

**T.C.  
MİLLÎ SAVUNMA ÜNİVERSİTESİ  
ATATÜRK STRATEJİK ARAŞTIRMALAR VE LİSANSÜSTÜ  
EĞİTİM ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

**SENSÖR FÜZYONUNA DAYALI DERİN  
ÖĞRENME YÖNTEMLERİ İLE NESNE TANIMA  
BAŞARISININ ARTIRILMASI**

**DOKTORA TEZİ**

**AHMET ÖZCAN  
3171702**

**TEZ DANIŞMANI: DR.ÖĞR. ÜYESİ ÖMER ÇETİN**

**İSTANBUL  
OCAK 2023**

T.C.  
MİLLÎ SAVUNMA ÜNİVERSİTESİ  
ATATÜRK STRATEJİK ARAŞTIRMALAR VE LİSANSÜSTÜ  
EĞİTİM ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI

**SENSÖR FÜZYONUNA DAYALI DERİN  
ÖĞRENME YÖNTEMLERİ İLE NESNE TANIMA  
BAŞARISININ ARTIRILMASI**

DOKTORA TEZİ

AHMET ÖZCAN  
3171702

Tezin Enstitüye Verildiği Tarih:.....2023  
Tezin Savunulduğu Tarih : 18.01.2023

Tez Oy birliği / Oy çokluğu ile başarılı bulunmuştur.

|               |                           |      |
|---------------|---------------------------|------|
| Tez Danışmanı | Unvan Ad Soyad            | İmza |
| Jüri Üyeleri  | Dr.Öğr.Üyesi Ömer ÇETİN   |      |
|               | Prof.Dr.Sırma YAVUZ       |      |
|               | Doç.Dr. Can EYÜPOĞLU      |      |
|               | Dr.Öğr.Üyesi Ediz ŞAYKOL  |      |
|               | Dr.Öğr.Üyesi Atınç YILMAZ |      |

İSTANBUL  
OCAK 2023

## ÖZGÜNLÜK RAPORU

Tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler ve ç) Sonuç kısımlarından oluşan toplam 87 sayfalık kısmına ilişkin, 01/02/2023 tarihinde şahsım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan özgünlük raporuna göre, tezimin benzerlik oranı %5'tir.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/dâhil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Millî Savunma Üniversitesi Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü Lisansüstü Tez Çalışması Özgünlük Raporu Alınması ve Kullanılması Uygulama Usul ve Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Ahmet ÖZCAN  
02.02.2023

## ETİK BEYAN

Millî Savunma Üniversitesi Enstitüleri Dönem Projesi ve Lisansüstü Tez Hazırlama Kılavuzu'nda yer alan kurallarına uygun olarak hazırladığım bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir; aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Bu tezdeki düşünce, görüş, varsayım, sav veya tezler bana aittir; Millî Savunma Bakanlığı, Millî Savunma Üniversitesi ve Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü sorumlu tutulamaz.

Ahmet ÖZCAN

02.02.2023

Aziz Şehitlerimize, Kahraman Gazilerimize,

## ÖNSÖZ ve TEŞEKKÜR

Rehberliği, desteği ve benimle paylaştığı bilgileri ile bu tezin ortaya çıkmasında büyük pay sahibi olan tez danışmanım Dr. Öğr. Üyesi Ömer ÇETİN'e, öneri ve destekleriyle çalışmama katkıda bulunan Tez İzleme Komitesi üyeleri Prof.Dr.Sırma YAVUZ'a ve Dr. Öğr. Üyesi Atınç YILMAZ'a, bana değerli zamanlarını ayırdıkları için tez savunma jüri üyeleri Doç. Dr. Can EYÜPOĞLU'na ve Dr. Öğr. Üyesi Ediz ŞAYKOL'a, çalışmalarım süresince yol arkadaşlığı yapan Önder ALPARSLAN'a, çalışma sürecinde beni destekleyen Hezârfen Havacılık ve Uzay Teknolojileri Enstitüsü personeline, hayatım boyunca maddi ve manevi destekleriyle her zaman yanımda olan aileme teşekkür ederim.

İstanbul; Ocak 2023

Ahmet ÖZCAN

## İÇİNDEKİLER

Sayfa

|                                                                                          |      |
|------------------------------------------------------------------------------------------|------|
| ÖZGÜNLÜK RAPORU                                                                          |      |
| ETİK BEYAN                                                                               |      |
| ÖNSÖZ ve TEŞEKKÜR                                                                        |      |
| İÇİNDEKİLER .....                                                                        | vii  |
| TABLolar LİSTESİ.....                                                                    | viii |
| ŞEKİLLER LİSTESİ.....                                                                    | ix   |
| SEMBOL LİSTESİ .....                                                                     | x    |
| KISALTMALAR .....                                                                        | xi   |
| TÜRKÇE ÖZ.....                                                                           | xii  |
| İNGİLİZCE ÖZ (ABSTRACT) .....                                                            | xiv  |
| 1. GİRİŞ .....                                                                           | 1    |
| 1.1 Tezin Amacı .....                                                                    | 3    |
| 1.2 Tezin Önemi ve Özgün Değeri.....                                                     | 4    |
| 1.3 Tezde Kullanılan Yöntemler, Donanımlar ve Yazılımlar .....                           | 7    |
| 1.4 Teze Genel Bakış .....                                                               | 8    |
| 2. ÖZGÜN SENSÖR FÜZYON YÖNTEMİ.....                                                      | 11   |
| 2.1 Sensör Füzyonu .....                                                                 | 11   |
| 2.2 Literatürde Yer alan Sensör Füzyonu Yöntemleri .....                                 | 13   |
| 2.3 Önerilen Sensör Füzyon Yöntemi .....                                                 | 19   |
| 3. TERMAL, OPTİK VE UZAKLIK VERİLERİN EŞLEŞTİRİLMESİ<br>İLE NESNE TESPİT UYGULAMASI..... | 27   |
| 3.1 Sensör Füzyonu ile Ortamdaki Nesnelerin Renk ve Sıcaklık Tespiti .....               | 27   |
| 3.2 Sensör Füzyonu ile Ortamdaki Nesnelerin Sınıflandırılması.....                       | 37   |
| 4. VERİ SETİ HAZIRLANMASI.....                                                           | 41   |
| 4.1 Veri Toplanması .....                                                                | 44   |
| 4.2 Veri Seti için Toplanan Verilerden Birleşik Verilerin Oluşturulması.....             | 46   |
| 4.3 Veri Seti Üzerinde Derin Öğrenme ile Başarım Kıyaslaması.....                        | 53   |
| 4.4 Veri Seti ile Gerçekleştirilen Eğitim ve Elde Edilen Başarım .....                   | 59   |
| 5. ÇOK MODLU YAPAY SİNİR AĞI TASARLANMASI .....                                          | 62   |
| 5.1 Çok Modlu Yapy Sinir Ağı .....                                                       | 62   |
| 5.2 Çok Modlu Yapy Sinir Ağının Eğitimi ve Sınanması.....                                | 64   |
| 6. SONUÇ.....                                                                            | 67   |
| KAYNAKÇA .....                                                                           | 69   |
| EKLER.....                                                                               | 76   |
| Ek 1. Farklı Ortamlardaki Sınama Sonuçları .....                                         | 76   |
| ÖZGEÇMİŞ.....                                                                            | 87   |

## TABLÖLAR LİSTESİ

|                                                                                            | Sayfa |
|--------------------------------------------------------------------------------------------|-------|
| <b>Tablo 1.1:</b> Tez çalışmasında kullanılan donanım ve yazılımlar.....                   | 8     |
| <b>Tablo 2.1:</b> Füzyon Yönteminin Literatürdeki Yöntemler ile Kıyası.....                | 18    |
| <b>Tablo 2.2:</b> Uzaklığa göre kalibrasyon değerleri .....                                | 26    |
| <b>Tablo 3.1:</b> Sınıflandırma için aralıklar .....                                       | 39    |
| <b>Tablo 4.1:</b> Toplanan verilerin ortamlara göre dağılımı .....                         | 45    |
| <b>Tablo 4.2:</b> İlgi Alanı ve Birleşim Görselleri .....                                  | 49    |
| <b>Tablo 4.3:</b> Tüm Veri Setinde Sınama Sonuçları .....                                  | 56    |
| <b>Tablo 4.4:</b> Sensör birleşiminin nesne tespitindeki başarımların artış yüzdeleri..... | 59    |
| <b>Tablo 4.5:</b> Eğitim Sonrası Sınama Sonuçları .....                                    | 60    |
| <b>Tablo 4.6:</b> Eğitim Sonrası Nesne Tespiti başarımların artış yüzdeleri.....           | 60    |
| <b>Tablo 4.7:</b> Mevcut Çalışmalarla Performans Karşılaştırması .....                     | 61    |
| <b>Tablo 5.1:</b> Sınama Sonuçları .....                                                   | 65    |
| <b>Tablo 5.2:</b> Eğitim Sonrası Nesne Tespiti başarımların artış yüzdeleri.....           | 65    |
| <b>Tablo 5.3:</b> Tek ve Çok Modlu Ağların Başarı İyileştirme Karşılaştırması .....        | 66    |

## ŞEKİLLER LİSTESİ

|             | Sayfa                                                                              |
|-------------|------------------------------------------------------------------------------------|
| Şekil 2.1:  | Çalışma Kapsamında Kullanılan Algılayıcılar..... 12                                |
| Şekil 2.2:  | Kamera ve Lidar Verisinin Birlikte Kullanımıyla Araç Tespiti..... 14               |
| Şekil 2.3:  | Optik , Termal Ve Eşiklenmiş Görüntü ..... 14                                      |
| Şekil 2.4:  | Kalibrasyon Düzenegi ..... 20                                                      |
| Şekil 2.5:  | Kalibrasyon Noktalarının Bulunarak Veri Eşleştirilmesi Akış Şeması. 21             |
| Şekil 2.6:  | 150 Cm Mesafeden Kalibrasyon Adımları..... 24                                      |
| Şekil 3.1:  | RGB-D ve Termal Verilerin Birleştirildiği Uygulama Görüntüsü..... 27               |
| Şekil 3.2:  | Anomali Tespiti Akış Şeması..... 29                                                |
| Şekil 3.3:  | Anomali Tespit Uygulaması..... 30                                                  |
| Şekil 3.4:  | Sayısal Görüntü ve Bölütleme..... 32                                               |
| Şekil 3.5:  | Mask R-CNN Yapısı ..... 33                                                         |
| Şekil 3.6:  | Renk Tespiti Yaklaşımı ..... 35                                                    |
| Şekil 3.7:  | Örnek Nesnenin Renk Tonu Kümelenmeleri ..... 35                                    |
| Şekil 3.8:  | Nesnelerin Renk Tespiti Sonucu ..... 36                                            |
| Şekil 3.9:  | Farklı Algılayıcılar ile Yapılan Tespitlerin Birleştirilmesi ..... 37              |
| Şekil 3.10: | VGG Aracı ile Veri Setinde Düzenleme ..... 38                                      |
| Şekil 3.11: | Farklı Sensörlerden Alınan Veriler Üzerinde Tespit Çalışması..... 40               |
| Şekil 4.1:  | Durum Farkındalığını Artırmak için Çok Kanallı Nesne Tespiti..... 41               |
| Şekil 4.2:  | Yüz Algılayıcı Aldatmacası Engelleme Sistemi ..... 42                              |
| Şekil 4.3:  | Örnek Çalışmalarda Görüntü Birleştirme İşlemi..... 42                              |
| Şekil 4.4:  | Algılayıcılardan Elde Edilen Veriler ve Birleştirilmiş Görüntü..... 43             |
| Şekil 4.5:  | Veri Toplama Düzenegi ..... 44                                                     |
| Şekil 4.6:  | Toplanan Verilerin Görselleştirilmesi Örneği..... 45                               |
| Şekil 4.7:  | Her Bir Algılayıcı Verisinden Elde Edilen İlgi Alanları Örnekleri..... 46          |
| Şekil 4.8:  | Üç Farklı Algılayıcıdan Elde Edilen Verilerden Üretilen<br>Örnek Görseller..... 48 |
| Şekil 4.9:  | Veri Setinde Tespit Örnekleri..... 55                                              |
| Şekil 4.10: | Veri Setinden Oluşturulan Birleşik Resimler Üzerinde<br>Tespit Örnekleri ..... 58  |
| Şekil 4.11: | Eğitim Grafiği ..... 60                                                            |
| Şekil 5.1:  | Optik Ve Termal Özellik Birleşimleri..... 63                                       |
| Şekil 5.2:  | Nesne Tespit Ağ Yapısı..... 64                                                     |
| Şekil 5.3:  | Eğitim Grafiği ..... 65                                                            |

## SEMBOL LİSTESİ

|           |                                                                       |
|-----------|-----------------------------------------------------------------------|
| $d$       | : Uzaklık Değeri                                                      |
| $r$       | : Derinlik Algılayıcısından Elde Edilen Ham Derinlik Verisi           |
| $k_1$     | : Uzaklık Hesaplama Sabiti                                            |
| $k_2$     | : Uzaklık Hesaplama Sabiti                                            |
| $k_3$     | : Uzaklık Hesaplama Sabiti                                            |
| $d_{max}$ | : En Uzak Kalibrasyon Mesafesi                                        |
| $v_{max}$ | : Dikey Düzeltmelerin En Büyük Değeri                                 |
| $t_{°C}$  | : Santigrat Derece Cinsinden Hesaplanan Sıcaklık Değeri               |
| $t_r$     | : Sıcaklık Algılayıcısından Elde Edilen Ham Sıcaklık Verisi           |
| $k_t$     | : Sıcaklık Hesaplama Sabiti                                           |
| $R_p$     | : Tespit Edilen Nesnenin Kırmızı Piksel Yoğunluk Değerlerinin Toplamı |
| $G_p$     | : Tespit Edilen Nesnenin Yeşil Piksel Yoğunluk Değerlerinin Toplamı   |
| $B_p$     | : Tespit Edilen Nesnenin Mavi Piksel Yoğunluk Değerlerinin Toplamı    |

## KISALTMALAR

|              |                                                                                                       |
|--------------|-------------------------------------------------------------------------------------------------------|
| <b>LIDAR</b> | : Işığın Tespiti ve Uzaklık Tayini (Light Detection and Ranging, Laser Imaging Detection and Ranging) |
| <b>RGB</b>   | : Kırmızı Yeşil Mavi (Red Green Blue)                                                                 |
| <b>RGB-D</b> | : Kırmızı Yeşil Mavi - Derinlik (Red Green Blue - Depth)                                              |
| <b>YSA</b>   | : Yapay Sinir Ağı                                                                                     |
| <b>İHA</b>   | : İnsansız Hava Aracı                                                                                 |
| <b>ROI</b>   | : İlgi Alanı (Region of Interest)                                                                     |
| <b>FPS</b>   | : Saniyedeki Kare Sayısı (Frame Per Second)                                                           |
| <b>SDK</b>   | : Yazılım Geliştirme Kiti (Software Development Kit)                                                  |
| <b>HSV</b>   | : Doygunluk Açıklık Değer (Hue Saturation Value)                                                      |
| <b>TP</b>    | : Ağın doğru tespit ettiği nesne sayısı (True Positive)                                               |
| <b>FP</b>    | : Ağın yanlış tespit ettiği nesne sayısı (False Positive)                                             |
| <b>FN</b>    | : Ağın tespit edemediği nesne sayısı (False Negative)                                                 |
| <b>AP</b>    | : Ortalama Kesinlik (Average Precision)                                                               |
| <b>IoU</b>   | : Ortalama kesişim ve birleşim (Intersection over Union)                                              |
| <b>RGBDT</b> | : Renkli, Derinlik ve Sıcaklık görsellerinin gri tonlamalarından 3 kanal olarak oluşturulan resim     |
| <b>RGBT</b>  | : Renkli görsel üzerine 0,8 ağırlıkla sıcaklık resim eklenmesiyle oluşan resim                        |
| <b>RT</b>    | : Derinlik verisi olmadan 3. kanal boş bırakılarak oluşturulan resim                                  |
| <b>TxR</b>   | : Renkli görsel üzerine 0,x ağırlıkla sıcaklık görseli eklenmesiyle oluşan resim                      |

## ÖZ

### **Sensör Füzyonuna Dayalı Derin Öğrenme Yöntemleri İle Nesne Tanıma Başarısının Artırılması**

Ahmet ÖZCAN

Millî Savunma Üniversitesi

Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü

İstanbul, Ocak 2023

Nesne ve özellik tespit yöntemleri, otonom araçlar, video gözetleme, kurtarma sistemleri gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Etkili bir tespit yöntemi geliştirmek için optik, termal ve derinlik gibi farklı sensör veri türleri hibrit bilgi olarak bir arada kullanılabilir. Optik verilere derinlik ve termal veriler eklenerek geliştirilecek sistemlerde tespit başarısının artmasıyla beraber tespit edilen nesneye yönelik mesafe ve sıcaklık bilgileri de belirlenebilir. Bu tez çalışmasında daha doğru bir nesne tespiti ve tespit edilen nesnelerden bilgi çıkarımı için RGB-D veriler ile termal sensör verilerini birleştirmek için basit ve etkili bir yöntem geliştirilmiştir. Sensör verilerini birleştirmek için sensörler birbirine fiziksel olarak sabitlenmiş ve aralarındaki ilişkiler önerilen yöntem ile belirlenmiştir. Görüntü işleme yöntemleri ile optik ve termal görüntülerde konumları belirlenen öznelik noktaları başarılı bir şekilde eşleştirilmiştir. Geliştirilen yöntem sensör marka ve modellerinden bağımsız, uygulanması basit ve gerçek zamanlı uygulamalarda kullanılabilecek performanstadır.

Görüntü işleme yöntemleri ile geliştirilen sensör füzyon yöntemi yapay sinir ağları ile kullanılarak çeşitli uygulamalar geliştirilmiştir. İlk uygulamada ortamda bulunan nesneler tespit edildikten sonra sıcaklık, uzaklık ve renk bilgileri belirlenmiştir. Bu çalışmada elde edilen tecrübe sayesinde bilgi çıkarımının doğruluğu için kullanılan nesne tespit yönteminin aynı zamanda nesne sınırlarını doğru biçimde çıkarabilmesi gerektiği görülmüştür. İkinci uygulamada optik derinlik ve termal veriler üzerinde örnek nesne tespiti ve özellik çıkarımı üzerinde durulmuştur. Literatürde var olan ağ yapılarından biri termal ve optik verilerle eğitilmiş ve her bir veride ayrı ayrı tespit yapılarak ortamdaki nesne konumu belirlenmiştir. Belirlenen ve sınırları çizilen nesnenin uzaklık ve sıcaklık bilgileri de çıkarılmıştır.

