜM 6

### DENEYSEL ÇALIŞMALAR

Eğitilen Yolov3 ağı ve geliştirilen dört rotorlu insansız hava aracıyla birlikte güneş panelleri üzerinde test uçuşları yapılmış ve hata tespit uygulaması gerçekleştirilmiştir. Bu tez çalışması kapsamında yapılan deneyler Karabük Üniversitesi Teknoloji Fakültesi üzerinde bulunan güneş panelleri üzerinde gerçekleştirilmiştir. Şekil 6.1’de Karabük Üniversitesi Teknoloji Fakültesi üzerinde bulunan güneş panellerinin görüntüsü verilmektedir.



Şekil 6.1. Karabük Üniversitesi Teknoloji Fakültesi üzerinde bulunan güneş panelleri.

#### 6.1. DÖRT ROTORLU İNSANSIZ HAVA ARACI İLE UÇUŞ TESTLERİ

Dört rotorlu insansız hava aracında bulunan Navio2 uçuş kontrol kartının yazılımının yüklenmesi ve pusula, ivmeölçer ve barometrenin kalibrasyon ayarları yapılmıştır. Kalibrasyon ayarları Mission planner programı aracılığıyla yapılmaktadır. Bu ayarların ardından dört rotorlu insansız hava aracının 12 defa manuel ve 18 defa otonom uçuş testleri gerçekleştirilmiştir.

### **6.1.1. Dört Rotorlu İnsansız Hava Aracının Manuel Uçuş Testleri**

Manuel olarak yapılan uçuş testlerinde dört rotorlu insansız hava aracı kumanda aracılığıyla kontrol edilmiştir. Yapılan bu testte dört rotorlu insansız hava aracının tasarımını sırasında seçilen motorların performansı ölçülmüştür. Ayrıca tasarım sırasında seçilen pervanelerin yeterli itki gücünü sağlayıp sağlamadığı da kontrol edilmiştir. Bir önceki bölümde uçuş süresine göre hesabı yapılan Li-po bataryanın kapasitesinin yeterli olup olmadığı test edilmiştir. Kullanılan telemetri modülünün kapsama alanı ve sinyal kalite testi yapılmıştır. Son olarak uçuş kartı ile kumanda arasındaki haberleşmenin kesilme testi yapılarak manuel uçuş testi tamamlanmıştır.

Manuel uçuş testi sonuçlarına göre tasarım süresince seçilmiş olan motor ve pervanenin yeterli itki kuvvetini sağlayarak dört rotorlu insansız hava aracını başarılı bir şekilde havada tuttuğu gözlemlenmiştir. Ayrıca karbon fiber ve plakaların kullanıldığı gövdede herhangi bir titreşim durumu gözlemlenmemiştir. Telemetri modülün kapsama alanı 500m olarak ölçülmüş ve 500m'deki sinyal kalitesi %82 olarak belirlenmiştir. Yapılan testler boyunca ortalama 9dk uçuş süresinin olduğu ölçülmüştür.

Uçuş sırasında kumanda ve uçuş kontrol kartı arasındaki haberleşme kesilme testinde kumanda açma kapama düğmesinden kapatılmış ve uçuş kontrol kartıyla arasındaki bağlantı kesilmiştir. Kumandadan kontrol sinyali alamayan Navio2 uçuş kontrol kartı acil durum moduna geçerek dört rotorlu insansız hava aracını güvenli bir şekilde yere indirmiştir.

### **6.1.2. Dört Rotorlu İnsansız Hava Aracının Otonom Uçuş Testleri**

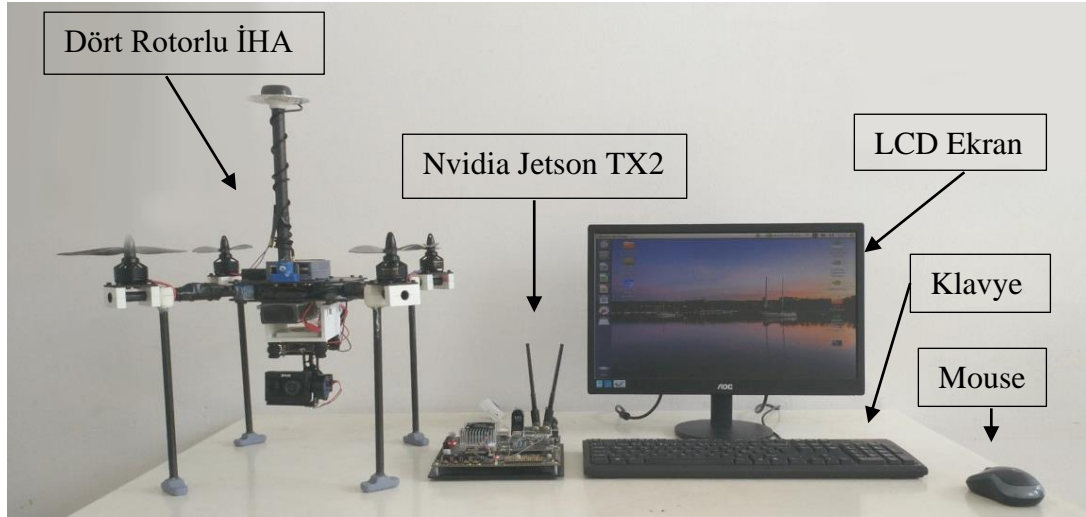
Dört rotorlu insansız hava aracının otonom uçuş testinde otonom uçuşun yapılacağı görev rotası Mission planner programında hazırlanıp Navio2 uçuş kontrol kartına yüklenmiştir. Otonom uçuş testi sırasında uçuş bilgileri Mission planner programından gözlemlenerek uçuşun görev rotasında yapılıp yapılmadığı kontrol edilmiştir. Otonom uçuş testi Karabük Üniversitesi Teknoloji Fakültesinin arka bahçesinde gerçekleştirilmiştir. Yapılan uçuş testi 20m yükseklikte 45sn'de tamamlanmıştır.