Çalışmanın ilerleyen bölümlerinde sensör füzyonunu sınavabilmek ve karşılaştırmalar yapabilmek için örnek nesne olarak insan belirlenmiştir. Belirlenen nesne olan insan odağında özgün hibrit veri seti oluşturulmuştur. Özgün veri seti 8 farklı ortamda 11 farklı zamanda toplanan 3310 adet optik, termal ve derinlik verisinden oluşmaktadır. Toplanan veriler özgün sensör füzyonu yöntemi ile eşleştirilerek ilgi alanları çıkarılmıştır. Veri setinden elde edilen ilgi alanı resimleri ve bu resimlerin çeşitli oranlarda birleşimi ile sınamalar yapılmıştır. Optik verilerin 0,3 ağırlığındaki termal

verilerle desteklendiđi grsellerin en iyi tespit sonularını rettiđi grlmřtr. En iyi sonucu elde edilen veriler ile sınamada kullanılan yapay sinir ađı eđitildiđinde ise bařarımın daha da arttıđı gzlenmiřtir. alıřmanın son blmnde herhangi bir n iřleme gerek duymadan termal ve optik verileri girdi olarak alabilen ve nesne tespiti yapabilen ok modlu bir ađ tasarlanmıřtır. ok modlu ađ zgn veri seti ile eđitildikten sonra sınamalar yapılmıřtır. Tm sınama sonuları tekil verilerle karřılařtırılarak aıklanmıř ve zgn sensr fzyon ynteminin bařarımı gsterilmiřtir. nerilen sensr fzyon yntemi ve ok modlu yapay sinir ađı literatrdeki yeni alıřmalara nclk edecektir.

**Anahtar Szckler:** Sensr Fzyon, İnsan Tespiti, Grnt İřleme, Yapay Sinir Ađları

Bilim Kodu: 92432

Sayfa Sayısı: xv + 87

Tez Danıřmanı: Dr. đr.yesi mer ETİN

## **ABSTRACT**

### **Increasing Object Detection Success with Deep Learning Methods Based on Sensor Fusion**

Ahmet ÖZCAN

National Defence University

Atatürk Strategic Studies And Graduate Institute

Istanbul, January 2023

Object and feature detection methods are widely used in various fields such as autonomous vehicles, video surveillance, and rescue systems. Different types of sensor data such as optical, thermal, and depth can be used together as hybrid information to develop an effective detection method. In systems that will be developed by adding depth and thermal data to the optical data, the distance and temperature information for the detected object can be determined together with the increase in detection success. In this thesis, a simple and effective method has been developed to combine RGB-D data with thermal sensor data for more accurate object detection and information extraction from detected objects. In order to combine the sensor data, the sensors are physically fixed to each other and the relationships between them are determined by the proposed method. The feature points whose positions were determined in optical and thermal images with image processing methods were successfully matched. The developed method is independent of sensor brands and models, is simple to implement, and has the performance to be used in real-time applications.

Various applications have been developed by using the sensor fusion method developed with image processing methods with artificial neural networks. In the first application, after the objects in the environment were detected, temperature, distance, and color information was determined. Thanks to the experience gained in this study, it has been seen that the object detection method used for the accuracy of information extraction should also be able to correctly extract the object boundaries. In the second application, sample object detection and feature extraction on optical depth and thermal data are emphasized. One of the existing network structures in the literature was trained with thermal and optical data, and the object location in the environment was determined by detecting each data separately. The distance and temperature information of the determined and drawn object is also extracted.

In the following parts of the study, the human was determined as a sample object in order to test the sensor fusion and make comparisons. An original hybrid data set was created with a focus on the determined object, the human. The original data set consists of 3310 optical, thermal, and depth data collected at 11 different times in 8 different environments. The areas of interest were extracted by matching the collected data with the original sensor fusion method. The tests were carried out with the pictures of

interest obtained from the data set and the combination of these pictures in various proportions. It has been seen that the images in which the optical data are supported by thermal data weighing 0.3 produce the best detection results. It was observed that the performance increased, even more, when the artificial neural network used in the test was trained with the data obtained with the best results. In the last part of the study, a multi-mode network that can take thermal and optical data as input and detect objects without any preprocessing is designed. After the multimodal network was trained with the original data set, the tests were carried out. All test results are explained by comparing with single data and the performance of the original sensor fusion method is shown. The proposed sensor fusion method and multimodal neural network will lead to new studies in the literature.

**Keywords:** Sensor Fusion, Human Detection, Image Processing, Neural Networks

Science Code: 92432

Pages: xv + 87

Supervisor: Asst. Prof. Ömer ÇETİN, Ph.D.

## 1. GİRİŞ

Veri füzyonu ile genellikle bilgi, boyut ve davranış açısından muazzam bir çeşitlilik sunan farklı veri kümelerinin birleştirilmesi amaçlanmaktadır. Bu yaklaşımın temel nedeni tek tip veriler ile problem hakkında karara varmak yerine farklı özellikler ihtiva eden veri setlerinin bir arada uyumlu kullanılması ile sistemlerin daha etkin sonuçlar üretebilmesini sağlamaktır. Tanımlı bir ilişki ile birbirlerine bağlanan farklı kaynaklara ait bilgi parçaları; farklı şekilde temsil edilen ve aynı zamanda analiz edilen veri bloklarında, birbirini tamamlayan bileşenler, olaylar veya kaynaklar tarafından paylaşılan varyasyonlar olarak durumu yansıtır. Bu farklılıklar içeren birleşim karar vericinin kararını daha etkin olarak almasını sağlar. Füzyon kapsamına alınacak veri setleri algılayıcılar tarafından anlık elde edilen gerçek zamanlı veriler olabileceği gibi geçmiş deneyimlere dayalı çevrimdışı bilgiler de olabilir. Gerek gerçek zamanlı gerekse de çevrimdışı kaynaklardan edinilir olsun bu veri setleri temsil ettikleri özellikleri etkin aktarabilmeleri açısından bellekte farklı temsil formatlarında yer alabilirler.

Aynı nesneye, olaya veya duruma ait toplanmış farklı özellikleri ihtiva eden birden fazla tipteki verinin bir füzyon şeklinde toparlanması bu veriler arasında en az ikili ilişkiler tanımlamak ile mümkün olacaktır. Kimi zaman bu ikili ilişkiler ön tanımlı olabileceği gibi kimi zaman da probleme uygun olarak gerçek zamanlı da oluşturulabilir. Ancak gerek ön tanımlı ilişkiler ile tanımlı gerekse de çevrimdışı veriler ihtiva eden veriler olsalar da füzyon şeklinde bu verileri bir bütün haline getirmek hesaplama açısından oldukça maliyetli süreçlerdir.

Son yıllarda yaşanan gelişmelerle sensörlerin çeşitliliği ve algılama yetenekleri artmaktadır. Her geçen gün daha da yaygınlaşan farklı tiplerdeki algılayıcılar, başta insansız araçlar olmak üzere çevresel durum farkındalığına ihtiyaç duyulan tüm sistemlerde kullanım alanını genişletmektedir. Arama kurtarma, gözlem, keşif gibi farklı amaçlara hizmet edecek sistemler insanlar için zorlayıcı görevleri başarıyla gerçekleştirecek özellikleri kazanmaktadır.

İnsan tespiti gözetleme, arama kurtarma ve güvenlik uygulamalarında geniş kullanım alanına sahiptir. Ancak karanlık ya da az ışıklı ortamlar, kötü hava koşulları ve görüş alanındaki bazı fiziksel varlıklar uygulamalarda zorluklara neden olabilir. Değişken ışık ve diğer rahatsız edici koşullar özellikle dış mekân uygulamalarında görüntü kalitesini düşürebilir ve algılama doğruluğunun azalmasına neden olabilir. Bu ve benzeri değişken koşullarla sık karşılaşılır ve doğal kabul edilir. Ayrıca deprem, sel, kasırga ve yangınlardan etkilenen afet bölgeleri koşulların hızla değişmesine neden olabilir.

Günümüz dünyasında çok önemli olan arama kurtarma ve gözetleme gibi görevlerinin zorlu çevresel koşullarda da başarılı olabilmesi için sistemlerin algılama yeteneklerinin artırılması gereklidir. Örneğin optik kameralar iyi aydınlatma koşulları altında yüksek doğruluk sağlayabilir ancak düşük aydınlatma koşullarında zayıf kalmaktadır. Benzer şekilde termal kameralar ısı yayan hiçbir engel olmadığında oldukça başarılıdır ancak cam ve folyo gibi engellerin varlığında düşük hassasiyetle çalışır. Bu nedenle, farklı sensörlerin birleştirilmesi gündüz ve gece gözetlenen yerlerde, değişen aydınlatma koşullarında veya sahada çok fazla engel olduğunda daha iyi algılama doğruluğu elde edilmesini sağlar. Tek bir kaynaktan gelen verileri kullanarak belirli bir sorunu çözmek yerine ortamın farklı özelliklerini içeren birden çok veri kaynağıyla çalışmak genellikle daha etkili sonuçlar üretir. Çevredeki varlıkların boyutları, rengi, mesafesi ve sıcaklığı gibi ayrıntılı bilgiler gerçek zamanlı olarak çeşitli sensör türleriyle elde edilebilir.

Çok sayıda insan kurtarma çalışmasında farklı tipteki insansız araçlar tek bir sensör kullanarak kurtarma öncesi insan algılama görevlerini gerçekleştirir (Zheng, Yang, Lu, & Zhang, 2019) (Dong, Ota, & Dong, 2021). Bununla birlikte sınıflandırma algoritmasının doğruluğu (Sneha, ve diğerleri, 2020)'te olduğu gibi aynı anda farklı sensörler kullanılarak artırılabilir. Ayrıca fazladan sensörlerin kullanılması bir kişinin tespiti ile birlikte, termal veri ile vücut sıcaklığının belirlenmesi, uzaklık verisi ile gözlemci veya nesne konumlandırılması, optik veriler ile ayırt edici özellikleri ortaya çıkarılması gibi çeşitli faydalar sağlayabilir. Tüm bu verilere aynı anda sahip olmak çevre hakkında ayrıntılı bilgi sağlayabilir ve görevin çok daha hassas bir analizini yapabilir. Örneğin ortamda istenilen herhangi bir cismin ya da bölgenin renk, sıcaklık ve uzaklık bilgileri belirlenebilir.

Etkili bir algılama sisteminin ilk şartı farklı sensörlerden elde edilen çoklu sensör verilerinin gerçek zamanlı olarak birleştirilmesidir. Sağlam bir yöntem sağlamak ve çeşitli sensörlerden zengin içerikte veriler sunmak için sensörler arasında simbiyotik bir ilişki tanımlanmalıdır. Bu ilişkiden elde edilecek eşleştirilmiş veriler kullanılan sistemin karar verme sürecini iyileştirmek için güncel bilgiler sağlamalıdır. Sensörler arasındaki ilişkiler bazı durumlarda önceden tanımlanabilir veya probleme göre anlık oluşturulabilir. Her iki durumda da verilerin birleştirilmesi hesaplama zamanına mal olur ve gerçek zamanlı uygulamaları zorlaştırır. Ayrıca birleştirme yönteminin gecikme olmadan çalışması ve sensörlerin odak noktası, görüş aralığı gibi özellikleri bilinmeden uygulanabilir olması gerekir. Diğer bir deyişle birleştirme yöntemi sensör öznitelikleri, mimarisi, üretici ve modellerinden bağımsız olmalıdır. Böylece güvenlik, gözetleme veya kurtarma gibi farklı görev ve alanlarda yöntemi esnek bir şekilde kullanmak mümkün olabilir.

Değişken koşulların mevcut olduğu yerlerde çalışması gereken insan tespiti gibi sistemler için sensör füzyonun kullanılması tek başına yeterli değildir. Çevre hakkında ayrıntılı bilgiye sahip olmanın yanı sıra nesneleri gerçek zamanlı olarak tespit edebilmek için etkin ve hızlı bir tespit algoritması gereklidir. Derin öğrenme yöntemlerindeki hızlı gelişmeler ve küçük boyutlu kartlarda grafik işlemcilerin kullanılmasıyla sınırlı işlem gücüyle bile nesneleri sınıflandırmak mümkün olmaktadır. (Alparslan & Çetin, 2021) çalışmasında gösterildiği gibi bazı sınıflandırma algoritmaları oldukça başarılı sonuçlar üretmesine rağmen hesaplama gücünü tüketmemek için tek bir sinir ağı kullanır. Ayrıca yapay sinir ağlarının performansının birleştirilmiş verilere uygun olarak iyileştirilmesi ve geliştirilmesi için veri setlerinin oluşturulması gerekmektedir. (Hwang, Park, Kim, Choi, & So Kweon, 2015) (Jia, Zhu, Li, Tang, & Zhou, 2021) (González, ve diğerleri, 2016) (Tzafestas, 2005) çalışmalarında sunulduğu gibi bir çok insan veri seti mevcut. Ancak zorlu koşullara sahip ortamlarda birleşik sensör verileri ile üretilmiş bir veri seti algılama doğrulunu artıracaktır.

## **1.1 Tezin Amacı**

Bu çalışmanın temel amacı, arama kurtarma, gözlem, keşif gibi farklı görevlerde ihtiyaç duyulan ve aşağıda listelenen problemlere çözüm üretmek olarak tanımlanabilir;

- a) Optik, termal ve : LIDAR (Light Detection and Ranging, Laser Imaging Detection and Ranging, Işık Tespiti ve Uzaklık Tayini) sensör verilerinin bir arada kullanılabilmesine yönelik füzyon yaklaşımı geliştirmek
- b) Sensör füzyonu için gereken hesaplama maliyetini en aza indirerek gerçek zamanlı sistemlerde kullanılabilecek basitlikte olmasını sağlamak
- c) Tespit edilen nesnenin temel özelliklerinin (ısı değerleri, boyutlar, konum vb.) çıkarımını farklı sensörlerden gelen verilerin eşleştirilmesi ile yapmak,
- d) Farklı sensörlerden elde edilen eşlenmiş veriler sayesinde literatürde var olan yöntemlerin başarımını artırmak,
- e) Birden fazla kaynaktan elde edilen veriler ile çalışabilen bir yapay sinir ağı modeli geliştirmek,
- f) Literatürde var olan ve geliştirilecek olan yapay sinir ağları için bir veri seti oluşturmaktır.

Bu çalışma sonucunda elde edilen kazanımlar doğrultusunda, birden fazla sensörün birlikte kullanımı sayesinde yüksek başarımlı nesne tespit ve tanımlaması ile tespit edilen nesneye yönelik çeşitli analizlerin ihtiyacına cevap verecek bir yapı ortaya koyulacaktır. Ortaya koyulacak bu yapının ister bütün halinde isterse de alt ürünleri halinde farklı sistemler ve senaryolar dahilinde özelleştirilebilir ve kullanılabilir olacağı değerlendirilmektedir.

## 1.2 Tezin Önemi ve Özgün Değeri

Bulundukları ortam hakkında bilgi toplama yetenekleri artan algılayıcılar eklendikleri araç ve sistemlere yeni görevler yapabilme yeteneği kazandırırken çeşitli problem ve yeni araştırma sahalarını da birlikte getirmektedir. Çözünürlüğü yükselen ve açıları genişleyen optik algılayıcılar sayesinde ortamın daha net görüntüsü algılanabilmektedir. Ayrıca geniş alanlarda daha kesin sonuçlarla nesne tanımlamaları yapabilme olanağı sağlanmaktadır. Termal kameralar küçülerek insansız hava araçları üzerinde taşınabilir boyutlara gelmiştir. Renkli görüntülerde ayırt edilemeyecek özellikleri içeren termal veriler diğer mini sistemlerde de kullanılabilir. Özellikle ışığın yetersiz olduğu ortamlarda termal veriler üzerinde çıkarım yapmak kolaylaşır. Herhangi bir ışık engelinin arkası ya da içerisi için de termal veriler üzerinde bilgi çıkarımı yapılabilir. Hassas kontrol sistemlerine sahip platformlar için çevresel farkındalığın gerçek zamanlı çalışabilmesi önemli bir gerekliliktir. Gerçek zamanlı

alıřma iin birden fazla sensörden elde edilen veri akışında düşük maliyetli yaklaşımlar gerekmektedir. Literatürdeki yaklaşımlar bu ihtiyaca yanıt vermemekte ve yeniliki yaklaşımlara ihtiyaç duyulmaktadır. Ayrıca farklı algılayıcılardan oluşan sistemler üzerinde algılayıcılardan gelecek veriler üzerinde işlemin doğasına uygun sensör füzyonu işlemleri gerçekleştirmek gerekmektedir. Sensör füzyonu iin de literatürde yaygın olarak kullanılan yöntemler bulunsada özelleştirilmiş işlemler iin yeni yaklaşımlara gereksinim duyulması kaçınılmazdır. Çeşitli algılayıcılardan gelen farklı özelliklerdeki bilgilerden çevrenin ve olası nesnelerin farklı özelliklerini algılanması mümkündür. Ancak algılanan bu özellikler sensör füzyonu yöntemleriyle bir araya getirilip yorumlanırsa işlemlerin gerçekleştirilmesinde başarıml artacaktır. Klasik sensör füzyonu yöntemleri ile çeşitli kaynaklardan gelen veriler ile etkin bir şekilde çalışacak yapay sinir ağı yaklaşımlarına olan ihtiyaç öngörülmektedir. Yapılan bu çalışma sayesinde farklı sensörlerden alınacak verilerin sensör füzyonu yaklaşımları ile yapay sinir ağıları üzerinde uygulanmasıyla bulunulan ortamdaki durum farkındalığı artırılacaktır. Tez kapsamında belirlenen çalışma alanı olan insan tespiti arama kurtarma, gözlem ve keşif çalışmalarında sıklıkla ihtiyaç duyulan konulardandır. Tez çalışması sonucunda ortaya çıkan tespit ve tanımlama başarısı bu alanlarda icra edilecek görevlerde karar destek sistemi olarak kullanılabilecek ve bu yönüyle verimliliğinin yükselmesine katkı sağlayacaktır.

Halihazırda literatürde sensör füzyonu ve füzyon verisi ile tespit teşhis yaklaşımları bulunmasına karşın sensör özelliklerinden bağımsız bir gerçek zamanlı füzyon yönteminin ve yöntemin sinir ağılarıyla çalışmasının bir arada olduğı çalışmaların çok kısıtlı olması geliştirilen yapının önemini ortaya koymaktadır. Geliştirilen yapı özelleştirilebilir ve çeşitli alanlara uyarlanabilir ile kendisinden sonraki çalışmalar iin öncü bir rol oynayacak potansiyele sahip olduğı da değerlendirilmektedir.

Farklı algılayıcılardan alınan verilerin sensör özelliklerinden bağımsız birleştirilerek bir arada kullanılmasına yönelik geliştirilen yöntem literatürde farklı sistem ve alanlara uygulanabilecek yeni yaklaşımlar kazandıracaktır. Tez kapsamında yapılan tespit ve tanımlama çalışmalarında kullanılacak yapay sinir ağıları temelli yaklaşımın gerçekleştirilebilmesi ve sınanabilmesi iin ihtiyaç duyulan veri seti farklı sensörlerden alınacak veriler ile oluşturularak hazırlanmıştır. Hazırlanan veri seti hem ilgili sensörler iin tek başına hem de tüm sensörlerden gelen verilerin bir arada kullanılabilmesine olanak sağlamakta ve ilgili alanda literatürdeki az sayıda

alıřmadan biri olarak yerini almaktadır. Gerekleřtirilen sensr fzyon yaklařımı ve oluřturulan ve veri seti ile uyumlu alıřabilecek bir yapay sinir ağı ihtiyaı da ortaya ıkmaktadır. Konuyla ilgili literatr incelendiğinde sınırlı sayıda alıřmanın olduėu gzlenmiřtir. Literatrdeki alıřmalardan yola ıkarak oluřturulan ok modlu yapay sinir ağı tasarımı sayesinde birden fazla sensrden alınan veriler ile nesne tespiti yapılabilmektedir. Tezde aıklanan ve sınamaları yapılan ok modlu yapay sinir ağı da literatrdeki az sayıda benzer alıřma arasında yerini alırken yeni alıřmalar iin de temel oluřturacaktır.