## 6.2. GÜNEŞ PANELLERİNDEKİ HATALARIN DERİN ÖĞRENME YÖNTEMİYLE TESPİT VE TEŞHİS DENEYLERİ

Yolov3 ağının eğitiminin ardından, güneş panellerindeki arızaların benzetimi yapılan çeşitli termal görüntüler ile Yolov3 ağı test edilmiştir. Yapılan bu testlerde güneş panellerindeki hataların benzetiminin yapıldığı termal görüntüler kullanılmıştır. Hücre hatası, modül hatası ve panel hatasının benzetimi bir güneş paneli üzerinde yapılmış ve her bir benzetim ile ilgili termal görüntüler FLIR DUO R termal kamera aracılığıyla elde edilmiştir. Elde edilen termal görüntüler termal kamera üzerinde takılı olan SD kart içerisine kaydedilmiştir. SD karta kaydedilen termal görüntüler Nvidia Jetson TX2 yapay zeka bilgisayarına yüklenmiş ve Yolov3 ağının testleri gerçekleştirilmiştir.


Deneysel ekipmanların görüntüsü Şekil 6.2’de verilmektedir. Güneş panellerinin termal görüntüsünün elde edilebilmesi için dört rotorlu İHA kullanılmıştır. Termal kamera takılı İHA güneş panellerinin üzerinde otonom uçuşunu gerçekleştirerek güneş panellerinin termal görüntülerini SD karta kaydetmiştir. SD karta kaydedilen görüntüler Nvidia Jetson TX2 yapay zeka bilgisayarına yüklenerek termal görüntülerdeki hataların tespiti yapılmıştır.



Şekil 6.2. Deneysel ekipmanlar.

Dört rotorlu insansız hava aracı ile güneş panellerinin termal görüntülerinin alınması sırasında otonom uçuş gerçekleştirilmiştir. Otonom uçuşun gerçekleştirilmesi için bir otonom uçuş rotasının oluşturulması gerekmektedir. Şekil 6.3’te güneş panellerindeki

hata tespit testi için oluşturulan otonom uçuş rotası verilmektedir. Oluşturulan otonom uçuş rotası Navio2 uçuş kontrol kartına yüklenmiş ve 18 defa otonom uçuş gerçekleştirilmiştir.



Şekil 6.3. Güneş panellerindeki hata tespit testi için oluşturulan otonom uçuş rotası.

Bir güneş panelinin açısı bulunduğu bölgenin coğrafi konumuna göre değişmektedir. Karabük ilinde güneş panelleri  $16^\circ$  açı ile konumlandırılmaktadır. Yapılan otonom uçuşta dört rotorlu İHA'da kullanılan gimbalin açısı  $16^\circ$ 'ye ayarlanmıştır. Gimbalin açısının  $16^\circ$  olmasıyla termal kamera güneş panellerinin termal görüntülerini  $90^\circ$  açı ile almaktadır.


	Bu					Lat	Long	Alt	Frame	Eleme	Ust	Asagi	Grad %	Angle
1	TAKEOFF	0	0	0	0	41,2136202	32,6535183	35	Relative	X	☰	☷	44416,5	89,9
2	WAYPOINT	0	0	0	0	41,2138603	32,6543766	35	Relative	X	☰	☷	45,7	24,6
3	WAYPOINT	0	0	0	0	41,2140702	32,6533923	35	Relative	X	☰	☷	0,0	0,0
4	WAYPOINT	0	0	0	0	41,2141226	32,6534030	35	Relative	X	☰	☷	0,0	0,0
5	WAYPOINT	0	0	0	0	41,2138966	32,6544410	35	Relative	X	☰	☷	0,0	0,0
6	WAYPOINT	0	0	0	0	41,2139511	32,6544356	35	Relative	X	☰	☷	0,0	0,0
7	WAYPOINT	0	0	0	0	41,2141690	32,6534030	35	Relative	X	☰	☷	0,0	0,0
8	WAYPOINT	0	0	0	0	41,2136242	32,6535183	35	Relative	X	☰	☷	0,0	0,0
9	LAND	0	0	0	0	41,2136242	32,6535156	0	Relative	X	☰	☷	-15497,2	-89,6

Şekil 6.4. Otonom uçuş rotası parametreleri.


Şekil 6.4'te otonom uçuş rotası parametreleri verilmektedir. Otonom uçuş rotasının yüksekliği 35m olarak belirlenmiştir. Bu yüksekliğin seçilmesinin sebebi güneş panellerinin termal görüntüsünün en iyi alındığı yüksekliktir. Yapılan otonom uçuşların ortalama süresi 5dk 15sn olarak ölçülmüştür. Yapılan otonom uçuş sonucunda batarya gerilimi 11.9V olarak ölçülmüştür.

Deneysel çalışmalar Şubat ve Mart aylarında yağmursuz, güneşli havalarda, hava sıcaklığının ortalama 10 derece olduğu gün içerisinde saat 11:30 ile 15:30 aralığında yapılmaktadır. Deneysel çalışmaların yapıldığı Şubat ve Mart ayları içerisinde toplam 18 defa otonom uçuş yapılmıştır.

Çizelge 6.1. Otonom uçuş sayısına göre gerçekleşen uçuş yüksekliği.



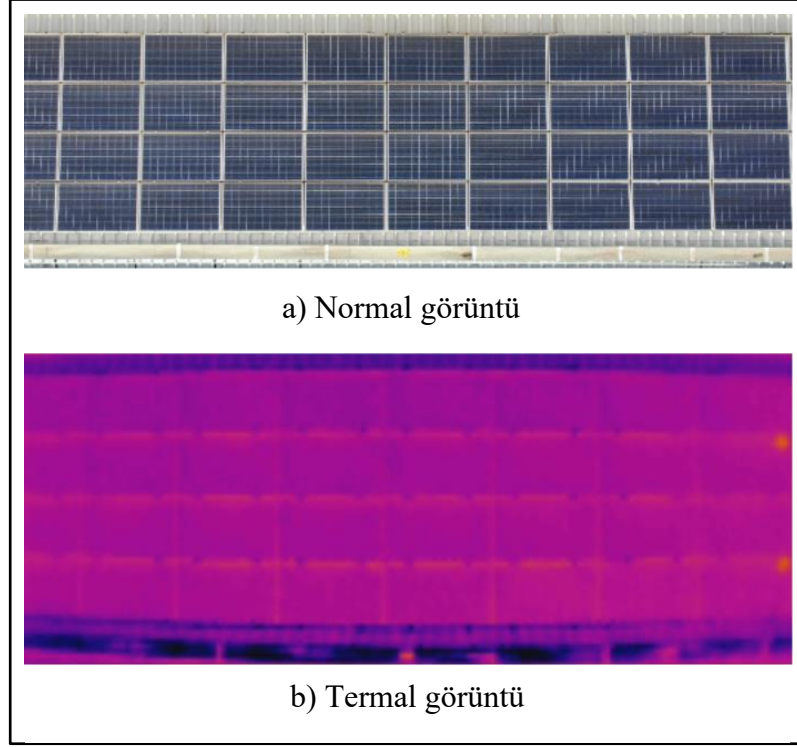
Navio2 uçuş kontrol kartının içerisinde alınan otonom uçuş verilerine göre çizelge 6.1 oluşturulmaktadır. Bu çizelgede dört rotorlu İHA'nın uçuş rotasında belirlenen 35m yüksekliğin, otonom uçuş boyunca gerçekleşen değerleri bulunmaktadır. Bu çizelge yardımıyla dört rotorlu İHA'nın otonom uçuş sırasındaki yükseklik başarımları değeri bulunabilmektedir. Başarımlar değeri, referans yüksekliğin gerçekleşen uçuş yüksekliğine bölümü ile bulunmaktadır. Otonom uçuşlar sonrası elde edilen verilere göre dört rotorlu İHA'nın yükseklik başarımları değeri %98,6 olarak hesaplanmaktadır.



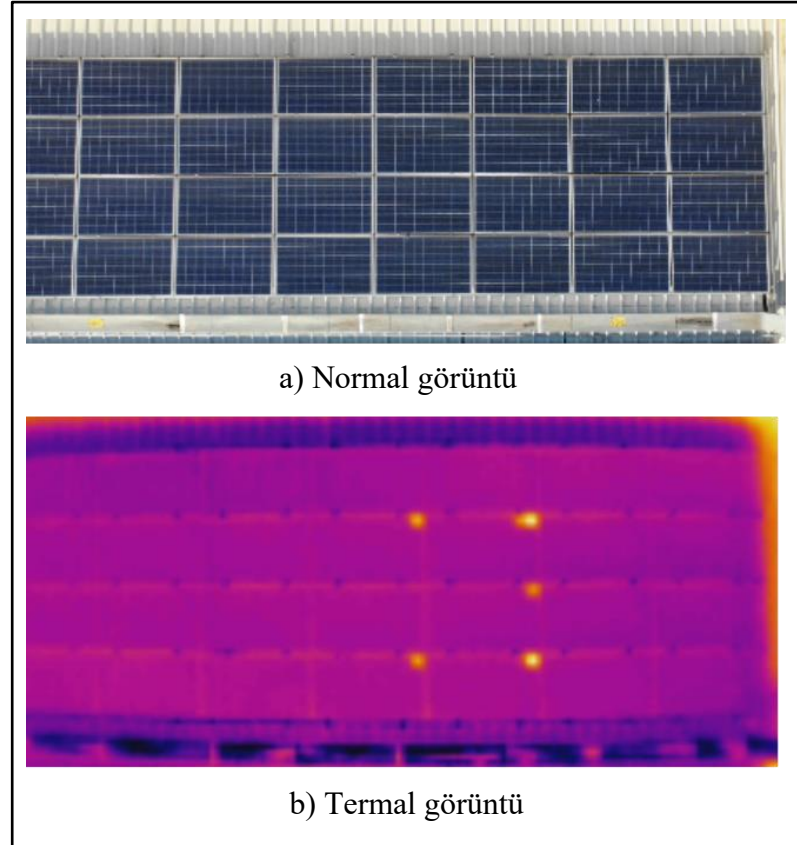
Şekil 6.5. Gerçekleşen otonom uçuş rotası.

Şekil 6.5'te gerçekleşen otonom uçuş rotasının görseli verilmektedir. Şekilde referans ve gerçekleşen otonom uçuş rotası verilmektedir. Otonom olarak yapılan 18 uçuş, 2.3m/sn hızla 35m yükseklikte gerçekleşmektedir. Uçuş kayıt verilerine bakılarak dört rotorlu İHA'nın X ve Y eksenlerindeki hata payı hesaplanmaktadır. Uçuş kayıt verilerine göre yapılan 18 uçuştaki ortalama hata X ekseninde 42cm, Y ekseninde 44cm olarak hesaplanmaktadır. Hesaplanan bu hata payı referans uçuş rotasındaki GPS koordinatları ile gerçekleşen otonom uçuş rotasındaki GPS koordinatlarının eksenlere göre farkının alınmasıyla oluşturulmaktadır. Hesaplanan bu hata payı uçuş yüksekliğide göz önüne alındığında termal kameranın görüş açısında negatif bir durum oluşturmamaktadır.