Bu alıřma kapsamında yaygın olarak farklı disiplinlerde kullanılacağı deėerlendirilen gerek zamanlı edinilmiş ve n tanımlı iliřkilere dayalı farklı trden veri setlerinin fzyonuna ynelik bir metot ortaya konulmuřtur. Temel ama tanımlandığı řekilde karar verme yntemlerinin ıktılarını geliřtirmeye imkn saėlayacak daha fazla bilgi ihtiva eden farklı trden verilerin karar sistemine bir arada girdi řeklinde sunulmasını saėlayacak gerek zamanlı bir fzyon mimarisini ortaya koymaktır. evresel farkındalık, nesne incelemesi, yol planlaması, otonom hareket kabiliyetinin geliřtirilmesi, anomali tespiti vb. amalar doėrultusunda farklı disiplinlerde tanımlanmış problemlerin zmnde yaygın olarak faydalanılan optik, termal ve derinlik verilerinin bu alıřmada kullanılmasına karar verilmiřtir. Gerek optik ya da derinlik gerekse de termal veriler ok farklı bellek temsil yapılarına sahiptir. Bu algılayıcılar arasında sensr fzyonu geliřtirmenin iki nemli zorluėu vardır; birincisi sensrlerin tamamının gerek zamanlı veri kaynağı olmaları ve ok hızlı bilgi toplayabilmeleri, ikincisi ise her ne kadar n tanımlı bir iliřkiye sahip olsalar dahi dinamik řekilde ok hızlı deėiřiklik gsteren bir yapıda sensr tanımlamaları olmalarıdır. Bu sensrler arasında oluřturulacak veri iliřki tanımlı dinamik zellikler ihtiva etmeli ve uyarlanabilir bir yaklařım olmalıdır. Bu iliřki tanımlı sensr fzyonu sonularının tutarlı olabilmesi iin farklı tipte sensrler ile kullanılabilirlik saėlamalı, algılayıcıya zg olmamalıdır. Tm bu kısıtlar ve tanımlar bir arada incelendiğinde en saėlıklı ve hızlı yaklařımın aynı zamanda bir grnt olarak bellekte temsil edilebilen optik, termal ve derinlik verilerinin grnt iřleme yntemlerine dayalı bir yntem ile fzyon haline getirilmesi olarak karřımıza ıkmaktadır. Bu nedenle grnt temsiline dayalı bir fzyon yaklařımı geliřtirilmesine karar verilmiřtir.

Grnt eřleřtirme iřlemi aynı algılayıcılardan alınan veriler zerinde yapılabilceėi gibi eřitli zellik ve znitelikler yardımıyla farklı trdeki algılayıcılardan elde edilen

veriler üzerinde de yapılabilir (Masood, Sharif, Yasmin, Shahid, & Rehman, 2017). Ancak görüntü işleme çalışmalarında farklı türden görüntüleri eşleştirmek literatürde yer alan başlıca sorunlardan biridir. Bu çalışmanın amacı görüş alanındaki varlıkların farklı özelliklerini algılayabilen ve odak noktası, görüş açısı gibi özellikleri bilinmeyen farklı tipteki algılayıcıların verilerini örtüştürerek ilgilenilen alan hakkında ortaya konulan dinamik ilişki çerçevesinde daha fazla bilgiye sahip olmaktır. Elde edilecek bilgiler sayesinde herhangi bir bölgenin üç boyutlu ortamdaki optik görüntüsü ısı değerleri de içerek şekilde oluşturulabilecektir. Belirli bir çevre, tanımlı bir bölge hatta bu bölge içinde yer alan nesne hakkında elde edilecek bu tip ilişkisel füzyon verilerinin halihazırda literatürde var olan çalışmalara uygulanması durumunda yöntemlerde değişikliğe gidilmeden ufak uyarlamalar yapılarak dahi başarı oranlarının artması ve yeni araştırma alanlarına olanak sağlanması beklenmektedir.

Bu çalışmada, Kırmızı Yeşil Mavi - Derinlik (RGB-D, Red Green Blue - Depth) algılayıcılar ile termal algılayıcılar arasındaki ilişki kuran ve gerçek zamanlı çalışabilen bir füzyon yöntemi önerilmiştir. Yöntemin başarısının sınanması için birleştirilmiş sensör verileri ile elde edilen bilgilerin tek bir sensör verisine göre performansı karşılaştırılmıştır. Çalışmanın ana katkısı sensör özelliklerinden bağımsız gerçek zamanlı bir füzyon yöntemi sunmasıdır. Ayrıca bu yöntemle elde edilen bir veri seti de sunulmuştur.

### **1.3 Tezde Kullanılan Yöntemler, Donanımlar ve Yazılımlar**

Çalışma kapsamında gerçekleştirilen sistem farklı sensörlerden gelen verilere dayalı tespit ve tanımlama yöntemleri ile karar vermeye dayanmaktadır. Gerçekleştirilen bu tespit ve tanımlama işlemi sonrası ise istenilen bilgiler olası işlemler için kullanılabilir hale gelmiştir.

Farklı algılayıcılardan elde edilen verileri eşleştirebilmek ve aynı anda kullanabilmek için aralarında bir ilişki kurmak gerekmektedir. Çalışmada kullanılan algılayıcılardan elde edilen veriler görüntü olarak temsil edilebilmektedir. Sensör füzyonu gerçekleştirmek için her bir algılayıcıdan elde edilen veriler görüntüye çevrilmiştir. Klasik görüntü işleme yöntemleri ile aralarındaki ilişkiler tespit edilen veriler uygun yöntemler sunularak eşleştirilmiştir.

Tezde sunulan başarısı artırılmış ve farklı algılayıcılara uyarlanabilen sistemin temelini oluşturan tespit ve tanımlama aşamasında gerekli işlemler için görüntü işleme yöntemleriyle nesne tanıma ve tespitinde başarısını kanıtlamış evrimsel sinir ağıları kullanılmıştır. Evrimsel sinir ağlarının temelinde bulunan evrim ve ortaklama katmanlarının sayısı, her bir katmandaki filtre boyutları ve adım sayıları ile aktivasyon fonksiyonları seçimi ile özelleştirilebilmekte ve yeni ağ modelleri sunulabilmektedir.

Tez çalışmasında kullanılan teknik donanım ve yazılımlar ise Tablo 1.1’de görülebilir. Kullanılan teknik donanımların ve yazılımların öznitelikleri hakkında bilgiler ilerleyen bölümlerde ayrıntılı olarak açıklanmıştır.

**Tablo 1.1: Tez Çalışmasında Kullanılan Donanım ve Yazılımlar.**

| Donanım Yazılım Türü | Temel Özellikleri                                    | Kullanım Amacı                                                                 |
|----------------------|------------------------------------------------------|--------------------------------------------------------------------------------|
| Microsot Kinect      | RGB-D algılayıcı                                     | Renk ve derinlik bilgilerini algılamak                                         |
| Seek Compact Pro     | Termal Algılayıcı                                    | Sıcaklık bilgilerini algılamak                                                 |
| Macbook Pro          | i7 8gb ram 512 ssd<br>256 nvidia gpu                 | Algılayıcı verilerinin toplanması ve sensör füzyonu için kullanılan bilgisayar |
| HP Z8                | Xenon işlemci 64 gb<br>ram 6 gb nvidia gpu           | Yapay Sinir Ağı (YSA) düzenleme ve eğitimi için kullanılan bilgisayar          |
| Nvidia Xavier        | 32 GB ram arm<br>işlemci                             | YSA performans ölçümü için kullanılan geliştirme kiti                          |
| Ubuntu               | 20.04 Bionic sürümü                                  | Geliştirmeler ve uygulamalar için kullanılan işletim sistemi                   |
| GCC 9                | C++ Derleyici                                        | C++ da yazılan sensör füzyonu ve veri toplama komutları için derleyici         |
| Python 3.9           | Python programlama<br>dili yorumlayıcısı             | Python da yazılan sensör füzyonu ve veri toplama komutları için derleyici      |
| CUDA 10              | Paralel Programlama<br>Kütüphanesi                   | C++ da gerçekleştirilen YSA uygulamaları için temel kütüphane                  |
| Tensorflow           | YSA Kütüphanesi                                      | Python da gerçekleştirilen YSA uygulamaları için temel kütüphane               |
| Colab                | Bulut ortamında<br>çalışma olanağı<br>sağlayan çözüm | Çok modlu YSA eğitim ve sınaması için kullanılan ortam                         |

#### 1.4 Teze Genel Bakış

Tez çalışmasının ilk bölümünde tezin yapılmasındaki motivasyon açıklanmış ve tez çalışmasının yöntemi ile araştırma alanı hakkında genel bilgi verilmiştir. Tez çalışmasının amacı, özgün değeri ve önemi bu bölümde açıklanmıştır. Çalışma esnasında kullanılan donanım ve yazılımlar hakkında bilgiler verilmiştir. Tez

alışmasının konusu ile ilgili literatürde var olan alışmalar üzerinde yapılan incelemeler, karşılaştırmalar ve ıkarımlar da bu bölümde açıklanmıştır.

İkinci bölümde tezin ana temasını oluşturan özgün sensör füzyon yaklaşımı açıklanmıştır. Sensör marka ve modeli ile odak noktası, görüş açısı gibi sensör özniteliklerinden bağımsız birleştirme yapabilen bu yeni yaklaşımın yöntemi anlatılmıştır. Sensör füzyon yaklaşımı uygulamalı olarak adım adım açıklanmıştır. Sensör füzyonu için elde edilen gerekli parametreleri hesaplandıktan sonra nihai kalibrasyon değerleri verilmiştir. Bu bölümde açıklanan yöntem ve sonrasında elde edilen değerler sonraki bölümlerde kullanılmıştır.

Üçüncü bölümde önceki bölümde açıklanan yöntem ve hesaplanan değer ile geliştirilen bir anomali tespit alışması açıklanmıştır. Bölümün ilk kısmında çeşitli renkteki kaplar içindeki farklı sıcaklıklardaki sıvılar hakkında ıkarımlar yapılmıştır. Uzaklığı, sıcaklığı ve rengi belirlenen nesneler hakkında daha ayrıntılı bilgi edinilmesi amacıyla yöntem iyileştirilmiştir. İyileştirilen yöntem insan tespiti için kullanılmıştır. İnsan tespiti için kullanılan yöntem sayesinde tespit edilen insanın sıcaklık ve uzaklık bilgileri elde edilmiştir. Sıcaklık ve uzaklık bilgileri makine öğrenmesi yöntemleriyle kümelenip sınıflandırılarak çeşitli aralıklarla verilen sözel ifadeler ile eşleştirilmiştir.

Dördüncü bölüme bakıldığında ise ikinci bölümde açıklanan füzyon yöntemiyle eşleştirilen verilerden özgün bir veri seti üretilmiştir. Veri seti üretmek için değişik ortamlarda, farklı ışık koşullarında insan nesnesi içerecek şekilde toplanan veriler bu bölümde örneklenmiştir. Ham halde saklanan verilerden çeşitli görüntüler ve ilgi alanları üretimi de bu bölümde açıklanmıştır. Elde edilen veriler üzerinde yapılan sınamalar ve sonuçları verildikten sonra sensör füzyon yönteminin başarısı ispatlanmıştır. Sınamalardan sonra en iyi sonuçların elde edildiği veri birleştirme yöntemi ile üretilen veriler ile yapay sinir ağı eğitilerek sonuçları açıklanmıştır.

Beşinci bölüm alışma kapsamında geliştirilen çok modlu yapay sinir ağıının açıklandığı bölümdür. Neden çok modlu bir yapay sinir ağına ihtiyaç duyulduğu bu bölümde açıklanmıştır. Önerilen yapay sinir ağıının yapısı, literatürdeki alışmalarla benzer ve farklı yönleri bu bölümde ele alınmıştır. Yapay sinir ağı üzerinde gerçekleştirilen eğitim hakkında bilgiler verilmiş ve sınama sonuçları paylaşılmıştır. Önceki bölümlerde elde edilen sonuçlar ile yapay sinir ağı sonuçları kıyaslanarak yorumlanmıştır.

Altıncı bölüm tez çalışmasının sonuç kısmıdır. Çalışmanın özgünlüğü ve çalışma sürecinde ulaşılan hedefler bu bölümde açıklanmıştır. Çalışmanın getirdiği yenilikler ile çalışmadaki yaklaşımlar kullanılarak gerçekleştirilebilecek yeni çalışma alanlarından bahsedilmiştir.



## 2. ÖZGÜN SENSÖR FÜZYON YÖNTEMİ


Optik, termal ve derinlik sensörlerini bir arada kullanarak ortamın farklı özelliklerini çıkarmak görüntü işlemeye destek olabilmek ve sıcaklık derinlik gibi çıkarımları gerçekleştirmek amacıyla kullanabilmek önemlidir. Bu çalışma çeşitli sensör türlerinden gerçek zamanlı veri toplamanın yanında esnek bir birleştirme yaklaşımı sağlayan yeni bir yöntemle odaklanmaktadır. Tezin bu bölümünde çalışma kapsamında geliştirilen ve başarısı ispatlanan sensör birleştirme yönteminin işlem adımları uygulamalı olarak anlatılmaktadır. Birçok üretici optik, termal ve derinlik verilerini elde edebilmek için sensörler geliştirmektedir. Farklı marka veya modeldeki çeşitli sensörlerin saniyede algıladığı kare hızı (FPS), algılama menzili, veri boyutu, bellekte temsil edilme biçimleri gibi farklı öznitelikleri eşdeğer olmayabilir. Ancak bu tezdeki yöntem herhangi bir marka modeldeki sensörler ile uygulanabilmektedir. Tezin bu bölümünde sensör birleştirme yöntemi örnek sensörler ile açıklanmıştır.

### 2.1 Sensör Füzyonu

Çalışma kapsamında görüş alanındaki varlıkların farklı özelliklerini algılayabilen ve odak noktası, görüş açısı gibi özellikleri bilinmeyen farklı tipteki algılayıcıların verilerini örtüştürerek ilgilenilen alan hakkında daha fazla bilgiye sahip olmak amaçlanmıştır. Elde edilecek bilgiler sayesinde herhangi bir bölgenin 3 boyutlu ortamdaki imgesi ısı değerleri de içerek şekilde oluşturulabilmiştir. Belirli bir bölge hakkında elde edilen bu bilgiler literatürde var olan çalışmalara uygulanarak yöntemlerin başarı oranları artmış ve yeni araştırma alanlarına olanak sağlamıştır.

Tez çalışmasında farklı sensörlerin bir arada kullanımı ve sensörlerden alınan verilerin eşleştirilmesi başlıca sorunlardan biridir. Çalışmada kullanılan sensörlerden elde edilen veriler sayısal görüntülere çevrilmiş ve görüntü eşleştirme problemi haline getirilerek eşleme sorununa çözüm bulunmuştur. Görüntü eşleştirme işlemi aynı algılayıcılardan alınan veriler üzerinde yapılabileceği gibi çeşitli özellik ve öznitelikler yardımıyla farklı türdeki algılayıcılardan elde edilen veriler üzerinde de yapılabilir. Ortamın durumunu farklı özelliklerde algılayabilmek için kullanılan yapı ortamdaki

ısı değerleri algılayabilen termal kamera ve ortamdaki renk değerleriyle birlikte uzaklık bilgisini de algılayabilen RGB-D kameradan oluşmaktadır. Bu kameralar birbirine sabit hale getirilerek üçlü bir algılayıcı haline getirilmiştir. Kullanılan algılayıcılar ve birbirlerine sabitlenmiş biçimleri Şekil 2.1’de görülebilir.



**Şekil 2.1: Çalışma Kapsamında Kullanılan Algılayıcılar.**  
**(a) Microsoft Kinect, (b) Seek Compact Pro, (c) Sabitlenmiş Algılayıcılar**

Uzaklık ve optik verilerin algılanması için Microsoft Kinect, termal verilerin algılanabilmesi için ise Seek Compact Pro algılayıcılarından faydalanılmıştır. Şekil 2.1 (a)’ da görülen Kinect renk algılayıcısı ile 640x480 piksel çözünürlüğünde 8 bit RGB renk derinliğinde saniyede 30 kare optik veri üretebilir. Ayrıca üzerinde bulunan

kızılötesi aydınlatıcı ve algılayıcı ile elde ettiği uzaklık bilgilerini optik algılayıcı üzerinden alınan verilerle eşleyerek her bir piksel için uzaklık verisini üretebilir. Microsoft Kinect sensörü ile elde edilen uzaklık verisi 50 cm ile 5 metre mesafelerde sağlıklı olarak ortam değişkenlerine de bağlı olmak üzere 30 Hz hızında elde edilebilmektedir (Dolinay, Pivnickova, & Vasek, 2014). Şekil 2.1 (b)'de görülen Seek Compact Pro algılayıcısı ise -40 ~ 330 santigrat derece aralığındaki ısı değerleri algılayabilir ve bu verileri 320x240 piksel çözünürlüğünde 15 Hz hızında görüntülenebilecek şekilde üretebilir (Seek Thermal, 2022). Algılayıcı özelliklerinden de görüldüğü üzere derinlik, renk ve ısı olmak üzere üç farklı bilgi üretebilen bu iki sensör, termal kamera görüntüleri ile RGB-D verilerinin eşleştirilmesine yönelik bir yöntem geliştirilmesi amacıyla ihtiyaç duyulan gerekli altyapıyı sağlayabilecek nitelikte donanımlardır.

## **2.2 Literatürde Yer alan Sensör Füzyonu Yöntemleri**

Kameralarından alınan sayısal görüntülerin klasik görüntü işleme yöntemleriyle anlamlandırılmasıyla geniş yelpazede uygulamalar geliştirilebilmektedir. LIDAR sistemler de ortamın derinliğine bağlı bir örneklemesini oluşturarak insan gözünün de algılayabileceği sayısal görüntüler oluşturabilmektedir. LIDAR sisteminden elde edilen sayısal görüntüler üzerinde istenilen görüntü işleme teknikleri uygulanabilmekte ya da elde edilen bu veriler yapay sinir ağları ile kullanılabilir. Ayrıca LIDAR verileri ve renkli kamera verilerinin birlikte kullanımı ile evrimsel sinir ağı yardımıyla nesne tespitinde doğruluğun artırılacağı, (Chen, ve diğerleri, 2018) yapmış olduğu çalışmada Şekil 2.2 ile gösterilmiştir.


Kızılötesi kameralar, sensörleri optik kamera sensörlerinden farklı olmakla birlikte üzerinde görüntü işleme yöntemlerinin uygulanabileceği sayısal görüntüler üretmektedirler. Kızıl ötesi kameralardan alınan veriler, insan gözünün algılayamadığı dalga boylarındaki ışığı algılayıp insan gözünün görebileceği şekilde örnekleyerek sayısal ortama sunmaktadır. İnsan gözünün algılayabileceği hale getirilen bu görüntüler, sıradan renkli görüntüler gibi görüntü işleme yöntemleriyle kullanılabilir. (Ghazali & Jadin, 2014) çalışmalarında kızılötesi bir görüntüden klasik görüntü işleme yöntemleri ile patlayıcı tespiti yapmışlardır. Yapılan çalışmada tespit edilen bir nesnenin optik, termal ve işlenmiş görüntüsü Şekil 2.3'de görülebilir.