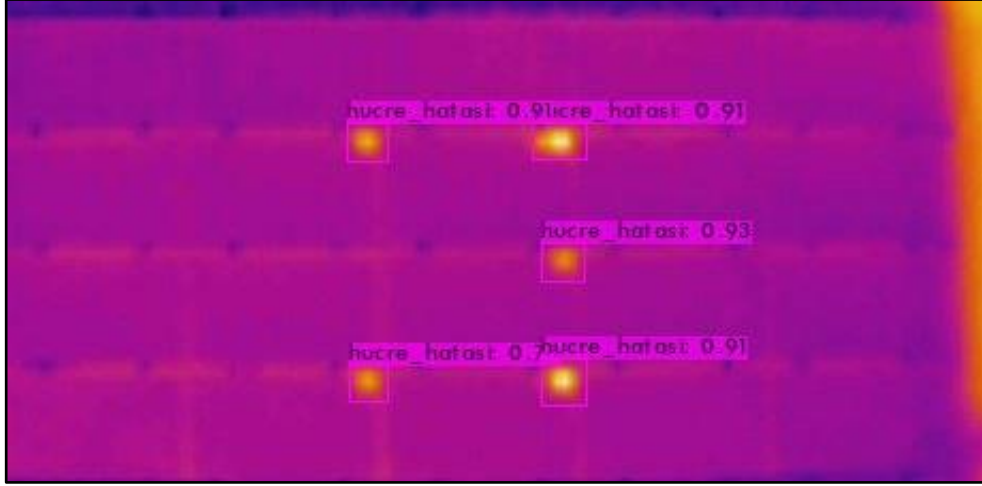
Otonom olarak yapılan uçuşların sonucunda termal görüntüler elde edilmektedir. Bu uçuşlar sırasında benzer termal görüntüler elde edilmiştir. Benzer termal görüntülerin elde edilmesinin sebebi dört rotorlu İHA'nın X ve Y eksenindeki hata payının düşük olmasından kaynaklanmaktadır. Otonom uçuşlar sırasında elde edilen sağlam güneş panelinin görüntüsü Şekil 6.6'da verilmektedir. Yapılan otonom uçuş sırasında elde edilen hatalı güneş panelinin görüntüsü Şekil 6.7'de verilmektedir. Şekil 6.8'de hatalı güneş panelinde bulunan hücre hatalarının tespit ve teşhis görüntüsü verilmektedir.



Şekil 6.6.Sağlam güneş panelinin görüntüsü.




Şekil 6.7. Hatalı güneş panelinin görüntüsü.



Şekil 6.8. Güneş panelinde bulunan hücre hataları.

Güneş panellerinin termal görüntülerinin analiz edilmesi sırasında hatalı tespit ve teşhis yapıldığı görülmektedir. Şekil 6.9’da güneş panelinde bulunan hatalı sonuçlar verilmektedir. Şekil 6.9’da yanlış olarak tespit ve teşhis edilen modül hatası ile aynı noktada birden fazla tespit ve teşhis edilen hücre hatası bulunmaktadır.



Şekil 6.9. Güneş panelinde bulunan hatalı sonuçlar.

DeneySEL çalışmaların sonunda Çizelge 6.2’deki sonuçlar elde edilmiştir. Bu çizelge gerçek hatalardan ve tahmin edilen hatalardan oluşmaktadır. Bu çizelgede her hataya ait satırdaki değerlerin toplamı o hataya ait gerçek hata sayısını, her hataya ait sütundaki değerlerin toplamı ise o hataya ait olan tahmin sayısını vermektedir.

Çizelge 6.2. Deneysel çalışma sonucu oluşan hata matrisi.

Gerçek hatalar	Hücre hatası	28	0	0
	Modül hatası	0	8	1
	Panel hatası	1	1	5
		Hücre hatası	Modül hatası	Panel hatası
Tahmin edilen hatalar				

Çizelge 6.2'ye göre gerçekte hücre hatası olan 28 görüntü bulunmaktadır. Bu görüntülere göre yapılan tahminlerin tamamı hücre hatasından oluşmaktadır. Hücre hatası olarak tahmin edilen 29 görüntü bulunmaktadır. Bu görüntülerden 1 tanesinde panel hatası, hücre hatası olarak tespit edilmektedir.

Çizelge 6.2'ye göre gerçekte modül hatası olan 9 görüntü bulunmaktadır. Bu görüntülere göre yapılan tahminlerden 8 tanesi modül hatası ve 1 tanesi panel hatası olarak tespit edilmektedir. Modül hatası olarak tahmin edilen 9 görüntü bulunmaktadır. Bu görüntülerden 1 tanesinde panel hatası, modül hatası olarak tespit edilmektedir.

Çizelge 6.2'ye göre gerçekte panel hatası olan 7 görüntü bulunmaktadır. Bu görüntülere göre yapılan tahminlerden 5 tanesi panel hatası, 1 tanesi hücre hatası ve 1 tanesi modül hatası olarak tespit edilmiştir. Panel hatası olarak tahmin edilen 6 görüntü bulunmaktadır. Bu görüntülerden 1 tanesinde modül hatası, panel hatası olarak tespit edilmektedir.

Çizelge 6.2'yi anlamlandırmak ve Yolov3 ağının başarımlarını bulmak için çeşitli terimler kullanılmaktadır. Bunlar doğruluk, kesinlik, duyarlılık ve F1 skorudur. Bu terimleri hesaplamak için pozitif doğru (TP), pozitif yanlış (FP), negatif doğru (TN) ve negatif yanlış (FN) ifadeleri kullanılmaktadır. Pozitif doğru ifadesi görüntüde bir hatanın olduğu ve bu hatanın doğru bulunduğu, pozitif yanlış ifadesi görüntüde bir hatanın olmadığı fakat tahmin sonucuna göre bir hatanın tespit edildiğini, negatif doğru ifadesi görüntüde bir hatanın bulunmadığını ve herhangi bir

hatanın tahmin edilmediğini, negatif yanlış ise hata bulunan görüntünde tahmin sonucu herhangi bir hatanın bulunmadığını ifade etmektedir. Başarım oranı hesaplanırken doğruluk, kesinlik, duyarlılık ve F1 skoru terimleri kullanılmaktadır. Bu terimlerden doğruluk ifadesi pozitif doğru ve pozitif yanlış ifadelerinin toplamının tüm ifadelere bölümü ile hesaplanmaktadır. Eşitlik 6.1’de doğruluk ifadesinin denklemi verilmektedir.

$$\text{Doğruluk} = \frac{TP+FP}{TP+FP+TN+FN} \quad (6.1.)$$

Kesinlik ifadesi pozitif doğrunun, pozitif doğru ve pozitif yanlış ifadelerinin toplamına olan bölümü ile hesaplanmaktadır. Eşitlik 6.2’de kesinlik ifadesinin denklemi verilmektedir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (6.2.)$$

Duyarlılık ifadesi pozitif doğrunun, pozitif doğru ve negatif yanlış ifadelerinin toplamına olan bölümü ile hesaplanmaktadır. Eşitlik 6.3’te duyarlılık ifadesinin denklemi verilmektedir.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (6.3.)$$

F1 skoru ise kesinlik ve duyarlılığın harmonik ortalaması alınarak hesaplanmaktadır. Eşitlik 6.4’te F1 skorunun ifadesinin denklemi verilmektedir.

$$\text{F1 skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (6.4.)$$

Yukarıdaki eşitliklere göre yapılan Yolov3 ağı başarım değerleri hesaplamaların sonuçları Çizelge 6.3’te verilmektedir. Bu çizelgede bulunan verilerden, sütundaki veriler hatalar, satırdaki veriler hatalarla ilgili başarım değerlerini ifade etmektedir. Hücre hatasının tespit ve teşhisi %97 doğrulukla, %96 kesinlikle ve %100 duyarlılıkla yapılmaktadır. Hücre hatasının F1 skoru %98 olarak bulunmaktadır. Modül hatasının tespit ve teşhisi %95 doğrulukla, %88 kesinlikle ve %89 duyarlılıkla yapılmaktadır.



Modül hatasının F1 skoru %89 olarak bulunmaktadır. Panel hatasının tespit ve teşhisi %93 doğrulukla, %83 kesinlikle ve %71 duyarlılıkla yapılmaktadır. Panel hatasının F1 skoru %77 olarak bulunmaktadır.

Çizelge 6.3. Yolov3 ağı başarımlar değerleri.

	Hücre hatası	Modül hatası	Panel hatası
Doğruluk	0,97	0,95	0,93
Kesinlik	0,96	0,88	0,83
Duyarlılık	1	0,89	0,71
F1 skoru	0,98	0,89	0,77

## BÖLÜM 7

### SONUÇLAR VE DEĞERLENDİRME

Bu tez çalışması, Karabük Üniversitesi Teknoloji Fakültesi binası üzerinde bulunan güneş panellerinin sağlık kontrolünün nasıl yapılacağı düşüncesiyle ortaya çıkmıştır. Güneş panellerindeki hataların tespit edilmesinde, panellerin sistemden ayrılmadan, uzaktan ve hızlı bir şekilde kontrol edilmesi özelliklerinden dolayı termografi yöntemi seçilmiştir. Termografi yöntemiyle, güneş panellerinden elde edilen termal görüntüler kullanılarak panellerde oluşan hücre, modül ve panel hatalarının tespiti ve teşhisi yapılmaktadır. Termografi yöntemi kullanılırken termal kameralardan faydalanılmaktadır. Bir operatörün termal kamera ile termal görüntüleri elde etmesi oldukça zaman almaktadır. Bundan dolayı çalışma kapsamında dört rotorlu bir İHA tasarlanmış ve araca termal kamera yerleştirilmiştir. Bu İHA termal kamera dahil 2.45kg ağırlığa ve 9dk otonom uçuş süresine sahiptir.

Güneş panellerindeki hücre, modül ve panel hatalarının tespit ve teşhisinde derin öğrenme tabanlı Yolov3 evrişimsel sinir ağı kullanılmıştır. Diğer derin öğrenme tabanlı evrişimsel sinir ağlarına göre aynı sürede daha yüksek doğrulukla tespit yapabilmesinden dolayı Yolov3 ağı tercih edilmiştir. Termal kamera ile hücre, modül ve panel hatalarının olduğu bir termal veri seti oluşturulmuştur. Bu termal veri seti ile Yolov3 ağı eğitilmiştir. Eğitim gömülü yapay zeka özellikli bir bilgi işlem cihazı olan Nvidia Jetson TX2 cihazında gerçekleştirilmiştir. Yolov3 ağının eğitimi 162 adet görüntü ile 3000 adımda tamamlanmıştır. Eğitimin tamamlanmasının ardından yapılan deneylerde hücre hatasının tespit ve teşhisinde %97, modül hatasının tespit ve teşhisinde %95 ve panel hatasının tespit ve teşhisinde %93 doğruluk başarıyla tespit edildiği sonucuna ulaşılmıştır.

Yapılan çalışmanın akademik yönünün haricinde bir de sanayiye uygulanabilirlik yönü bulunmaktadır. Güneş panellerinin kullanıldığı çatı uygulamalarında veya güneş

paneli tarlalarında bulunan güneş panellerinin hata tespit ve teşhisinde kullanılabilir. Geliştirilen sistemin kullanılmasıyla işletme sahipleri güneş panellerinin kondisyonu hakkında bilgi sahibi olacaktır.