Ancak çalışmada son yıllarda başarımı giderek artan yapay sinir ağı yöntemlerinin kullanılmaması ve tek bir sensöre bağlı kalınmış olması çalışmanın eksik yanlarıdır.



**Şekil 2.2: Kamera ve LIDAR Verisinin Birlikte Kullanımıyla Araç Tespiti.**

Chen ve diğerleri (2018)'den uyarlanmıştır.



**Şekil 2.3: Optik , Termal ve Eşiklenmiş Görüntü.**  
**(a)Optik görüntü, (b) Termal görüntü, (c) Eşiklenmiş görüntü.**

Ghazli ve Jadin (2014)'ten uyarlanmıştır.

Etkili ve sağlam görevleri yerine getirmek için robotik çalışmalarda (Tzafestas, 2005) (Aman, Mahmud, Jiang, Abdelgawad, & Yelamarthi, 2016) (Xi, 2019) ve insansız araçlarda (Kumar, Kavitha, Subramanian, & Ramesh, 2011) (Dai, ve diğerleri, 2020) (Cook & Cohen, 2017) uygun sensör füzyon yöntemlerinin kullanılması kilit

konulardan biridir. Sensör füzyonunu kullanarak, otonom bir araç çevresini daha iyi algılayabilir, bu sayede kendisini bilinmeyen bir ortamda daha ayrıntılı bir şekilde konumlandırabilir (Xi, 2019), (Nandi & Mitra, 2001), (Dobrev, Flores, & Vossiek, 2016) ve çevresel değişiklikleri daha hızlı tespit edebilir (Matía & Jiménez, 1998), (Aman, Mahmud, Jiang, Abdelgawad, & Yelamarthi, 2016). Ayrıca insanlar, hayvanlar vb. hedefler için daha ayrıntılı veriler üretebilir (Liu, Hu, & Wang, 2020) (Dieterle, Particke, Patino-Studencki, & Thielecke, 2017) (Zhang, Wei, & Zhou, 2019) (Sankey, Donager, McVay, & Sankey, 2017). Sensör verilerini kaynaştırmaya yönelik en son çalışmalar dinamik bir füzyon yaklaşımından uzaktır ve belirli sensörler için tasarlanmıştır (Saha & Mukhopadhyay, 2020), (Kong, ve diğerleri, 2020). Ayrıca füzyon çalışmalarının derin öğrenme yöntemleriyle uyumlu olması için grafik işlemcilerle ihtiyaç duyulabilir (Zhang, Sidibé, Morel, & Mériaudeau, 2021). Sensörlerin hızlı ve büyük veri toplama yetenekleri ve elde edilen büyük verilerin farklı veri türleri ile bellekte temsil edilmesi, özellikle sınırlı bilgi işlem gücüne sahip işlemcilerle yapılandırılan mobil robotik sistemlerde gerçek zamanlı füzyon sürecinin temel sorunlarıdır. Bunun için sensörler arasındaki ilişki dinamik özellikler içermeli ve sensör markaları, türleri ve üreticilerinden bağımsız olarak adaptif bir yaklaşım sağlamalıdır.

Yukarıdaki beklentiler göz önüne alındığında, görüntü işleme teknikleri kullanılarak veri birleştirmeye yönelik sağlam ve en hızlı yaklaşım elde edilebilir (Han & Huh, 2019). Optik, termal ve derinlik sensörlerinin verileri farklı formlarda olmasına rağmen görüntü olarak modellenabilir ve işlenebilir. Aynı ortamda iki özdeş sensörden elde edilen optik görüntülerin birleştirilmesi işlemi literatürde stereo görme olarak tanımlanmaktadır (Treible, ve diğerleri, 2017) ve bu da bir veri füzyonu şeklidir. Son yıllarda stereo görme ile ilgili geniş çaplı araştırmalar yapılmıştır. Örneğin, Tippetts ve meslektaşları, sınırlı kaynaklara sahip sistemler için stereo görüş algoritmalarının kapsamlı bir incelemesini gösterdiler. Son on yılda geliştirilen tüm stereo görüş algoritmaları için doğruluk ve çalışma zamanı performans verilerini topladılar ve sundular (Tippetts, Lee, Lillywhite, & Archibald, 2013). Stereo görme, popüler ve başarıyla uygulanan bir sensör füzyon tekniği olmasına rağmen, aynı sensörlerin birlikte kullanılmasıyla sınırlıdır (Ambrosch, Zinner, & Leopold, 2010) (Ben-Ari & Sochen, 2010) (Bleyer & Gelautz, 2005) (Gehrig, Schneider, Stalder, & Franke, 2017).

Değişen ihtiyaçları karşılamak ve daha iyi karar verme sistemleri sağlamak için farklı sensörler bir arada kullanılarak farklı özellikler kaydedilir. Bununla birlikte, az sayıda araştırmacı, stereo görme perspektifinden heterojen sensör füzyonu çalışmıştır. Örneğin, Yang ve ark. gerçek zamanlı sonuçlar üretemese de derinlik, termal ve optik verilerin bir birleşimini sunabilen bir yapıyı başarıyla sağlamıştır (Yang, Su, & Lin, 2018). Chen ve diğerleri tarafından yapılan başka bir çalışmada, belirli bir bölgeye belirli bir amaç için bakan çeşitli sensörlerden toplanan veriler birleştirilmiştir (Chen, Tian, Wu, Tang, & Li, 2019). Ancak yöntemleri, özellik çıkarımına dayanmaktadır ve farklı sensörler, ortamlar ve amaçlar için geçerli değildir. Vidas et al. gerçek zamanlı sensör füzyon sonuçları üretmek için başka bir yöntem önerdi. Ancak yinelenen işlemlerle kaynak tüketimi artar ve ortamda belirlenecek özellik noktalarının sayısının önceden tanımlanması gerekir (Vidas, Moghadam, & Sridharan, 2015). Cao ve arkadaşları yaptıkları çalışmada iki farklı sensörü birbirine sabitleyip birleştirmiştir, ancak çalışmada kullanılan ICP yöntemi birkaç öznitelik noktasına ihtiyaç duymaktadır ve karmaşık hesaplamalar içermektedir (Cao, ve diğerleri, 2018). Kim ve arkadaşlarının yaptıkları çalışmada ise özellikleri bilinen iki farklı algılayıcı değişik açılardan özellik çıkarımı yapabileceği bir alanda kullanılmış ve sensör verileri birleştirilerek sonuçlar çıkarılmıştır. Bu çalışmada farklı sensör kullanımı öne çıksa da optik sensör verisi üzerinden özellik çıkarımına ihtiyaç duyulması ve sensörlerin odak uzaklıkları ve görüş açıları ile işlem yapıldığı görülmektedir (Kim, Lee, Ahn, Shin, & Sim, 2020). Schramm ve arkadaşlarının yaptığı çalışmada ise termal ve RGB-D algılayıcılar birleştirilmiştir. Özellik çıkarımına dayanmaması ve farklı tipteki algılayıcıların birleştirilmesi çalışmanın dikkat çekici özelliğidir. Sensör füzyonu için kamera öznitelikleri yardımıyla elde edilen kalibrasyon bilgileri kullanılmıştır (Schramm, Osterhold, Schmoll, & Kroll, 2021).

Farklı sensör türlerinin bir arada kullanıldığı birçok robotik araştırma çalışması bulunmaktadır. Correa ve arkadaşlarının yaptığı çalışmada, evsel ortamlarda termal ve optik sensörleri bir arada kullanan robotlar tarafından insanlar ve yüzleri tespit edilmiştir (Correa, Hermosilla, Verschae, & del-Solar, 2011). Bu çalışmada, sensörler benzer bir görüş alanına ve alan derinliğine sahipti. Böylece termal ve optik görüntülerin görüş alanlarının birbirine yakın olması sağlanmıştır. Bu çalışmanın en büyük dezavantajı, sensörlerin herhangi bir veri birleştirme işlemi olmadan kullanılmasıdır. Optik ve termal sensörlerin birlikte kullanıldığı başka bir çalışmada

Carrio ve ark. küçük insansız hava araçları (İHA) için bir engel tespit sistemi geliştirdi (Carrio, Lin, Saripalli, & Campoy, 2017). Çalışmada sensörlerden gelen verilerin senkronize versiyonu kullanıldı ve doğrudan güneş ışığına maruz kalma gibi aşırı aydınlatma koşullarında ve gece saatlerinde çalışmasına izin verdi. Ancak çalışmada füzyon yöntemi anlatılmamıştır.

Farklı sensör verilerinin görüntü işleme yöntemleri ile birleştirilmesi literatürdeki temel problemlerden biridir ve bu konuda çok sayıda çalışma yapılmıştır. Bu çalışmaların çoğunda, aynı özelliklere sahip optik kameraların farklı açılardan birleştirilmiş görüntüleri alınırken (Ambrosch, Zinner, & Leopold, 2010) (Ben-Ari & Sochen, 2010) (Bleyer & Gelautz, 2005) (Gehrig, Schneider, Stalder, & Franke, 2017), bazı çalışmalarda farklı özelliklere sahip kameralar da kullanılmıştır (Bastanlar, Temizel, & Yardimci, 2009). Termal görüntüler ile renkli görüntülerin birleştirilmesinde genellikle karmaşık hesaplamaları içeren yöntemlerin kullanıldığı görülmektedir. Ben-Artzi ve arkadaşlarının çalışmasında, 2 noktalı bir yaklaşım önerildi ve yöntem, farklı görüntülerin epipolar geometrilerini eşitlemek için yaygın olarak kullanılan 8 noktalı ve 7 noktalı yaklaşımlardan daha iyi performans gösterdi (Ben-Artzi, Halperin, Werman, & Peleg, 2016). Bu çalışma, epipolar düzlemde 2 nokta belirlenerek görüntülerin birleştirilebileceğini göstermektedir. Ancak yöntem aynı sensör ile farklı açılarda gerçekleştirilir. John ve arkadaşlarının yaptığı çalışmada, termal ve optik sensörler kaynaştırıldı. Özellik noktaları, ısı ve ışık yayan bir kaynak kullanılarak oluşturuldu ve kayıtlı sensör verilerini elde etmek için bu noktalar üst üste getirildi. Ayrıca, kişi tespit doğruluğunun bir karşılaştırması yapılmıştır (John, Tsuchizawa, Liu, & Mita, 2016).

Tablo 2.1, önerilen yöntem ile RGB-D ve termal sensörlerin kullanıldığı füzyon çalışmaları arasındaki farklılıkları ve benzerlikleri göstermektedir. Tabloda çalışmalarda tercih edilen sensörler, çalışma ortamı, gerçek zamanlı kullanılabilirlik ve sunulan füzyon yöntemleri için teknik verilmiştir. Bu yöntemler, sensörleri kaynaştırmak için özellik çıkarma tekniklerinden yararlanır. Bu işlem, her çerçeve için özellik noktaları toplamak için gereklidir. Her durumda özellik noktalarını tespit etmek mümkün olmadığı için gerçek dünya ortamlarında çalışırken büyük zorluklara neden olabilir. Öte yandan, çalışmamız sensör füzyonu için önceden hesaplanmış değerlerle kalibrasyon sağlar ve her kare için özellik çıkarma noktalarına ihtiyaç duymaz.

**Tablo 2.1: Füzyon Yönteminin Literatürdeki Yöntemler ile Kıyası.**

| <b>Çalışma</b>                               | <b>Kullanılan Algılayıcılar</b> | <b>Ortam</b> | <b>Çalışma zamanında özellik çıkarımı</b> | <b>Veri seti Oluşturma</b> | <b>Gerçek Zamanlı Çalışma</b> |
|----------------------------------------------|---------------------------------|--------------|-------------------------------------------|----------------------------|-------------------------------|
| (Yang, Su, & Lin, 2018)                      | Termal, RGB                     | Dış, İç      | Evet                                      | Hayır                      | Hayır                         |
| (Chen, Tian, Wu, Tang, & Li, 2019)           | Termal, RGB-D                   | İç           | Evet                                      | Hayır                      | Bilgi Yok                     |
| (Vidas, Moghadam, & Sridharan, 2015)         | Termal, RGB-D                   | İç           | Evet                                      | Hayır                      | Evet                          |
| (Cao, ve diğerleri, 2018)                    | Termal, RGB-D                   | İç           | Evet                                      | Hayır                      | Evet                          |
| (John, Tsuchizawa, Liu, & Mita, 2016)        | Termal, RGB                     | Dış, İç      | Evet                                      | Evet                       | Evet                          |
| (Schramm, Osterhold, Schmoll, & Kroll, 2021) | Termal, RGB-D                   | İç           | Hayır                                     | Hayır                      | Evet                          |
| Tez                                          | Termal, RGB-D                   | Dış, İç      | Hayır                                     | Evet                       | Evet                          |

Görüntülerde insan tespiti, bilgisayarla görü çalışmaları başladığından beri defalarca gerçekleştirilmiştir. Gerçek zamanlı olarak daha iyi doğruluğu hedefleyen en son örnekler genellikle sinir ağlarına ve derin öğrenmeye dayanır (Gonçalves, Silva, Nunes, Ferreira, & Araújo, 2021). (Boudjit & Ramzan, 2021)'deki yazarlar, bir YOLO algılama algoritmasından yararlanan sınırlı bilgisayar gücüne sahip küçük boyutlu İHA'lar için insan algılamayı inceledi. (Rahmaniar & Hernawan, 2021)'de yazarlar, derin öğrenmeyi kullanarak gömülü platformlarda gerçek zamanlı algılamayı önerdiler.


İnsan algılama doğruluğunu geliştirmek için çok sayıda çalışma yapılmıştır. Xue et al. gece vakti yaya algılama performansını iyileştirmek için MAF-YOLO adlı bir YOLO varyasyonu önerdi (Xue, Ju, Li, & Zhang, 2021). Doğrudan birleştirme yerine çok modlu bir özellik çıkarma modülü ve mod ağırlıklı füzyon kullandılar. (Ko, Jeong, & Nam, 2014)'te yazarlar, görüntü ölçekleme için algılama doğruluğunu artıran ve algılama süresini azaltan uyarlanabilir bir ilgi alanı (ROI) kullanmıştır. (Haider, Shaukat, & Mir, 2021)'te yazarlar, termal görüntüleri kullanarak insan tespiti için regresyona dayalı bir yaklaşım önerdiler. Düşük güçlü insan termal imzalarını uzak bir bakış açısından tespit etmek için tam bağlantılı bir ağ modeli kullanıldı ve diğer benzer mimarilere göre çok daha düşük bir hesaplama maliyeti elde edildi. Bu çalışmalar farklı yönler dikkate alınarak yapılırken, beklenmedik değişken koşullar tespit kabiliyetine zarar vermiştir. Farklı sensörlerin aynı anda kullanılması, değişen faktörlere karşı daha dirençli olduğu için algılama hatalarını azaltmak için önemli bir avantaj sağladı.

### **2.3 Önerilen Sensör Füzyon Yöntemi**


Resimleri eşleştirme yöntemleri için literatür bölümüne göz atıldığında çok çeşitli çalışmalar göze çarpmaktadır. Ancak bu çalışmaların büyük çoğunda eşleştirilen görüntülerin alındığı kameraların aynı özelliklerde farklı açılardan çekilmiş görüntüler olduğu gözlenmiştir. Termal görüntüler ile renkli görüntülerin eşleştirme çalışmalarında ise genellikle karmaşık hesaplamalar içeren yöntemlerin kullanıldığı görülmektedir. Ben-Artzi ve arkadaşlarının yaptığı çalışmaya bakıldığında farklı resimlerin epipolar geometrilerini eşitlemek için yaygın olarak kullanılan 8 nokta ve 7 noktalı yaklaşımların yerine 2 noktalı bir yaklaşım önerilmiş ve başarımı ispatlanmıştır (Ben-Artzi, Halperin, Werman, & Peleg, 2016). Tez çalışması

kapsamında ise benzer mantıktan yola çıkarak birbirlerine göre konumu sabit olan, termal ve optik verilerde ayırt edilebilecek iki nokta belirlenmesi ve bu noktaların düzlemdeki konum ile birbirlerine göre konum verilerinden yola çıkarak görüntüler arası eşleme yapabilmek için üretilcek değerlerin belirlenmesi düşünülmüştür.

Bu düşünceye dayanarak oluşturulan ve Şekil 2.4'te görülen düzenek beyaz bir Zemin üzerinde iki tane siyah daire ve bu dairelerin tam merkezinde ısı yayacak akkor ampullerden oluşmaktadır. Bu düzenek yardımıyla kalibrasyon değerlerini bulabilmek için optik görüntülerde daire ve merkezinin bulunması, termal görüntülerde ise ısı merkez kaynağının bulunması işlemleri gerçekleştirilecektir. Bu işlemlerin başarıyla sonuçlanması için her iki algılayıcının görüş alanında farklı bir ısı kaynağı ve daire şeklinde nesne olmamasına dikkat edilmiştir. Optik, termal ve derinlik verisi sunan algılayıcıların sensör mimarisinden bağımsız bir füzyon haline sunulmasını sağlamaya yönelik geliştirilen yaklaşımın işlem adımları Şekil 2.5 'deki akış şemasında görünmektedir.




(a)



(b)

**Şekil 2.4: Kalibrasyon Düzeneği.**  
**(a) Optik Görüntü, (b) Termal Görüntü**



**Şekil 2.5: Kalibrasyon Noktalarının Bulunarak Veri Eşleştirilmesi Akış Şeması.**

Çalışmanın bu bölümü linux (Ubuntu 18.04) işletim sistemi yüklü bir bilgisayarda C++ programlama dilinde gerçekleştirilmiştir. Kullanılan algılayıcılara bakıldığında Kinect algılayıcı Xbox oyun konsolu için üretilmiş ve resmi uygulama geliştirme kiti (SDK) Windows işletim sistemlerinde çalışmalar yapmak için yayınlanmıştır. OpenKinect adlı topluluk ise Windows, Linux ve Mac işletim sistemlerinde çeşitli programlama dillerinde Kinect özelliklerini kullanabilecek bir SDK geliştirmiş ve yayınlamıştır. freenect adlı bu SDK ile cihaz üzerindeki algılayıcılardan uzaklık ve optik veriler alınabilmekte, cihaz üzerinde bulunan motor kontrolü ile dikey eksenle hareket sağlanabilmektedir. Kinect optik algılayıcısının algıladığı renk değerleri RGB formatında ve 640x480 çözünürlüğünde bir görsel oluşturacak şekilde 921600 tane ham veriden oluşurken, uzaklık değerleri ise 640x480 pikselin her birine karşılık gelebilecek şekilde 307200 tane veriden oluşmaktadır.

Compact Pro algılayıcısı Seek Thermal firması tarafından iOS ve Android işletim sistemine sahip akıllı telefonlarda kullanılması için geliştirilmiş bir cihazdır ve herhangi bir resmi yazılım geliştirme SDK'sı bulunmamaktadır. Çeşitli kullanıcılar farklı uygulamalar için bazı SDK'lar yayınlamışlardır. Çalışma kapsamında açık kaynak kodlu bir çalışma olan libseek-thermal kütüphanesi kullanılarak geliştirmeler yapılmıştır. Compact Pro algılayıcısı 320x240 çözünürlüğünde görsel oluşturulabilecek 76800 tane ham veriden oluşan ısı değerlerinden oluşan bir veri üretmektedir.

Algılayıcılar için kullanılan SDK'lar dışında görüntü üzerinde yapılan işlemleri kolaylaştırmak için OpenCV ve verilerin 3 boyutlu temsilleri için OpenGL kütüphanelerinden de yararlanılmıştır. Tüm SDK'lar bir arada kullanılarak akış şemasında görülen işlemleri gerçekleştiren bir yazılım geliştirilmiştir. Bu yazılım ile algılayıcılardan ham veriler alınmış ve bu veriler kalibrasyon işlemleri sürecinde kullanılabilme üzere anlamlı veriler haline getirilmiştir.

Termal algılayıcıdan gelen ham veriler 16 bit yer kaplamaktadır. Bu verileri görsel hale getirebilmek için öncelikle veri üzerinde normalize işlemi gerçekleştirilmekte ve 16 bitlik bir resim oluşturulmaktadır. Daha sonra bu 16 bitlik resim 8 bitlik standart gri tonlamalı görsel haline getirilmektedir, son olarak bu gri tonlamalı resim kullanıcı görselliğini iyileştirmek adına sıcaklık temalı olarak renklendirilmektedir. Bu renklendirme sonrası görünür alandaki en soğuk bölgeler siyah, ara değerler siyahtan kırmızıya, kırmızıdan turuncuya, turuncudan da beyaza geçecek ve en sıcak bölgeler

beyaz olarak görüntülenmeye hazır hale gelmektedir. Optik algılayıcıdan gelen veriler ise standart 8 bit tonlamalı olmak üzere kırmızı yeşil ve mavi (RGB) ton bilgilerini içermektedir. Bu bilgiler ile üzerinde işlem yapılabilecek görünür görsel oluşturulmuştur.


Kinect uzaklık algılayıcısından libfreenect kütüphanesi aracılığıyla alınan ve optik algılayıcı ile oluşturulan her bir piksel için uzaklık değeri içeren verilerin her biri 11 bit değer ile temsil edilmektedir. İstenilen her bir pikselin metre biriminden uzaklığı algılayıcıdan alınan ham veri olan  $r$  ile kütüphane dökümanında belirtilen belirtilen  $k_1, k_2, k_3$  sabitlerine göre Denklem (2.1) ile hesaplanabilmektedir. Kalibrasyon işlemleri sırasında görüntüler alınırken kalibrasyon düzeneği görselin ortasına denk geldiği için her bir kalibrasyon verisi için optik görüntünün orta noktasındaki uzaklık hesaplanıp veriler kaydedilirken bu uzaklık değeri kullanılmaktadır.

$$\begin{aligned}
 d &= k_3 \times \tan(r \div k_2 + k_1) \\
 k_1 &= 0.1236 \\
 k_2 &= 2842.5 \\
 k_3 &= 1.1863
 \end{aligned} \tag{2.1}$$

Üzerinde işlem yapılabilecek görüntüler oluşturulduktan sonra termal ve optik verilerde kalibrasyon noktalarını bulmak için farklı işlemler gerçekleştirilmektedir. Termal görüntüdeki kalibrasyon noktaları ısı kaynakları olduğu ve renklendirme yapılırken görseldeki en sıcak bölgeler beyaz tonlamalar içerdiği için bu noktaların belirlenmesi için eşik değerine bağlı bir kenar belirleme işlemi olan Canny Kenar Belirleme yöntemi kullanılmıştır.

Kenar belirleme işlemi sonrası ortaya çıkan noktaların silüetlerinin daha belirgin hale gelmesi için genişletme işlemi uygulanmış, bu işlemin görselin genelinde yaptığı bozulmaları düzeltmek için ise aşındırma yöntemi uygulanarak kalibrasyon noktalarının silüetleri ortaya çıkarılmıştır. Termal görüntüdeki kalibrasyon noktaları belirginleştikten sonra çevre (contour) belirleme yöntemi ile silüeti belirlenen kalibrasyon noktaları bir sınırlayıcı kutu (bounding box) içerisine alınarak bu kutuların merkezleri kalibrasyon noktaları olarak belirlenmiştir. Optik görüntülerde ise Hough

daire bulma yöntemi ile görseldeki kalibrasyon noktalarını içine alan daireler bulunmuş ve bu dairelerin merkezleri kalibrasyon noktaları olarak belirlenmiştir.



**Şekil 2.6: 150 cm Mesafeden Kalibrasyon Adımları.**  
(a) Termal Görüntü, (b) Kenar Belirleme, (c) Genişletme, (ç) Aşındırma,  
(d) Çevre Belirleme, (e) Doğru Parçası, (f) Eğme, (g) Boyutlandırma,  
(ğ) Optik Görüntü, (h) Daire Bulma, (ı) Birleşik Görüntü

Hem termal hem optik verilerde konumları belirlenen noktaları birleştiren doğru parçaları bulunmuş ve çizilmiştir. Bu doğru parçalarının uzunlukları iki nokta

arasındaki öklit uzaklığı formülüyle bulunurken eğimleri iki noktası bilinen doğrunun eğimi formülüyle bulunmuş ve eşleştirmede kullanılmak üzere saklanmıştır. Bulunan eğimlerin birbirine göre farkı bulunarak termal görüntü bu fark kadar eğilmiştir. Sonrasında ise termal kalibrasyon noktaları arasındaki uzaklığın optik kalibrasyon noktaları arasındaki uzaklığa oranında termal görüntü yeniden boyutlandırılır. Optik ve termal görüntüyü düzlemde üst üste getirebilmek için her iki görüntüde belirlenen kalibrasyon noktaları arasındaki doğru parçalarının orta noktaları bulunmuş ve bu orta noktaların üst üste örtüşmesi için gerekli hesaplamalar yapılmış ve termal görüntünün optik görüntü üzerindeki konumu belirlenmiştir.

Belirlenen tüm bu veriler iterasyon sayısınca tekrar edildikten sonra kullanılmak için hesaplanan uzaklık değeri ile kaydedilmiştir. Örtüşme hatasının azaltılması için kaydedilen bu kalibrasyon verilerden büyütme oranı, eğim farkı ve yatay konumlandırma değerlerinin ortalaması alınmıştır. Bulunan ortalama değerler dışında kalan dikey konumlandırma değeri dikey ekseninde kameraların lens konumları farklı noktada olduğundan kalibrasyon mesafelerine bağlı değişkenlik göstermektedir. Uzaklık değerinin dikey konumlandırma üzerindeki etkisi, çeşitli uzaklıklardan gelen veriler incelenerek matematiksel olarak modellenmekte ve Denklem (2.2) ile temsil edilmektedir. Bu denklem kullanılarak dikey konumlandırma değerinin mesafeye göre büyük bir değişime uğraması engellenir. Denklem (2.2)'de,  $d_{max}$  en uzak kalibrasyon mesafesini temsil ederken  $v_{max}$ , dikey düzeltmelerin en büyük değerini gösterir.

$$f(x) = \begin{cases} v_{max} - (d_{max} - d)/15, & 100 < d < 250 \\ v_{max} - (d_{max} - d)/15 - (100 - d) \times 2/5, & 50 < d < 100 \end{cases} \quad (2.2)$$

Kalibrasyon işlemleri sensörlerin çalışma aralığına bağlı olarak her 50 cm mesafe için 50-250 cm aralığında beş kez tekrarlanır. Elde edilen büyütme ve ortalamalar, radyan cinsinden eğim farkı ve bunların ortalamaları, piksel cinsinden yatay düzeltmeler ve ortalamalar, piksel cinsinden dikey düzeltme değerleri ve saniye cinsinden değerlerin hesaplama süresi Tablo 2'de verilmiştir. Kalibrasyon için hesaplanan değerler farklı mesafelerde gerçekleştirilen işlemler de gösterilmiştir. Sensörlerin düzlemdeki yalpalama ve eğim farklılıkları yatay ve dikey farklılıklara neden olurken, kamera

özellikleri ise büyütme ve eğim farklılıklarını oluşturmaktadır. Tablo 2'deki değerlere bakıldığında, dikey düzeltme dışında değerlerin değişimi küçük olduğu için yöntemde ortalama değerler kullanılabilir. Kalibrasyon işlemi için hesaplama süreleri de Tablo 2'de sunulmuştur. Beş adımdan oluşan bir kalibrasyon işlemi yaklaşık 1 s'dir. Kalibrasyon işlemi tamamlandıktan sonra, sensörlerden gelen verilerin birleştirilmesi için Tablo 2.2 ve Denklem (2.2) 'deki ortalama değerler kullanılır. Bu füzyon işlemi yaklaşık 0,02 s'de yürütülür. Böylece sensörlerden elde edilen veriler bu işlemle birleşerek 20 milisaniyelik bir gecikmeye neden olarak yöntemin gerçek zamanlı olarak çalışmasına olanak tanır.

**Tablo 2.2: Uzaklığa Göre Kalibrasyon Değerleri.**


| Tanım                | Değer <sup>a</sup> |        |        |        |         |             |
|----------------------|--------------------|--------|--------|--------|---------|-------------|
| Kalibrasyon Mesafesi | 250                | 200    | 150    | 100    | 50      | Ortalama    |
| Büyütme Oranı        | 0.9564             | 0.9863 | 0.9721 | 0.9688 | 0.97680 | 0.9721132   |
| Eğim Farkı           | -0.0,32            | -0.059 | -0,046 | -0,074 | -0,041  | -0,050893   |
| Yatay Düzeltme       | 158,91             | 154,38 | 156,38 | 156,42 | 158,95  | 157,0132566 |
| Dikey düzeltme       | 95,591             | 84,809 | 85,058 | 83,326 | 62,719  | -           |
| Hesaplama Zamanı     | 0,1910             | 0,1959 | 0,1891 | 0,1850 | 0,1892  | 0,1900656   |

<sup>a</sup>Kalibrasyon mesafesi birimi santimetre, eğim farkı birimi radyan, düzeltme birimleri piksel ve zaman birimi saniye cinsindendir.


### 3. TERMAL, OPTİK VE UZAKLIK VERİLERİN EŞLEŞTİRİLMESİ İLE NESNE TESPİT UYGULAMASI

Tez çalışmasının bu bölümünde bir önceki bölümde açıklanan yöntem ile birleştirilen sensörlerden elde edilen veriler ile gerçekleştirilen çalışmalardan olan anomali tespiti açıklanacaktır. Elde edilen farklı özellikteki veriler sayesinde ortam hakkında daha fazla bilgi çıkarılabilmektedir. Bu bilgiler ile ortamdaki nesne tespit başarısının artması yanında tespit edilen nesneye yönelik çeşitli çıkarımlar da yapılabilmektedir. Aşağıdaki alt başlıklarda uygulamalar görülebilir.

#### 3.1 Sensör Füzyonu ile Ortamdaki Nesnelerin Renk ve Sıcaklık Tespiti




(a)



(b)



(c)




(ç)

**Şekil 3.1: RGB-D ve Termal Verilerin Birleştirildiği Uygulama Görüntüsü.**

Elde edilen ve Tablo 2.2’de sunulan kalibrasyon deęerleri ortalamaları ve Denklem 2 sonucu elde edilen dikey konumlandırma deęerine gre her iki algılayıcıdan gelen  tip verileri birleřtirecek bir yazılım geliřtirilmiřtir. řekil 3.1’ te rnek ıktıları grnen bu yazılım sayesinde bir ortamda bulunan nesnelerin sıcaklık, uzaklık ve renk deęerleri algılanabilmiřtir. Grsel olarak algılanması aısından 3 boyutlu olarak ekranda gsterilen bu veriler istenirse eřitli ıkarım, karar ve destek algoritmalarında kullanılabilir.

nceki blmde gerekleřtirilen alıřma ile gerek zamanlı eřleřtirilen termal, optik ve uzaklık verileri bir arada kullanılarak herhangi bir ortamdaki nesneler hakkında birden fazla bilgi ıkarımı yapılmıřtır. Nesne tespiti iin derin ęrenme yntemlerinden olan evriřimsel sinir aęlarından yararlanması, tespit edilen bu nesneleri sıcaklık ve uzaklık bilgileri eřleřtirilmiř verilerden elde edilmesi dřnlmřtr. Nesne tespit ve sınıflandırması iin nerilmiř eřitli aęlar bulunmaktadır. Gerek zamanlı nesne tespiti iin kullanılan YOLO adlı aę modelinin hızı dięer bazı evriřimsel sinir aęları ile kıyaslanmış ve YOLO aęının kltlmř srm olan Fast YOLO’nun saniyede 155 kare iřleyebilme yeteneęi ile n plana ıktıęı grlmřtr (Redmon, Divvala, Girshick, & Farhadi, 2016). ok eřitli alıřmalarda kullanılan bu aę yapısı yardımıyla Zhang ve arkadaşları tarafından gerekleřtirilen bir alıřmada YOLO aęı trafik ıřıklarını tespit edebilecek řekilde eęitilmiř ve bulunan trafik ıřıkları zerinde doygunluk aıklık deęer (HSV) renk filtreleme iřlemi ile trafik ıřıęının kırmızı ya da yeřil olup olmama durumu bulunmuřtur (Zhang, Qiu, Huang, Hu, & Luo, 2018).

Gerekleřtirilen ve yapısı řekil 3.2’te grlen alıřmada ise nceden eęitilmiř bir aę yapısı kullanılarak optik grntlerde nesne tespiti yapılmıřtır. Tespit edilen bu nesnelerin konumlarına gre eřleřtirilmiř verilerden uzaklık, renk ve sıcaklık deęerleri bulunarak ekranda gsterilmiřtir.



**Şekil 3.2: Anomali Tespiti Akış Şeması.**

Belirlenen nesnenin rengini bulabilmek için optik verilerden elde edilen konum bilgisine istinaden renk değerleri elde edilmiş ve bu renk değerlerine göre anlaşılabilir renk değeri belirlenmeye çalışılmıştır. Uzaklık ve sıcaklık değerlerini hesaplamak için de konum bilgisine istinaden eşleşmiş verilerden alınan ham bilgiler üzerinde hesaplamalar yapılarak değerler bulunmuştur. Bu değerler kontrol amaçlı olarak iki farklı yöntemle hesaplanmıştır, ilk yöntemde nesne konumuna göre nesneyi içeren en küçük sınırlayıcı kutu (minimum bounding box) içeriğindeki tüm değerlerin ortalaması bulunurken ikinci yöntemde ilgili karenin merkezi nesnenin merkezi kabul edilerek sadece merkez noktanın bilgileri hesaplanmıştır. Bu hesaplamalardan uzaklık hesabı için kalibrasyon işleminde de kullanılan Denklem (2.1) kullanılmıştır. Sıcaklık değerlerinin hesaplanması için ise SDK dokümanında belirtilen Denklem (3.1) kullanılmıştır. Bu denklemde  $t_{oC}$  santigrat derece cinsinden hesaplanan sıcaklık değerini temsil ederken  $t_r$  ham sıcaklık verisini temsil etmektedir.

$$\begin{aligned} t_{oC} &= h_1 \times t_r + 37 - 273 \\ h_t &= 0.0171156038 \end{aligned} \quad (3.1)$$

$$Renk = \begin{cases} Kırmızı, & \mathcal{R}_p > \mathcal{G}_p \text{ ve } \mathcal{R}_p > \mathcal{B}_p \\ Yeşil, & \mathcal{G}_p > \mathcal{R}_p \text{ ve } \mathcal{G}_p > \mathcal{B}_p \\ Mavi, & \mathcal{B}_p > \mathcal{R}_p \text{ ve } \mathcal{B}_p > \mathcal{G}_p \end{cases} \quad (3.2)$$


Renk deęerleri hesaplanırken optik verilerden elde edilen RGB deęerleri Denklem (3.2) yardımı ile kıyaslanarak aęırlıklı olan renk tonuna gre renk belirleme iřlemi yapılmıřtır. Yapılan bu renk tayini ok geliřmiř olmamakla birlikte karar verme ve renk tayini yapılabildięini gstermesi aısından nemlidir.




(a)

```
*****
0. bardak:0.97ort: Mavi 182.83cm -140.12 C merkez: Mavi 175.00 cm -99.99 C
1. bardak:0.97ort: Mavi 182.19cm -236.00 C merkez: kırmızı 184.00 cm -99.99 C
2. bardak:0.95ort: Mavi 165.00cm 21.43 C merkez: Mavi 166.00 cm 20.39 C
3. bardak:0.94ort: Mavi 180.72cm 50.27 C merkez: kırmızı 176.00 cm 61.50 C
4. sise:0.91ort: Mavi 60.88cm 54.35 C merkez: Mavi 0.00 cm 64.31 C
5. sise:0.86ort: Mavi 92.54cm 18.14 C merkez: kırmızı 0.00 cm 16.81 C
```

(b)



(c)



()

**řekil 3.3: Anomali Tespit Uygulaması.**

**(a) Ortam Grnts, (b) Elde Edilen Sonular, (c) 3 Boyutlu Optik Grnt, () Termal Grnt ile Zenginleřtirilmiř 3 Boyutlu Optik Grnt**


Kalibrasyon değerlerine göre her iki algılayıcıdan gelen üç tip verileri birleştiren ve bu veriler üzerinde derin öğrenme ile nesne tanıma yapan bir yazılım geliştirilmiştir. Şekil 3.3' te deney ortamı ve örnek çıktıları görünen bu yazılım sayesinde bir ortamda bulunan farklı tipteki nesneler tanımlanabilmekte ve her bir nesnenin sıcaklık, uzaklık ve renk değerleri algılanarak ekranda gösterilebilmektedir. Deney ortamında iki farklı renkte aynı tipte dört bardak ve farklı renk ve tiplerde iki adet şişe bulunmaktadır. Bardaklar her bir renk bardağın biri sıcak biri soğuk olmak üzere sıvı ile doldurulmuş ve karışık olarak yerleştirilmiştir. Şişelerden mavi olanda sıcak sıvı varken turuncu olanda soğuk sıvı bulunmaktadır. Görüş alanındaki her bir nesnenin algılayıcıya olan mesafesi de birbirinden farklı olmasına dikkat edilmiştir.

Yukarıdaki renk, sıcaklık ve uzaklık üzerindeki tespit çalışmalarına bakıldığında tespit edilen nesneyi içeren çerçeve (bounding box) içerisindeki ortalama değerler ve merkez noktasına göre nitelik çıkarılmaya çalışıldığı görülecektir. Yaklaşık sonuçlar üreten bu yöntem basit olmakla birlikte bazı zayıflıkları düşünülebilir. İlk yaklaşımda hedef nesne etrafındaki sınırlayıcı kutu merkezindeki verilerin tüm nesne verilerini yansıtmayacağı durumlar oluşabilir. Diğer yaklaşımda ise sınırlayıcı kutu içerisindeki tüm verilerin nesneye ait olmadığı düşünülürse bu verilerin ortalama değerleri yanıltıcı olabilir. Tespit edilen nesnenin konum ve şekline göre sınırlayıcı kutu içerisinde kaplayacağı alan farklı olacaktır. Bu sorunun üstesinden gelebilmek için yeni bir yaklaşım önerilmesi gerekmektedir. Önerilecek yaklaşım görüntü üzerinde sınırlayıcı kutu ile nesne tespiti yapmak yerine nesneler arasında ayırım yaparak sınır bölgelerini çıkarabilmesi gerekmektedir.