Tasarlanan ve üretilen dört rotorlu İHA'nın Karabük Üniversitesi Teknoloji Fakültesi binası üzerinde bulunan güneş panellerinin taranması sırasında yeterli olduğu görülmüştür. Fakat güneş paneli tarlalarındaki panellerin taranması için uçuş süresinin artırılması gerekebilir. Bunun için dört rotorlu İHA üzerindeki bataryanın daha yüksek kapasiteli bir batarya ile değiştirilmesi veya dört rotorlu İHA'nın boyutunun küçültülmesi yeterli olacaktır.

Termal görüntülerle yapılan testler sonucunda Yolov3 ağında elde edilen doğruluk oranlarının bu çalışma kapsamında yeterli olduğu görülmektedir. Farklı tipteki güneş panellerinden elde edilecek termal görüntülerle Yolov3 ağının yeniden eğitilmesi doğruluk oranının yükseltilmesini sağlayacaktır. Güneş panellerinin termal görüntüleri elde edilirken kullanılan termal kameranın yerine bu kameraya göre daha yüksek çözünürlüklü termal kamera modellerinin kullanılması termal görüntülerdeki hataların tespit edilmesini kolaylaştıracaktır.

Gelecek çalışmalarda güneş panellerinin termal görüntüleri kullanılarak yapılacak hata tespit ve teşhisinde farklı derin öğrenme yöntemleri kullanılarak bu yöntemler arasında kıyas yapılabilir. Nvidia Jetson TX2 yapay zeka bilgisayarının dört rotorlu İHA'ya entegre edilmesiyle, elde edilen termal görüntülerin anlık olarak İHA üzerinde işlenmesi ve kullanıcıya anlık bilgi gönderilmesi sağlanabilir. Ayrıca Nvidia Jetson TX2 ile İHA'nın otonom uçuş rotası kontrol edilerek hatalı olan güneş panellerinin konumu tespit edilebilir.

## KAYNAKLAR

1. Growth, E., "Yenilenebilir Enerji ve Ekonomik Büyüme İlişkisi: G20 Ülkeleri Örneği (2000-2016)", *Int. Journal of Management Economics and Business*, 16 (2): 251–266, (2020).
2. Öztürk, C., "Güneş Enerji Sistemlerinde Verim Analizi ve Enerji Kayıplarının Tespiti", Yüksek Lisans Tezi, *Hasan Kalyoncu Üniversitesi Fen Bilimleri Enstitüsü*, Gaziantep, 50-65 (2020).
3. Spagnolo, G. S., vd., "A Review of IR Thermography Applied to PV Systems", *11th International Conference on Environment and Electrical Engineering*, Venice Italy, 879-884 (2012).
4. Köntges, M., vd., "Review of Failures of Photovoltaic Modules", *International Energy Agency Photovoltaic Power Systems Programme*, 1-140 (2014).
5. Öztemel, E., "Yapay Sinir Ağları", *Papatya Yayıncılık Eğitim*, İstanbul, 13-50 (2012).
6. Kahveci, M. ve Can, N., "İnsansız Hava Araçları: Tarihçesi, Tanımı, Dünyada ve Türkiye'deki Yasal Durumu", *Selcuk University Journal of Engineering, Science and Technology*, 5 (4): 511–535, (2017).
7. Haser, A. B., "Bu İnsansız Hava Aracı'ndan Daha Önce Yapmamış mıydık?", *Bilim ve Teknik*, 44 (517): 32–37, (2010).
8. Demir, B. E., vd., "Real-time Trajectory Tracking of an Unmanned Aerial Vehicle Using a Self-tuning Fuzzy Proportional Integral Derivative Controller", *International Journal of Micro Air Vehicles*, 8 (4): 252–268, (2016).
9. Şin, B. ve Kadioğlu, İ., "İnsansız Hava Aracı (İHA) ve Görüntü İşleme Teknikleri Kullanılarak Yabancı Ot Tespitinin Yapılması", *Turkish Journal of Weed Science*, 20 (2): 211–217, (2019).
10. Higuchi, Y. ve Babasaki, T., "Failure Detection of Solar Panels Using Thermographic Images Captured by Drone", *7th International IEEE Conference on Renewable Energy Research and Applications*, 5: 391–396, (2018).

11. Pierdicca, R., vd., "Deep Convolutional Neural Network for Automatic Detection of Damaged Photovoltaic Cells", *International Archives of The Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42 (2): 893–900, (2018).
12. Carletti, V., vd., "An Intelligent Flying System for Automatic Detection of Faults in Photovoltaic Plants", *Journal of Ambient Intelligence and Humanized Computing*, 11 (5): 2027–2040, (2020).
13. Li, X., vd., "Deep Learning Based Module Defect Analysis for Large-Scale Photovoltaic Farms", *IEEE Transactions on Energy Conversion*, 34 (1): 520–529, (2019).
14. Wei, S., vd., "Hotspots Infrared Detection of Photovoltaic Modules Based on Hough Line Transformation and Faster-RCNN Approach", *6th International Conference on Control, Decision and Information Technologies*, Paris Fransa, 1266-1271, (2019).
15. Akram, M. W., vd., "Automatic Detection of Photovoltaic Module Defects in Infrared Images with Isolated and Develop-model Transfer Deep Learning", *Solar Energy*, 198: 175–186, (2020).
16. Díaz, J. J. V., vd., "Solar Panel Detection within Complex Backgrounds Using Thermal Images Acquired by Uavs", *Sensors*, 20 (21): 1–16, (2020).
17. Huerta Herraiz, Á., vd., "Photovoltaic Plant Condition Monitoring Using Thermal Images Analysis by Convolutional Neural Network-based Structure", *Renewable Energy*, 153: 334–348, (2020).
18. Henry, C., vd., "Automatic Detection System of Deteriorated PV Modules Using Drone with Thermal Camera", *Applied Sciences*, 10 (11): 1-16, (2020).
19. Xie, X., vd., "Photovoltaic Panel Anomaly Detection System Based on Unmanned Aerial Vehicle Platform", *IOP Conference Series: Materials Science and Engineering*, 768 (7): 1-7, (2020).
20. Naveen Venkatesh, S. ve Sugumaran, V., "Fault Detection in Aerial Images of Photovoltaic Modules Based on Deep Learning", *IOP Conference Series: Materials Science and Engineering*, 1012: 1-9, (2021).
21. Kaycı, B. ve Demir, B. E., "Güneş Panellerinin Derin Öğrenme Tabanlı Sağlık Kontrolü", *V. Uluslararası Battalgazi Bilimsel Çalışmalar Kongresi*, Malatya, 202-209 (2020).