Bölütleme (segmentation) işlemi görüntüler üzerinde sınırların belirlenmesi için literatürde var olan bir görüntü işleme yöntemidir. Bölütleme işlemi başlı başına kullanılabileceği gibi nesne tespiti ile birlikte de kullanılabilir. Nesne tespiti olmadan yapılan işleme anlamsal (semantic) bölütleme, nesne tespiti ile birlikte yapılan işleme örnek (instance) bölütlemesi adı verilir. Anlamsal bölütleme işleminde görüntü üzerindeki nesneler belirli bir ilişki içerisindeki bölgeler belirlenmektedir. Örnek bölütlemesinde ise daha detaylı bir analiz yapılarak aynı tipte olsa dahi her bir nesne için bölgeler belirlenmektedir.



(a)



(b)



(c)


**Şekil 3.4: Sayısal Görüntü ve Bölütleme.**  
**(a) Sayısal Görüntü, (b) Anlamsal Bölütleme, (c) Örnek Bölütlemesi**

Bai ve Urtasun (2017)'den uyarlanmıştır.

Nesne tespiti işleminde görüntü üzerindeki nesneler ayrı ayrı sınırlayıcı kutu içerisine alınmaktadır. Bu özelliği göz önüne alınınca örnek bölütlemesi nesne tespiti ile anlamsal bölütlemenin birleşimi olarak düşünülebilir. Şekil 3.4 incelendiğinde bu üç işlemin farkları incelenebilir. Şekil incelendiğinde örnek bölütleme yönteminin bizim çalışmamız için gerekli olan yaklaşım olduğu görülebilir. Anlamsal bölütleme de birbirine benzer nesneler geniş bir alanda aynı bölgede temsil edilmektedir. Örnek bölütlemesinde ise aynı tipteki nesneler farklı bölgelerde temsil edilerek ayırt

edilebilmiştir. Tez çalışmasında her bir algılayıcıdan elde edilen veriler üzerinde bu bölütleme işlemini gerçekleştirmemiz gerektiği ortadadır.

Örnek bölütlemesi konusunda literatüre bakıldığında çeşitli yaklaşımlar olduğu görülebilmektedir. Tez çalışmamızda kullandığımız evrişimsel sinir ağları üzerinde de bu işlemin gerçekleştirildiği çalışmalar mevcuttur. Bu çalışmalardan Facebook yapay zekâ ekibi tarafından önerilen ve yapısı Şekil 3.5’te görülen Mask R-CNN yapılan çalışmalarda ön plana çıkmaktadır. Mask R-CNN yaklaşımının temelinde evrişimsel ağlar ile nesne tespiti bulunmaktadır. Yaklaşımda görüntü geneline bölütleme yapılmamakta öncelikle tahmini nesnelerin olduğu bölgeler (ROI) belirlenir. Belirlenen alanlarda aynı anda tespit ve sınıflandırma ile bölütleme gerçekleştirilerek nesnelerin sınıfları ve konumları ile bulunduğu alanlar için maskeler belirlenir (He, Gkioxari, Dollar, & Girshick, 2017).



**Şekil 3.5: Mask R-CNN Yapısı.**


Bayram (2019)’dan uyarlanmıştır.

Çalışmanın bu bölümünde kullanılmak üzere Mask R-CNN ağ yapısı incelenmiş ve çalıştırılabilir hale getirilmiştir. Geliştirilen derin öğrenme yöntemlerinin sınanması ve literatürdeki diğer yöntemlerle kıyaslanması için sık kullanılan veri setlerinden biri de MS-COCO (Lin, ve diğerleri, 2014) veri setidir. Literatürde var olan birçok ağ yapısının bu veri seti ile eğitilmiş ve sınanmış ağırlıkları bulunmaktadır. Çalışmada kullanılan Mask R-CNN ağının hazır ağırlıkları ile optik görüntülerde 80 nesne tipinde tespit gerçekleştirebilir. Derinlik ve sıcaklık verilerinden oluşturulan görüntüler doğaları gereği optik verilerden farklı olarak temsil edilmektedir. Bazı görselleştirilmeler ile bu görüntüler renklendirilse de optik veriler üzerinde eğitilen

ağlar ile özellikle derinlik görüntülerinde tespit yapılması zorlaşmaktadır. Bu nedenle çalışmada kullanılacak derinlik ve sıcaklık görüntülerinde nesne tespit edilebilmesi için ağ yapısının yeniden eğitilmesi gerekmiştir. Belirtilen hususlar konusunda öncelikle renkli görüntülerde tespit edilen nesnenin rengini bulmaya yönelik bir çalışma gerçekleştirilmiştir. Bunun yanı sıra sıcaklık ve derinlik resimlerinde insan tanımayaya yönelik ayrı ayrı eğitimler gerçekleştirilmiştir. Sonrasında ise renk tespiti temelindeki yaklaşımlar sıcaklık ve derinlik görüntülerine uygulanarak sıcaklık ve uzaklık durumları belirlenmiştir. En son aşamada ise 3 algılayıcıdan alınan veriler üzerinde tespit çalışması yapılarak başarımlar artırılmıştır.


Literatürde tespit edilen nesnelerin renklerinin belirlenmesine yönelik çeşitli çalışmalar mevcuttur. Evrimsel sinir ağları temelli yöntemlerde eğitim aşamasında ilgili nesnenin farklı renklerde etiketlenmesi ve ağın eğitilmesi sıklıkla görülen bir yöntemdir. Ancak bu yöntemdeki temel zorluk aynı tipteki nesnelerin farklı özelliklerdeki biçimlerinin bulunması ve tek tek etiketlenmesidir. Bir nesnenin farklı renklerdeki görüntülerinin elde edilip etiketlenmesi yapılsa bile seçeneklerin kısıtlı olacağı ve benzer nesnelerin farklı etiketlere sahip olacağı için eğitimin zorlaşacağı düşünülebilir. Nesne tespiti ve renk tespiti işleminin birbirinden bağımsız işlemesi eğitim sürecini zorlamayacaktır. Bu sayede renk tespiti işleminde yapılacak işlemlerde farklı renk grupları ya da renkler tanımlanarak probleme özel çözümler geliştirme imkânı oluşacaktır.

Bu aşamaya gelindiğinde bölütleme işlemiyle belirlenen nesne bölgesindeki renk değerlerinden baskın olan değerin belirlenmesi gerekir. Yukarıda anlatılan çalışmada basit cebirsel ortalama ile bulunan bu ağırlık için burada kümeleme yaklaşımlarından yararlanılması düşünülmüştür. Her bir nesne bölgesi için kendi özelinde renk değeri belirlenmesi gerektiği için denetimsiz öğrenme yöntemlerinden birinin kullanılması gerekmektedir. Denetimsiz öğrenme yöntemi ile nesne tespitinde herhangi bir etiketlemeye ihtiyaç duyulmadan renk değerleri kümelenecek baskın renk tonu bilgisi elde edilebilecektir. Belirlenen baskın renk tonu ise yine denetimsiz bir yöntem ile sınıflandırılarak hangi renk tonuna ait olduğu belirlenecek ve çıktı üretilenektir. Bu akış Şekil 3.6’da görülebilir.



**Şekil 3.6: Renk Tespiti Yaklaşımı.**

K-Means farklı özelliklere göre kümeleme yapabilen bir algoritmadır. Öncelikle bu algoritma yardımıyla nesnenin belirlenen sınırları içerisindeki renk tonlamaları 5 kümeye ayrılmıştır. Şekil 3.7’de tek bir nesne ve bu nesnenin renk tonlaması örneği görülmektedir. Şekil incelendiğine b ve c ile gösterilen sonuçlarda çerçeve içerisindeki beyazlığın etkisi görülmektedir. bölütleme işlemi sonrası yapılan kümelemenin renk tespitinde daha başarılı olacağı görülmektedir.



**Şekil 3.7: Örnek Nesnenin Renk Tonu Kümelenmeleri.**  
**(a) Tespit Edilen Nesne, (b) Çerçeve İçerisindeki Alanın Renk Tonu Kümelenmesi ve Görselleştirilmesi, (c) Bölütleme Alanının Renk Tonu Kümelenmesi ve Görselleştirilmesi**

Kümeleme işlemi sonrasında belirlenen baskın renk değerinin sınıflandırılması gerekmektedir. Makine öğrenmesinde kullanılan çeşitli algoritmalar arasından seçilen KNN algoritması sınıflandırma için kullanılmıştır. Öncelikle bu algoritmada kullanılacak renk tonlaması değerlerinin tanımlanması gerekmektedir. ISCC-NBS


sistemi için tanımlar içeren bir çalışmada renk tonları ve adları için aralıklar belirlenmiştir. 3 seviye olarak yapılan sınıflandırmalar giderek detaylanan 13, 29 ve 257 renk tanımı içermektedir (Centore, 2022). Bu çalışmadan yola çıkarak oluşturulan veri setine KNN algoritmasının uygulanmasına karar verilmiştir. Sonuç olarak elde etmek istediğimiz renk tanımı tek olduğu için tek bir yakınlık derecesi belirlenmiş ve uzaklıklar Minkowski yöntemiyle hesaplanmıştır. Mask R-CNN ile birlikte gerçekleştirilen bu işlemin sonucunun örnek bir çıktısı Şekil 3.8’te görülmektedir.



**Şekil 3.8: Nesnelerin Renk Tespiti Sonucu.**

### 3.2 Sensör Füzyonu ile Ortamdaki Nesnelerin Sınıflandırılması

Renk tespiti için geliştirilen ve kullanılan yukarıdaki yöntemin uzaklık ve sıcaklık bilgileri ile de kullanılabileceği değerlendirilmiştir. Bu kapsamda ilgili yöntemi kullanabilmek için her iki tip veride de nesne konumlarının belirlenmesi gerekmektedir. Yukarıda açıklanan veri eşleştirme çalışması sayesinde renkli verilerde tespit edilen nesnenin alanı üzerinden yola çıkarak derinlik ve sıcaklık bilgisi kestirilebilir. Ancak burada derinlik ve sıcaklık bilgilerinden de nesne tespiti yapılabilirse bu üç veride ayrı ayrı yapılacak tespitler ile başarımın artırabileceği düşünülmüştür. Takumi ve arkadaşlarının yaptığı ve Şekil 6'da yapısı görünen çalışmaya bakıldığında farklı özelliklerdeki sıcaklık algılayıcılardan alınan veriler ile optik algılayıcıdan alınan veriler üzerinde ayrı ayrı yapılan tespitlerin birleştirilerek elde edilen sonuçların başarısı görülmektedir (Takumi, ve diğerleri, 2017).




**Şekil 3.9: Farklı Algılayıcılar ile Yapılan Tespitlerin Birleştirilmesi.**

Takumi ve diğerleri (2017)'den uyarlanmıştır.

Yukarıdaki çalışmada kullanılan 4 farklı algılayıcı girdisi yerine bizim çalışmamızda 3 farklı algılayıcı girdisi bulunmaktadır. Bu algılayıcılardan elde edilen derinlik ve

sıcaklık verilerinden oluşturulan görseller kendilerine has özellikler ihtiva ettiğinden her biri için ağ yapısının tekrar eğitilmesi gerekmektedir. Literatürde derinlik ve sıcaklık verileri üzerine farklı veri setleri mevcuttur. Çalışma kapsamında derinlik ve sıcaklık verilerinde insan tespit edebilmek için iki farklı veri setinden yararlanılmıştır. Derinlik görsellerinden insan tespiti yapabilmek için Can ve arkadaşlarının çalışması sonucu ürettikleri veri setinden yararlanılmıştır (Can, Cakir, Namli, & Dutagaci, 2016). Bu veri setinin içerdiği 500 adet görselin 480 tanesi eğitim 20 tanesi de doğrulama verisi olarak ayrılmıştır. Ayrılan veriler üzerinde bölütlemeye uygun bir işaretleme olmadığı için VGG aracı (Dutta & Zisserman, 2019) yardımıyla işaretlenerek eğitime hazır hale getirilmiştir. VGG aracıyla gerçekleştirilen düzenlemeye ait ekran görüntüsü Şekil 3.10’da görülebilir. Sıcaklık verilerinden insan tespiti yapabilmek için ise Palmero ve arkadaşlarının hazırladığı veri seti içeriğindeki sıcaklık verilerinden yararlanılmıştır (Palmero, ve diğerleri, 2016). Sıcaklık verilerinden 4588 görsel eğitim 575 tanesi de doğrulama verisi olarak ayrılmıştır. Bu veri setinde bölütleme işlemi için maske görselleri de bulunduğundan bu maskeler açık kaynak kodlu bir uygulama (waspinator, 2022) yardımıyla eğitimde kullanılacak işaretlemelere dönüştürülmüştür.



**Şekil 3.10: VGG Aracı ile Veri Setinde Düzenleme.**

Mask R-CNN ağı için COCO veri seti ile eğitilmiş ağırlık dosyası kullanılarak Sıcaklık ve Derinlik görselleri ile ayrı ayrı 160 tur eğitilmiştir. Eğitimler sonucu elde edilen ağırlıklar tahmin işleminde kullanılmıştır.

**Tablo 3.1: Sınıflandırma için Aralıklar.**  
(a) Sıcaklık Aralıkları, (b) Uzaklık Aralıkları

| Sıcaklık | Sınıflandırma |
|----------|---------------|
| 30       | Çok Soğuk     |
| 31       | Çok Soğuk     |
| 32       | Çok Soğuk     |
| 33       | Soğuk         |
| 34       | Soğuk         |
| 35       | Normal        |
| 36       | Normal        |
| 37       | Normal        |
| 38       | Sıcak         |
| 39       | Sıcak         |
| 40       | Çok Sıcak     |
| 41       | Çok Sıcak     |
| 42       | Çok Sıcak     |

(a)


| Mesafe | Sınıflandırma |
|--------|---------------|
| 50     | Çok Yakın     |
| 70     | Çok Yakın     |
| 90     | Çok Yakın     |
| 100    | Yakın         |
| 110    | Yakın         |
| 125    | Orta Uzak     |
| 145    | Orta Uzak     |
| 165    | Orta Uzak     |
| 175    | Uzak          |
| 195    | Uzak          |
| 210    | Çok Uzak      |
| 230    | Çok Uzak      |
| 250    | Çok Uzak      |

(b)

Gerçekleştirilen eğitim çalışmaları sonucunda elde edilen ağırlıklar kullanılarak gerçekleştirilen çalışmada her bir algılayıcıdan alınmış veriler üzerinde ayrı ayrı tespit işlemi yapılmıştır. Yapılan tespit işlemlerinden sonra elde edilen nesne konumları kesiştirilerek nihai sonuçlar elde edilmiştir. Yukarıda anlatılan renk belirleme yöntemi burada sıcaklık ve derinlik verilerine uygulanmış ve nesnenin sınıflandırılması gerçekleştirilmiştir. Sıcaklık olarak çok soğuk, soğuk, normal, sıcak, çok sıcak olarak 5 alt sınıflandırma bilgisi tanımlanmıştır. Uzaklık sınıflandırmasında ise benzer

şekilde çok yakın, yakın, orta uzak, uzak ve çok uzak olmak üzere tanımlamalar yapılmıştır. Bu tanımlamaların aralıkları Tablo 3.1’de görülebilir.

Şekil 3.11’de görülen örnek çıktılarda optik görüntüde herhangi bir nesne tespiti yapılamamasına karşın sıcaklık ve derinlik görüntülerinden elde edilen tespit sonuçları Non-Maximum Suppression yöntemiyle kıyaslanarak eşleştirilmiş verilerdeki nesne konumu bulunmuştur. Optik görüntülerde bulunamayan nesne konumu diğer iki görüntüden yola çıkılarak gösterilmiştir. Ayrıca tespitin yanında nesnenin uzaklık ve sıcaklık bilgileri de yorumlanarak bilgi olarak ekranda gösterilebilmiştir.




**Şekil 3.11: Farklı Sensörlerden Alınan Veriler Üzerinde Tespit Çalışması.**

**(a) Optik Görüntü, (b) Sıcaklık Görüntüsü, (c) Derinlik Görüntüsü**

#### 4. VERİ SETİ HAZIRLANMASI


Üç farklı kaynaktan gelecek verileri giriş olarak alarak sonuçta nesne tespiti gerçekleştirilecek bir ağ tasarımı yapılması için araştırmalar yapılmıştır. Literatür incelendiğinde doğrudan üç farklı kaynaktan gelen farklı özellikteki veriler ile sonuç üreten bir ağ yapısı hakkında çok fazla kaynak bulunamamıştır. Bunun yerine derinlik, optik ve sıcaklık gibi farklı kaynaklardan elde edilen verilerin birleştirilmesiyle elde edilen tek bir görüntünün giriş olarak verildiği ağ yapıları üzerine çalışmalar literatürde mevcuttur.

Liu amacı ortamdaki askeri araçları tespit etmek olan bir çalışma gerçekleştirmiştir. Çalışmada durum farkındalığını artırmak için orta dalga kızılötesi (MWIR) ve optik algılayıcılardan gelen görüntüler birleştirilerek yeni bir görüntü elde edilmiştir (Liu & Liu, 2017). Şekil 4.1’te gerçekleştirilen çalışmanın yapısı görülebilir. Şekil incelendiğinde görülen üçüncü katman optik görüntülerden elde edilen hareket katmanıdır. Bu katmanı elde etmek için anlık görüntüden beş kare önceki görüntünün farkı çıkarılır ve ortamdaki hareketli nesnelerin özelliklerini içeren bir görüntü elde edilmiş olur. Gerçekleştirilen ağ yapısı SENSIAC (Military Sensing Information Analysis Centre) veri seti üzerinde sınanmış ve tespit başarımının artırıldığı gözlenmiştir.



**Şekil 4.1: Durum Farkındalığını Artırmak için Çok Kanallı Nesne Tespiti.**

Liu ve Liu (2017)’den uyarlanmıştır.




Şekil 4.2: Yüz Algılayıcı Aldatmacası Engelleme Sistemi.

George ve Marcel (2020)'den uyarlanmıştır.



(a)




(b)

Şekil 4.3: Örnek Çalışmalarda Görüntü Birleştirme İşlemi.

(a) Farklı Özellikteki Görüntülerin Birleştirilmesi,  
(b) Optik, Derinlik ve Termal Görüntülerin Birleştirilmesi

Liu ve Liu (2017) ile George ve Marcel (2020)'den uyarlanmıştır.

George ve Marcel tarafından yapılan çalışmaya bakıldığında ise yüz algılayıcı/tanımlayıcılar için yapılan aldatmacaların önüne geçilmesi amaçlanmıştır. Bu amaçla geliştirilen yaklaşımda optik, derinlik ve kızılötesi algılayıcılardan elde edilen verilerle çalışabilen çok kanallı bir yüz tanımlayıcı elde edilmiştir (George & Marcel, 2020). Liu ve Liu'nun çalışmasına (Liu & Liu, 2017) benzer şekilde burada da farklı algılayıcılardan elde edilen veriler bir uyum içerisinde tek bir görüntü elde edecek şekilde birleştirilmiştir. Şekil 4.2'te yapısı görülen çalışma WMCA (Wide Multi-Channel presentation Attack) veri setinde sınınanarak başarımı ispatlanmıştır.



**Şekil 4.4: Algılayıcılardan Elde Edilen Veriler ve Birleştirilmiş Görüntü.**

**(a) Derinlik, (b) Optik, (c) Sıcaklık, (ç) Birleştirilmiş Görüntü.**

Yukarıdaki çalışmalardan yola çıkılarak tasarlanacak ağın birden fazla algılayıcıdan gelen veriyi tek görüntü verisi olarak alabileceği görülmüştür. Şekil 4.3 incelendiğinde elde edilen verilerin tek bir resim üzerinde birleştirilmesi ve sonuçları gözlenebilir.

Oluşturulacak veri setinin bu özelliklere uygun olarak elde edilmesi gerekliliği göz önüne alınarak algılayıcı verilerinden gelen verilerin tek görsel üzerinde birleştirilmesi üzerinde çalışılmıştır. Şekil 4.4’da görülen örnekte karanlık ortamda elde edilen bir görüntü mevcuttur. Optik görüntüye bakıldığında belli belirsiz bardak göze çarpmakta başka hiçbir nesne ya da ortama ait bilgi ayırt edilememektedir. Derinlik ve sıcaklık verilerinde ise bardağı tutan insan şekli görülebilmektedir. Bu örnekte her iki algılayıcıdan da alınan veriler ile optik algılayıcıdan alınan veriler desteklenebilir.

#### 4.1 Veri Toplanması


Yukarıda ayrıntıları anlatılarak gerçekleştirilen sensör birleştirmesi ile veri seti oluşturulması işlemi bu bölümde açıklanacaktır. Oluşturulacak veri seti için hedef nesne olarak “İnsan” belirlenmiştir. Birbirine sabitlenen sensörler bir üçayak üzerine koyularak ortama sabit bir yerden bakabilmesi ve gerektiğinde yatay ve dikey olarak iki eksende hareket edebilmesi sağlanmıştır. Oluşturulan veri toplama düzeneği Şekil 4.5’de görülebilir. Veri toplama işlemi enstitü binasında açık ile kapalı alanlarda ve değişen ışık koşullarında 8 farklı ortamda 11 farklı zamanda gerçekleştirilmiştir. Veri setinde bulunan görsel sayıları Tablo 4.1’de gösterilmiştir.



**Şekil 4.5: Veri Toplama Düzeneği.**

**Tablo 4.1: Toplanan Verilerin Ortamlara Göre Dağılımı.**

| Ortam                 | Kare Sayısı | Ortam                 | Kare Sayısı |
|-----------------------|-------------|-----------------------|-------------|
| Algılama Laboratuvarı | 134         | Uzaktan Eğitim Sınıfı | 523         |
| Gazino                | 273         | İHA Laboratuvarı      | 709         |
| Kamelya               | 519         | Çalışma Odası         | 250         |
| Koridor               | 494         | Sınıf                 | 408         |
|                       |             | Toplam:               | 3310        |



**Şekil 4.6: Toplanan Verilerin Görselleştirilmesi Örneği.**


**a) Renk Verilerinden Oluşturulan Görsel, b) Sıcaklık Verilerinden Oluşturulan Görsel, c) Derinlik Verilerinden Oluşturulan Görsel**

Veri seti oluşturulurken tekil olarak her bir sensörden (optik, termal ve derinlik) 3310 adet görsel elde edilmiştir. Dolayısıyla, Optik, Derinlik ve Sıcaklık algılayıcılarından 9930 tane görsel elde edilmiştir. Veriler toplandıktan sonra gerçekleştirilecek işlemler (normalizasyon, histogram eşitleme, görüntüye çevirme vb.) sonrası herhangi bir veri kaybı ya da anlam bozulmasını önlemek için toplanan veriler CSV formatında kaydedilmiştir. CSV dosyası, renk sensöründen gelen verileri R, G ve B değerleri için 0-255 aralığında değerler olarak saklanırken derinlik ve sıcaklık verileri için ilgili

SDK'ların dokümanlarında belirtilen ham (RAW) biçimde sayısal olarak saklanmıştır. Bu sayede veri setinin ilerleyen aşamalarda istenilen işlemlerle görüntüye çevrilebilmesi sağlanmıştır. Ayrıca ham veri kullanılarak yapılacak farklı çalışmalar için Uzaklık ve Derinlik değerlerinin de hesaplanabilmesi sağlanmıştır. Şekil 4.6'de CSV olarak kaydedilen değerlerden oluşturulan görseller görülebilir.

#### 4.2 Veri Seti için Toplanan Verilerden Birleşik Verilerin Oluşturulması

Veri seti için toplanan verilerin üzerinde istenildiği gibi işlem yapılarak farklı özelliklerde birleştirilebilmesi için ham veri şeklinde saklanmıştır. Buradan hareketle yukarıda açıklanan birleştirme yöntemi ve kalibrasyon değerleri kullanılarak birleştirme işlemi gerçekleştirilmiştir. Öncelikle toplanan veriler Şekil 4.6'de görüldüğü gibi görselleştirilmiştir. Sonrasında ise yukarıdaki hesaplamalar kullanılarak eşleştirilecek her bir veri için ilgi alanları belirlenmiştir. Belirlenen ilgi alanları Şekil 4.7'da görülebilir.





**Şekil 4.7: Her Bir Algılayıcı Verisinden Elde Edilen İlgi Alanları Örnekleri.**  
**(a) Derinlik Verisinde İlgi Alanı, (b) Optik Veri İlgi Alanı, (c) Termal Veri İlgi Alanı**

Elde edilen ilgi alanı resimleri sonraki bölümde başarımların kıyaslanması işleminde kullanılmak üzere saklanmıştır. Başarımların kıyaslanması ve eğitim için kullanılmak amacıyla veriler üzerindeki insan bölgeleri “YOLO Annotation Tool” aracıyla işaretlenmiştir. İşaretleme işlemi öncelikle sıcaklık görsellerinde gerçekleştirilmiş, sonrasında ise renkli görseller üzerinde doğrulama yapılmıştır. Ayrıca ilgi alanı resimleri kullanılarak farklı özelliklerde birleşimler oluşturulmuş ve başarımların kıyaslanmasına hazır hale getirilmiştir. 3 farklı algılayıcıdan alınan verilerden oluşturulan ilgi alanı resimleri kullanılarak 11 farklı birleşim ve bu birleşimlerin sonucu elde edilen görsellerin gri tonlamalı hali üretilmiştir.

Öncelikle her 3 algılayıcıdan alınan resimlerin gri tonlamalı değerleri alınarak her bir algılayıcı bir kanal oluşturacak şekilde 3 kanallı (RGB) görsel üretilmiştir. Sonrasında ise derinlik verisi kanalı değerleri boş bırakılarak sıcaklık ve renkli verilerle 3 kanallı görsel oluşturulmuştur. Oluşturulan bu görseller Şekil 4.8’de görülebilir.

Sonrasında ise optik ve termal veriler OpenCV’de bulunan ağırlıklı ekleme yöntemi (addWeighted) adı verilen yöntem ile birleştirilmiştir. Bu yöntemde birleştirilecek görsellerin aynı boyut ve tipte olması gerekmektedir. Birleşim işlemi sırasında her iki görselden alınan piksel yoğunluk değerleri istenilen ağırlıklar ile çarpılarak toplanır ve yeni görselin piksel yoğunluk değerini oluşturur. Bu yöntem ile sıcaklık görselleri ile renkli görseller farklı ağırlıklarda eklenmiştir. Renkli görüntü ağırlığı her zaman 1 olmak üzere sıcaklık görüntüsü 0,1~0,9 aralığında 0,1 aralıklarla değişmek üzere 9 farklı birleşim görseli oluşturulmuştur. Oluşturulan tüm görseller ilerleyen çalışmalarda kullanılabilmek adına kaydedilmiştir. Önceki bölümde 3 algılayıcıdan alınarak ham halde kaydedilen veriler bu bölümdeki işlemler ile 26 farklı görsel halinde saklanmıştır. Şekil 4.6’de örnek iki durum için üretilen görseller sırasıyla görülebilir. İlgili şekilde görülen görsellerden elde edilen ilgi alanları Şekil 4.7’de görülürken oluşturulan birleşim görselleri, gri tonlamalı biçimleri ve açıklamaları Tablo 4.2’de verilmiştir. Tablo 4.2 incelendiğinde veri birleşiminin ortamdaki nesne varlığının görünürlüğüne olan katkısı hem sıcaklık hem renkli veriler için iyileştirildiği görülebilir. Sonraki bölümde yapılan çalışma ile bu iyileştirme işleminin başarısı sınanmıştır.



(a)



(b)

**Şekil 4.8: Üç Farklı Algılayıcıdan Elde Edilen Verilerden Üretilen Örnek Görseller.**

**(a) Optik, Derinlik ve Termal Görsellerinin Gri Tonlamalarından 3 Kanal Olarak Oluşturulan Resim ve Gri Tonlamalı Hali, (b) Optik ve Sıcaklık Görsellerinin Gri Tonlamalarından 3. Kanal Boş Olarak Oluşturulan Resim ve Gri Tonlamalı Hali**

**Tablo 4.2: İlgi Alanı ve Birleşim Görselleri.**

| Açıklama                                                                                       | Birinci Örnek                                                                                                                                                              | İkinci Örnek                                                                                                                                                                   |
|------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Renkli resim üzerine 0,1 Oranında Termal Resim Eklenmesiyle oluşan resim ve Gri Tonlamalı Hali | <br>    | <br>    |
| Renkli resim üzerine 0,2 Oranında Termal Resim Eklenmesiyle oluşan resim ve Gri Tonlamalı Hali | <br> | <br> |

Renkli resim üzerine 0,3  
Oranında Termal Resim  
Eklenmesiyle oluřan  
resim ve Gri Tonlamalı  
Hali



Renkli resim üzerine 0,4  
Oranında Termal Resim  
Eklenmesiyle oluřan  
resim ve Gri Tonlamalı  
Hali



Renkli resim üzerine 0,5  
Oranında Termal Resim  
Eklenmesiyle oluřan  
resim ve Gri Tonlamalı  
Hali



Renkli resim üzerine 0,6  
Oranında Termal Resim  
Eklenmesiyle oluřan  
resim ve Gri Tonlamalı  
Hali



Renkli resim üzerine 0,7  
Oranında Termal Resim  
Eklenmesiyle oluşan  
resim ve Gri Tonlamalı  
Hali



Renkli resim üzerine 0,8  
Oranında Termal Resim  
Eklenmesiyle oluşan  
resim ve Gri Tonlamalı  
Hali





#### 4.3 Veri Seti Üzerinde Derin Öğrenme ile Başarım Kıyaslaması

Sensör füzyonuna dayalı nesne algılama performansını test etmek için algılama ve sınıflandırma doğruluğu, önceden eğitilmiş bir evrimsel sinir ağı kullanılarak ölçülmüştür. Önceki bölümde ilgi alanlarından oluşturulan birleşim görsellerin her biri ayrı ayrı saklanarak derin öğrenme üzerinde başarımları kıyaslanmıştır. Kıyaslamada YOLO ağının 4. versiyonu ve bu ve bu ağın COCO Veri seti ile eğitilmiş ağırlıkları kullanılmıştır. Sınama işlemlerinin sonuçları alınırken sadece “İnsan” sınıfını sonuçları değerlendirilmeye alınmıştır. Yukarıda bahsedilen 8 farklı ortamdaki 11 farklı zamandaki veriler üzerinde elde edilen sonuçlar aşağıdaki tablolarda verilmiştir. Her bir ortam için tabloda gösterilen ölçütlerin anlamları şu şekildedir;

- TP (True Positive): Ağın doğru tespit ettiği nesne sayısı
- FP (False Positive): Ağın yanlış tespit ettiği nesne sayısı
- FN (False Negative): Ağın tespit edemediği nesne sayısı
- Precision (Kesinlik): Doğru tespit edilen nesnelerin oranını gösteren ölçüt.

$$Precision = \frac{TP}{TP + FP}$$

- Recall (Duyarlık): Doğru tespit edilmesi gereken nesnelerin oranını gösteren ölçüt.

$$Recall = \frac{TP}{TP + FN}$$

- F1 Score(F1 Puanı): Kesinlik ve duyarlık ölçütlerinin harmonik ortalamasını gösteren başarımlı ölçütü.

$$F_1 = 2 * \frac{Precision * Recall}{Precision + Recall}$$

- Average Precision (Ortalama Kesinlik): Kesinlik ve Duyarlık eğrisinin altında kalan alanı ölçen ve başarımlı tanımlayan diğer bir ölçüt.


$$AP = \int_0^1 p(r)dr$$

- Average IoU (Intersection over Union): Ortalama kesişim ve birleşim olarak adlandırılan ve tespit edilen nesneyi içeren kutunun doğruluğunu hesaplayan bir ölçüt.

Tabloda gösterilen başlıklardaki birleştirme yöntemleri ise şu şekildedir;

- Derinlik: Derinlik görseli
- Renkli: Renkli görseli
- Sıcaklık: Sıcaklık verilerinden elde edilen görsel
- RGBDT: Renkli, Derinlik ve Sıcaklık görsellerinin gri tonlamalarından 3 kanal olarak oluşturulan resim
- RGBT: Renkli görsel üzerine 0,8 ağırlıkla sıcaklık resim eklenmesiyle oluşan görsel

- RT: Derinlik verisi olmadan 3. kanal boş bırakılarak oluşturulan resim
- TxR: Renkli görsel üzerine 0,x ağırlıkla sıcaklık görseli eklenmesiyle oluşan görsel




(a)



(b)



(c)



(ç)


**Şekil 4.9: Veri Setinde Tespit Örnekleri.**

**Tablo 4.3: Tüm Veri Setinde Sınama Sonuçları.**


|                       | <b>F1</b>      | <b>Precision</b> | <b>Recall</b>  | <b>IoU</b>  | <b>AP</b>    | <b>TP</b>   | <b>FP</b> | <b>FN</b>   |
|-----------------------|----------------|------------------|----------------|-------------|--------------|-------------|-----------|-------------|
| <b>Derinlik</b>       | 0.03479        | 0.66234          | 0.01786        | 0.42        | 9.11         | 102         | <b>52</b> | 5608        |
| <b>Renkli</b>         | 0.75923        | 0.79574          | 0.72592        | 0.66        | 77.68        | 4145        | 1064      | 1565        |
| <b>Sıcaklık</b>       | 0.34554        | 0.88147          | 0.21489        | <b>0.72</b> | 42.39        | 1227        | 165       | 4483        |
| <b>Sıcaklık (Gri)</b> | 0.58481        | 0.85268          | 0.44501        | 0.69        | 68.65        | 2541        | 439       | 3169        |
| <b>RGBDT</b>          | 0.27421        | <b>0.88697</b>   | 0.16217        | 0.68        | 37.73        | 926         | 118       | 4784        |
| <b>RGBDT (Gri)</b>    | 0.45833        | 0.83441          | 0.31594        | 0.65        | 51.19        | 1804        | 358       | 3906        |
| <b>RGBT</b>           | 0.66496        | 0.85005          | 0.54606        | 0.69        | 73.13        | 3118        | 550       | 2592        |
| <b>RGBT (Gri)</b>     | 0.78712        | 0.84509          | 0.73660        | 0.69        | 84.63        | 4206        | 771       | 1504        |
| <b>T1R</b>            | 0.77036        | 0.81076          | 0.73380        | 0.65        | 83.14        | 4190        | 978       | 1520        |
| <b>T1R (Gri)</b>      | 0.78903        | 0.82213          | 0.75849        | 0.68        | 85.09        | 4331        | 937       | 1379        |
| <b>T2R</b>            | 0.76411        | 0.82224          | 0.71366        | 0.70        | 81.64        | 4075        | 881       | 1635        |
| <b>T2R (Gri)</b>      | 0.79647        | 0.82882          | 0.76655        | 0.68        | 86.14        | 4377        | 904       | 1333        |
| <b>T3R</b>            | 0.75256        | 0.82186          | 0.69405        | 0.68        | 80.94        | 3963        | 859       | 1747        |
| <b>T3R (Gri)</b>      | <b>0.79851</b> | 0.82875          | <b>0.77040</b> | 0.68        | <b>86.22</b> | <b>4399</b> | 909       | <b>1311</b> |
| <b>T4R</b>            | 0.74836        | 0.83248          | 0.67968        | 0.69        | 80.02        | 3881        | 781       | 1829        |
| <b>T4R (Gri)</b>      | 0.79749        | 0.82946          | 0.76790        | 0.68        | 86.08        | 4387        | 902       | 1326        |
| <b>T5R</b>            | 0.73674        | 0.83496          | 0.65919        | 0.69        | 78.86        | 3764        | 744       | 1946        |
| <b>T5R (Gri)</b>      | 0.79462        | 0.83183          | 0.76060        | 0.69        | 85.80        | 4343        | 878       | 1367        |
| <b>T6R</b>            | 0.72471        | 0.84544          | 0.63415        | 0.70        | 77.21        | 3621        | 662       | 2089        |
| <b>T6R (Gri)</b>      | 0.79286        | 0.83579          | 0.75412        | 0.69        | 85.40        | 4306        | 846       | 1404        |
| <b>T7R</b>            | 0.70425        | 0.85340          | 0.59947        | 0.70        | 75.34        | 3423        | 588       | 2287        |
| <b>T7R (Gri)</b>      | 0.75911        | 0.77076          | 0.74781        | 0.69        | 85.06        | 4270        | 1270      | 1440        |
| <b>T8R</b>            | 0.75370        | 0.85578          | 0.67338        | 0.70        | 83.60        | 3845        | 648       | 1865        |
| <b>T8R (Gri)</b>      | 0.73197        | 0.86943          | 0.63205        | 0.71        | 81.23        | 3609        | 542       | 2101        |
| <b>T9R</b>            | 0.63395        | 0.85262          | 0.50455        | 0.70        | 71.03        | 2881        | 498       | 2829        |
| <b>T9R (Gri)</b>      | 0.78235        | 0.84757          | 0.72644        | 0.70        | 84.13        | 4148        | 746       | 1562        |

Her bir ortam için ayrı ayrı sına sonuçları Ek 1’de yer alan tablolarda gösterilmiştir. Ayrıca tüm veri seti üzerinde, her bir ham verinin doğruluğunun ve birleştirme yönteminin ayrıntılı olarak verildiği Tablo 4.3’te gösterilmiştir. Yukarıda açıklanan True Positive, False Positive, False Negative, Precision, Recall, F1 Score, Avarage Precision, Average IoU değerlerinin tümü için hesaplanmış ve gösterilmiştir. Yetersiz ışık koşullarında, RGB sensör verileri için doğruluk önemli ölçüde artarken, yeterli aydınlatma olmadığı durumlarda azalmaktadır. Termal verilere bakıldığında ise tam tersi bir durum gözlenebilir. Sonuçlara bakıldığında birleşim işlemi sonrası hem termal hem de optik verilerdeki tespit doğruluğunun arttığı ortadadır. Her bir metrik için en iyi değerler Tablo 4.3’te kalın harflerle vurgulanmıştır. Her ne kadar tüm metrikler hesaplanıp gösterilmiş olsa da diğer değerlerden hesaplandığı için F1 puanı değeri odak noktası olarak değerlendirilebilir. F1 puanlarına bakıldığında, 0.1, 0.2 ve 0.3 termal ağırlıklı birleşimler göze çarpmaktadır. Bu değerler arasında 0,3 ağırlıklı birleştirme biraz daha iyi performans göstermiştir. Bu nedenle bundan sonraki sınamalarda temel olarak 0.3 termal ağırlıklı birleşim kullanılmıştır.