22. Bosio, A., vd., "The History of Photovoltaics with Emphasis on CdTe Solar Cells and Modules", *Coatings*, 10 (4): 1–30, (2020).
23. Sayigh, A., "Photovoltaics for Sustainable Electricity and Buildings", *Photovoltaics for Sustainable Electricity and Buildings*, Springer International Publishing, Brighton, 1–186 (2016).
24. Özçelik, S., "Fotovoltaik (PV) Teknolojileri", *Gazi Üniversitesi Fotonik Uygulama ve Araştırma Merkezi*, Ankara, 1-54 (2016).
25. Megep, "Güneş Pillerinde Üretilen Doğru Akımın Temelleri", *Millî Eğitim Bakanlığı*, Ankara, 48-53 (2012).
26. Biçen, T., "Güneş Panelleri ile Elektrik Üretiminin Teknik ve Ekonomik Analizi: Bursa Örneği", Yüksek Lisans Tezi, *Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü*, Bursa, 37-44 (2018).
27. Beyoğlu, M. F., "Balıkesir İlinde Çift Eksenli Güneş Takip Sistemi ile Sabit Eksenli PV Sistemin Verimlerinin Karşılaştırılması", Yüksek Lisans Tezi, *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü*, Balıkesir, 61-72 (2011).
28. Karpuz, G., "Güneş Paneli Üretiminde Kullanılan Yarı İletken Malzemeler", *Türk Mühendis ve Mimar Odaları Birliği Metalurji ve Malzeme Mühendisleri Odası*, Ankara, 1-3 (2020).
29. İzgi, E. ve Özcan, Ö., "Şebekeye Bağlı Fotovoltaik Çatı Sisteminin Karşılaştırmalı Performans Analizi", *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 20 (3): 127–140, (2020).
30. Akman, E., vd., "Organik Güneş Pilleri", *Trakya Üniversitesi Mühendislik Bilimleri Dergisi*, 14 (1): 1–30, (2013).
31. Oğuz, Y., vd., "Afyonkarahisar'da Kurulu Olan Monokristal, Polikristal ve İnce Film Güneş Panellerinin Verimliliğinin İncelenmesi", *Tesisat Mühendisliği Dergisi*, 23 (149): 47–58, (2015).
32. Sayın, S. ve Koç, İ., "Güneş Enerjisinden Aktif Olarak Yararlanmada Kullanılan Fotovoltaik (PV) Sistemler ve Yapılarda Kullanım Biçimleri", *Selçuk University Journal of Engineering, Science and Technology*, 26 (3): 89–106, (2011).
33. Çiçek, O. ve Karatay, S., "Küçük & Orta Ölçekli Fotovoltaik (PV) Modül Üretimi İçin Dijital PID Sıcaklık Denetimli Laminatör Deney Kiti Tasarımı ve Üretimi", *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve*

- Teknoloji*, 6 (4): 814–823, (2018).
34. Coşgun, A. E., "Detection of Photovoltaic Panel Faults with Thermal Camera and UV Led", Doktora Tezi, *Aksaray Üniversitesi Fen Bilimleri Enstitüsü*, Aksaray, 24-36 (2020).
  35. Triki-Lahiani, A., vd., "Fault Detection and Monitoring Systems for Photovoltaic Installations: a Review", *Renewable and Sustainable Energy Reviews*, 82: 2680–2692, (2018).
  36. Bozkurt, E., vd., "Dört Rotorlu İnsansız Hava Aracının Kayan Kipli Denetleyici ve Geri Adımlamalı Denetleyici ile Yönelim ve Yükseklik Denetimi", *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32 (1): 189–202, (2020).
  37. Demir, B. E., "Öz Ayarlamalı Bulanık PID Denetimli Dört Rotorlu İnsansız Hava Aracıyla Otonom Güzergâh ve Nesne Takibi", Doktora Tezi, *Karabük Üniversitesi Fen Bilimleri Enstitüsü*, Karabük, 17-55 (2017).
  38. Can, K. ve Başçı, A., "Dört Rotorlu Bir İHA'nın Geri Adımlamalı Kontrolcü ile Gerçek Zamanlı Yörünge Kontrolü", *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6 (3): 77–85, (2016).
  39. Süzen, A. A., vd., "Benchmark Analysis of Jetson TX2, Jetson Nano and Raspberry PI using Deep-CNN", *2nd International Congress on Human-Computer Interaction, Optimization and Robotic Applications*, Ürgüp, 1-5 (2020).
  40. Rungsuptaweekoon, K., vd., "Evaluating the Power Efficiency of Deep Learning Inference on Embedded GPU Systems", *2nd International Conference on Information Technology*, Beijing, 1-5 (2017).
  41. Öztürk, K. ve Şahin, M. E., "Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış", *Takvim-i Vekayi*, 6 (2): 25–36 (2018).
  42. İzmirli Ayan, S. M., "Fotovoltaik Sistemin Yapay Zeka Algoritması ile Güç Tahmini", Yüksek Lisans Tezi, *Kırklareli Üniversitesi Fen Bilimleri Enstitüsü*, Kırklareli, 33-42 (2018).
  43. Voyant, C., vd., "Machine Learning Methods for Solar Radiation Forecasting: a Review", *Renewable Energy*, 105: 569–582, (2017).
  44. Ketkar, N., "Deep Learning with Python", *Deep Learning with Python*, Apress, 202-226 (2017).

45. Aalami, N., "Derin Öğrenme Yöntemlerini Kullanarak Görüntülerin Analizi", *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 1 (1): 17–20, (2020).
46. Aktaş, A., "Derin Öğrenme Yöntemleri ile Dokunsal Parke Yüzeyi Tespiti", Yüksek Lisans Tezi, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 43-58 (2020).
47. Şeker, A., vd., "Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme", *Gazi Mühendislik Bilimleri Dergisi*, 3 (3): 47–64, (2017).
48. Hinton, G. E., vd., "The “wake-sleep” Algorithm for Unsupervised Neural Networks", *Science*, 268 (5214): 1158–1161, (1995).
49. Doğan, F. ve Türkoğlu, İ., "Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme", *DÜMF Mühendislik Dergisi*, 10 (2): 409–445, (2019).
50. Medsker, L. R. ve Jain, L. C., "Recurrent Neural Networks Design and Applications", *CRC Press*, New York, 148-161 (2001).
51. Metin, İ. A. ve Karasulu, B., "İnsan Aktivitelerinin Sınıflandırılmasında Tekrarlayan Sinir Ağı Kullanan Derin Öğrenme Tabanlı Yaklaşım", *Veri Bilimi*, 2 (2): 1–10, (2019).
52. Özer, İ., "Uzun Kısa Dönem Bellek Ağlarını Kullanarak Erken Aşama Diyabet Tahmini", *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 2 (2): 50–57, (2020).
53. Fischer, A. ve Igel, C., "Training restricted Boltzmann machines: An introduction", *Pattern Recognition*, 47 (1): 25–39, (2014).
54. Chen, Y., vd., "Spectral–Spatial Classification of Hyperspectral Data Based on Deep Belief Network", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8 (6): 2381–2392, (2015).
55. Uçar, M. ve Uçar, E., "Derin Otomatik Kodlayıcı Tabanlı Özellik Çıkarımı ile Android Kötücül Yazılım Uygulamalarının Tespiti", *Yönetim Bilişim Sistemleri Dergisi*, 5 (2): 21–28, (2019).
56. İnik, Ö. ve Ülker, E., "Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri", *Gaziosmanpaşa Journal of Scientific Research*, 6 (3): 85–104, (2017).



57. Altan, G., "DeepGraphNet: Grafiklerin Sınıflandırılmasında Derin Öğrenme Modelleri", *European Journal of Science and Technology*, 319–327 (2019).
58. Toğaçar, M. ve Ergen, B., "Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması", *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31 (1): 109–121, (2019).
59. Gündüz, G. ve Cedimoğlu, İ. H., "Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet Tahmini", *Sakarya University Journal of Computer and Information Sciences*, 2 (1): 9–17, (2019).
60. Lecun, Y., Bottou, vd., "Gradient-based Learning Applied to Document Recognition", *Proceedings of the IEEE*, 86 (11): 2278–2324, (1998).
61. Krizhevsky, A., vd., "ImageNet Classification with Deep Convolutional Neural Networks", *Communications of the ACM*, 60 (6): 84–90, (2017).
62. Simonyan, K. ve Zisserman, A., "Very Deep convolutional Networks for Large-scale Image Recognition", *3rd International Conference on Learning Representations*, San Diego, 2-8 (2015).
63. Szegedy, C., vd., "Going Deeper with Convolutions", *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Boston, 1-9 (2015).
64. He, K., Zhang, X., Ren, S., ve Sun, J., "Deep Residual Learning for Image Recognition", *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Las Vegas, 770-778 (2016).
65. Redmon, J. ve Farhadi, A., "YOLOv3: An Incremental Improvement", *ArXiv*, 1–6 (2018).
66. Kılıç, B., "Panorama ile Üretilen Plevral Efüzyon Sitopatoloji Görüntüleri Üzerinde YoloV3 ile Otomatik Çekirdek Algılama", Yüksek Lisans Tezi, *Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü*, Trabzon, 15-45 (2020).
67. Yu, C. W., vd., "Efficient Intelligent Automatic Image Annotation Method based on Machine Learning Techniques", *IEEE International Conference on Consumer Electronics*, Taiwan, 1-2 (2019).

## ÖZGEÇMİŞ

Barış KAYCI 1994 yılında İstanbul'da dünyaya geldi. İlk ve orta öğrenimini Şair Yahya Kemal İlköğretim okulunda tamamladı. 2012 yılında İSOV-DİNÇKÖK Anadolu Teknik Lisesi Elektrik-Elektronik Bölümü'nden mezun oldu. 2013 yılında Karabük Üniversitesi Teknoloji Fakültesi Mekatronik Mühendisliği Bölümü'nde öğrenime başlayıp 2018 yılında Mühendis ünvanı alarak mezun oldu. 2018 yılında Karabük Üniversitesi Lisanüstü Eğitim Enstitüsü Mekatronik Anabilim Dalı'nda yüksek lisans öğrenimine başladı ve halen öğrenimine devam etmektedir.