Termal ve RGB verilerinde insan tespiti, iki örnek senaryo için Şekil 4.9’de görülebilir. Şekil 4.9 (a)’da gösterildiği gibi şeffaf bir engelin arkasında bir insanı tespit etmenin mümkün olduğu durumlarda, bu insan Şekil 4.9 (c)’de görüldüğü gibi termal veriler kullanılarak tespit edilemez. Ayrıca görüş alanındaki ikinci insan optik verilerde tespit edilebilirken, termal verilerde yanlış sınıflandırılmaktadır. Şekil 4.10 (a)’daki birleşik veriler göz önüne alındığında, engellerin arkasındaki insanın algılama doğruluğunun arttığı gösterilmiştir. Görüş alanındaki ikinci kişi için algılama doğruluğu optik verilere göre düşse bile sınıflandırma doğrudur. İkinci senaryoda, düşük ışıklı bir koridordan elde edilen veriler Şekil 4.9 (b) ve Şekil 4.9 (d)’de görülebilir. Her iki veri türünde de görüş alanındaki 3 kişiden 1’i tespit edilememektedir. Şekil 4.10 (b)’de verilen birleşik verilerde, füzyon öncesi verilere göre 3 kişinin tamamının daha doğru tespit edildiği görülmektedir.



(a)



(b)



(c)



(ç)

**Şekil 4.10: Veri Setinden Oluşturulan Birleşik Resimler Üzerinde Tespit Örnekleri.**


Algılayıcı verilerini birleştirme işleminin başarımı ise Tablo 4.4'te görülebilir. Önceki kıyaslamalarla seçilen 0,3 ağırlıklı sıcaklık verileri ile elde edilen sonuçların Renkli ve Sıcaklık verisinden üretilen görseller ile elde edilen sonuçlara göre başarımların kıyaslaması verilmiştir. Tablo 4.4 incelendiğinde algılayıcıların bir arada başarıyla kullanılmasının nesne tespitini dikkate değer oranda iyileştirdiği gözlenmiştir. Yine burada da diğer ölçütlerden hesaplanan F1 puanı değeri baz alınır ise renkli veriler üzerindeki tespit başarısının %5, sıcaklık verilerinden üretilen görseller üzerindeki tespit başarısının ise %37 oranında arttığı görülebilir.

**Tablo 4.4: Sensör Birleşiminin Nesne Tespitindeki Başarım Artış Yüzdeleri.**

|                  | <b>Renkli</b> | <b>Sıcaklık(Gri)</b> | <b>T3RG</b> | <b>Renkli Veriye Göre Başarım Artımı</b> | <b>Sıcaklık Verisine Göre Başarım Artımı</b> |
|------------------|---------------|----------------------|-------------|------------------------------------------|----------------------------------------------|
| <b>AP</b>        | 77,68         | 68,65                | 86,22       | 11%                                      | 26%                                          |
| <b>TP</b>        | 4145          | 2541                 | 4399        | 6%                                       | 73%                                          |
| <b>FP</b>        | 1064          | 439                  | 909         | 17%                                      | -52%                                         |
| <b>FN</b>        | 1565          | 3169                 | 1311        | 19%                                      | 142%                                         |
| <b>Avg IoU</b>   | 0,66          | 0,69                 | 0,68        | 3%                                       | -1%                                          |
| <b>F1 Score</b>  | 0,75923       | 0,58481              | 0,79851     | 5%                                       | 37%                                          |
| <b>Recall</b>    | 0,72592       | 0,44501              | 0,77040     | 6%                                       | 73%                                          |
| <b>Precision</b> | 0,79574       | 0,85268              | 0,82875     | 4%                                       | -3%                                          |

#### 4.4 Veri Seti ile Gerçekleştirilen Eğitim ve Elde Edilen Başarım

Başarım kıyaslamasından sonra ağ yapısının eğitilerek tekrar sınanması aşamasına geçilmiştir. Bu amaçla önceki bölümlerde başarımı gösterilen 0,3 oranında Sıcaklık Resmi ile desteklenmiş Renkli Resimlerin Gri Tonlamalı halleri kullanılmıştır. Toplamda 3310 tane olan verilerin 662 tanesi (%20) doğrulama için ayrılırken 2648 tanesi (%80) ise eğitim için ayrılmıştır. Eğitim yaklaşık 120 epoch olacak şekilde 10.000 iterasyon olarak gerçekleştirilmiştir. Eğitim esnasında elde edilen mAp ve AVG Loss grafiği Şekil 4.11’te görülebilir. Şekil incelendiğinde yaklaşık 2000 iterasyondan sonra başarımın çok değişmediği gözlenebilmektedir.



Şekil 4.11: Eğitim Grafiği.

Tablo 4.5: Eğitim Sonrası Sınama Sonuçları.

| AP   | TP   | FP | FN | Average IoU | Recall | Precision | F1-Score |
|------|------|----|----|-------------|--------|-----------|----------|
| 0.92 | 1120 | 98 | 37 | 0.73        | 0.97   | 0.92      | 0.94     |

Tablo 4.6: Eğitim Sonrası Nesne Tespiti Başarım Artış Yüzdeleri.

|             | Optik                                    | Termal | Birleşik* |
|-------------|------------------------------------------|--------|-----------|
|             | verilere göre başarımların artış yüzdesi |        |           |
| Average IoU | 12 %                                     | 7 %    | 8 %       |
| F1-score    | 24 %                                     | 61 %   | 18 %      |
| Recall      | 33 %                                     | 118 %  | 26 %      |
| Precision   | 16 %                                     | 8 %    | 11 %      |

\*Birleştirilmiş görüntü, yukarıdaki metriklerle göre en iyi birleştirme yöntemiyle elde edilir (0,3 ağırlıklı Termal ve RGB Görüntünün Gri Tonlaması).

Eğitim sonucunda elde edilen en iyi ağırlık değerleri ile test verileri tekrar sınanmış ve başarımlar Tablo 4.5’de gösterilmiştir. Eğitimden sonraki tespit örnekleri Şekil 4.10 (c) ve Şekil 4.10 (ç)’de görülebilir. Şekillerde gösterildiği gibi, veri füzyonu algılama doğruluğunu artırırken, yeni oluşturulan veri kümesindeki zorlu verileri test etmek performansı daha da artırır. Yeni oluşturulan veri seti ile eğitim sonrası füzyon yöntemi ile performans metriklerinin iyileştirilmesi Tablo 4.6’de sunulmaktadır. Tablo değerlendirildiğinde, birleştirilmiş verilerden elde edilen performansın daha da arttığı görülmektedir. Son olarak F1 puanlarına göre sensör füzyon işleminden sonra optik sensörün insan algılama doğruluğunun %24, termal sensörün algılama doğruluğunun ise %61 arttığı söylenebilir. Performans iyileştirmesi ayrıca mevcut diğer füzyon yöntemleriyle karşılaştırılmıştır. Tablo 4.7’de listelendiği gibi, bazı çalışmalar bir veri seti oluşturma ve nesne algılama performansları sunuşlardır. (John, Tsuchizawa, Liu, & Mita, 2016) yaptıkları çalışmada 1640 kare kullanılmış ve F1 skoru 0,899 olarak ölçülmüştür ki bu her ikisi de bizim çalışmamızdan daha küçüktür.

**Tablo 4.7: Mevcut Çalışmalarla Performans Karşılaştırması.**


| <b>Referans Çalışma</b>                           | <b>Görsel sayısı</b> | <b>Kare başı ortalama birleştirme (s)</b> | <b>F1 puanı</b>  |
|---------------------------------------------------|----------------------|-------------------------------------------|------------------|
| Yang et al. (YANG, SU, & LIN, 2018)               | 0                    | 1.66                                      | Nesne tanıma yok |
| Cao et al. (CAO, VE DİĞERLERİ, 2018)              | 0                    | 0.02                                      | Nesne tanıma yok |
| John et al. (JOHN, TSUCHIZAWA, LIU, & MITA, 2016) | 1640                 | 0.06                                      | 0.899            |
| Tez Çalışması                                     | 3310                 | 0.02                                      | 0.94             |

## 5. ÇOK MODLU YAPAY SİNİR AĞI TASARLANMASI

Tez çalışmasının önceki bölümlerinde bir sensör füzyon yöntemi geliştirilmiş ve bu yöntem ile literatürde var olan yöntemler kullanılarak çeşitli sınamalar yapılmıştır. Bu bölümde ise literatürdeki az sayıda örnek arasında yerini alacak çok modlu (multimodal) bir yapay sinir ağı tasarımı gerçekleştirilmiştir.

### 5.1 Çok Modlu Yapy Sinir Ağı

Çok modlu yapay sinir ağı birden fazla tipte veriyi giriş olarak alan ve istenilen sonucu üreten bir yapı olarak tanımlanabilir. Önceki bölümlerde açıklanan çalışmalar çerçevesinde literatür incelenmiştir. Eşleştirilmiş optik ve termal görüntüleri bir arada kullanarak nesne tespiti yapabilen çeşitli ağlar literatürde mevcuttur. Termal ve optik görüntüleri birlikte kullanarak nesne izleme (object tracking) başarısını artırmaya çalışan bir çalışmada yapay sinir ağına ayrı ayrı alınan verilerden yapılan çıkarımlar tespit işlemi öncesinde birleştirilmiştir (Li, Wu, Zhao, Cao, & Tang, 2018). Gerçekleştirilen benzer bir çalışmada da termal ve optik verilerden yapılan çıkarımlar farklı şekillerde birleştirilerek kullanılmıştır (Zhang, Xiao, Huang, Zhang, & Han, 2021) . Li ve arkadaşlarının çalışmasından daha ayrıntılı olan bu çalışmada optik ve termal verilerden elde edilen çıkarımlar doğrudan eklenmek yerine önerilen bir ağırlık belirleme yöntemi ile birleştirilmiştir. Literatürde var olan temel birleşim yaklaşımları Şekil 5.1’de görülebilir. Burada 3 farklı yaklaşım bulunmaktadır. İlk yaklaşımda optik ve termal görüntülerdeki özellikler ayrı ayrı çıkarılarak her bir piksel bazında ekleme yapılarak veriler elde edilmektedir. İkinci yaklaşımda optik ve termal özellikler birleştirilerek bir arada kullanılmaktadır. Son yaklaşımda ise belirli özelliklere ve durumlara göre yapılacak seçimler ile optik ve termal verilerden yapılan çıkarımlar değişen oranlarda birleştirilmektedir.




**Şekil 5.1: Optik ve Termal Özellik Birleşimleri.**

**a) Element Bazında Toplama, (b) Birleşim (Concatenation), (c) Ağırlık Belirleme**

Zhang vd. (2021)'den uyarlanmıştır.

Literatürdeki yöntemlere bakıldığında basitlik ve hız açısından optik ve termal verilerde yapılacak özellik çıkarımlarının element bazında eklenerek kullanılması düşünülmüştür. Nesne tespiti için çalışmaların önceki bölümlerinde kullanılan YOLO ağının 4. versiyonun genel yapısı Şekil 5.2 a)' da görülebilir. Ağ yapısı çok katmanlı olmasına karşın temelde üç alt ana bölüme ayrılabilir. İlk bölüm olan omurga özellik çıkarımının yapıldığı bölümdür. Boyun bölümünde çıkarılan bu özellikler üstünde

çeşitli işlemler yapılarak kafa bölümünde ise nihai tespit ve sınıflandırma işlemi gerçekleştirilir. Çalışmada kullanılan termal ve optik veriler birbirini destekleyecek nitelikte özellikler içerdiği için önerilecek çözümün her iki veriden de özellik çıkarması gerektiği ortadadır. Önceki bölümlerde gerçekleştirilen belirli oranlarda veri karıştırma işlemi yerine burada her bir veriden özelliklerin çıkarılması ve birbirine eklenmesi düşünülmüştür. Bu yapıyı sağlamak için tek omurgalı YOLO ağ yapısı termal ve optik verileri bir arada işleyebilecek şekilde çift omurgalı olarak uyarlanmıştır. Şekil 5.2 b)'de yapısı görülebilecek uyarlanmış ağda iki koldan yürüyen özellik çıkarım ağı boyun kısmına gelmeden birleşmektedir. Şekli verilen ağ yapısı Tensorflow kütüphanesi ile Python dilinde gerçekleştirilerek eğitim ve sınama işlemine hazır hale getirilmiştir.




**Şekil 5.2: Nesne Tespit Ağ Yapısı.**

**a) Yolo Ağı Genel Yapısı, b) Çok Modlu Olarak Uyarlanan Yapı**

## 5.2 Çok Modlu Yapı Sinir Ağının Eğitimi ve Sınanması

Geliştirilen çok modlu YSA sınanması için çalışmanın önceki bölümlerinde oluşturulan veri setinden yararlanılmıştır. Hazırlanan veri setindeki görseller herhangi bir birleştirme işlemine tabi tutulmadan doğrudan YSA girişlerine verilmiş ve eğitim

işlemi gerçekleştirilmiştir. Eğitim işlemi için veri setinin %20'si doğrulama ve %80'si test verisi olarak ayrılmıştır. 80 döngü (epoch) ve yaklaşık 50 bin iterasyon süren eğitim sonucu oluşan total loss grafiği Şekil 5.3'te görülebilir.



Şekil 5.3: Eğitim Grafiği.

Tablo 5.1: Sınama Sonuçları.

| AP   | TP   | FP | FN | Average IoU | Recall | Precision | F1-Score |
|------|------|----|----|-------------|--------|-----------|----------|
| 0.91 | 1059 | 58 | 98 | 0,82        | 0,92   | 0,95      | 0,93     |

Tablo 5.2: Eğitim Sonrası Nesne Tespiti Başarım Artış Yüzdeleri.

|             | Optik                                    | Termal | Birleşik* |
|-------------|------------------------------------------|--------|-----------|
|             | verilere göre başarımların artış yüzdesi |        |           |
| Average IoU | 24 %                                     | 18 %   | 21 %      |
| F1-score    | 22 %                                     | 59 %   | 16 %      |
| Recall      | 27 %                                     | 107 %  | 19 %      |
| Precision   | 19 %                                     | 11 %   | 15 %      |

\*Birleştirilmiş görüntü, yukarıdaki metriklerle göre en iyi birleştirme yöntemiyle elde edilir (0,3 ağırlıklı Termal ve RGB Görüntününün Gri Tonlaması).

Eğitim sonucunda elde edilen ağırlık değerleri ile test verileri sınanmış ve başarımlar Tablo 5.1'de gösterilmiştir. Tablo incelenip Tablo 4.5'te verilen eğitim sonuçları ile kıyaslandığında başarımın birbirine çok yakın olduğu görülmektedir. Önceki

bölümlerde açıklandığı gibi veri füzyonu algılama başarısını artırmaktadır. Özgün veri seti ile uyarlanan çok modlu YSA' nın eğitimi sonrası performans metriklerinin iyileştirilmesi Tablo 5.2' de sunulmuştur. Tabloya bakıldığında optik ve termal verilerin tekil kullanımına göre bariz başarı artımı görülmektedir. Birleşik verilerden elde edilen görseller ile en iyi tespit sonucunun da artırıldığı görülebilir. F1 puanlarına bakıldığında uyarlanan çok modlu ağın verilerin ön işlemlerle birleştirildiği ağa göre %16 başarı artışı sağladığı görülebilir. Yolo ağının eğitimi sonrası sınav sonuçlarını içeren Tablo 4.5 ve uyarlanan çok modlu ağın sınav sonuçlarını içeren Tablo 5.1 incelendiğinde başarımların birbirine çok yakın olduğu görülmektedir. Her iki ağ modelinin eğitilmesi sonucu elde edilen başarı iyileştirmeleri kıyaslamalı olarak Tablo 5.3'de görülebilir. Dördüncü bölümde gerçekleştirilen eğitimde 0,3 ağırlıklı termal veri ile desteklenen optik veri üzerinde sınav yapılmıştır. Burada 0,3 ağırlığı seçmek için yapılan sınamalar ilgili bölümde anlatılmıştır. Çok modlu yapay sinir ağında ise herhangi bir ön birleştirme işlemi olmadan ve hangi ağırlıkta seçim yapılacağı belirlenmeden tespit işlemi gerçekleştirilebilmiştir.

**Tablo 5.3: Tek ve Çok Modlu Ağların Başarı İyileştirme Karşılaştırması.**

|                    | <b>Tek Modlu Eğitim Sonucu</b> | <b>Çift Modlu Eğitim Sonucu</b> |
|--------------------|--------------------------------|---------------------------------|
| <b>Average IoU</b> | % 8                            | % 21                            |
| <b>F1-score</b>    | % 18                           | % 16                            |
| <b>Recall</b>      | % 26                           | % 19                            |
| <b>Precision</b>   | % 11                           | % 15                            |

## 6. SONUÇ

Bu çalışmada, farklı çevresel koşullar altında insan algılama doğruluğunu iyileştirmek için termal ve RGB-D sensörlerini birlikte kullanan basit ve verimli bir sensör füzyon yaklaşımı gerçekleştirilmiştir. Birden fazla sensörün çeşitli özelliklerinden yararlanmak için, değişen çevresel koşullara uyum sağlamak için uyarlanabilir bir yöntem kullanılarak birleştirilirler. Gerçekleştirilen yöntem, termal ve RGB-D sensörleri arasındaki esnek füzyon ilişkisini tanımlar. Bu yöntem ile bilinmeyen özniteliklere sahip sensörler tarafından toplanan ve farklı özellikler içeren veriler, sınırlı işlemci yetenekleri ile gerçek zamanlı olarak başarılı bir şekilde birleştirilir. Bu nedenle, gözetim veya kurtarma sistemleri gibi gerçek zamanlı problemlere uygulanabilir. Yöntem, sensör modelinden bağımsız olduğu için, özellikleri bilinmeyen çeşitli sensör türlerine de kolayca uygulanabilir. Bu nedenle farklı ortam veya koşullarda görevlerde kullanılabilir.

Düşük ışık ve şeffaf engeller gibi zorlu koşullara sahip bir veri kümesi kullanmak, insan algılaması için daha düşük doğrulukla sonuçlanır. Bununla birlikte, sensör füzyonu, doğru kullanıldığında algılama doğruluğunu artırır. Bu çalışmada, nesne tespit çalışmalarında hibrit verilerin başarısını göstermek için örnek nesne olarak insan seçilirken, aynı yöntemin hayvanlar ve araçlar gibi farklı nesneler için de kolaylıkla uygulanabilir. Yeni oluşturulan özgün veri seti, yöntem kullanılarak eşleştirilen verilerin farklı piksel yoğunluk değerleri ile hazırlanmıştır. Yöntemin başarısı, precision, recall ve F1 puanı gibi iyi bilinen ölçütlerle gösterilmiştir. Yöntemin doğruluğu, COCO veri seti ile eğitilmiş ağırlıklara sahip YOLOv4 sinir ağı üzerinde değerlendirilmiştir. Sonuç olarak, termal verilerde doğruluk oranı %37 artarken, optik verilerde algılama doğruluğu %5 artmıştır.

Sensör füzyonun başarısı ispatlandıktan sonra birleştirilmiş verilerle yapay sinir ağı eğitim ve sınamaları gerçekleştirilmiştir. Öncelikle YOLOv4 ağı COCO ağırlıkları yerine özgün hibrit veri seti ile eğitilmiştir. Eğitim sonucu doğruluğu önceden eğitilmiş ağ ve tek sensör verisi ile karşılaştırılmıştır. Eğitimden sonra, bir termal sensör ve bir optik sensör birlikte kullanıldığında, algılama doğruluğu yalnızca bir

optik sensör kullanmaya kıyasla %18 ve yalnızca bir termal sensör kullanmaya kıyasla %61 arttığı hesaplanmıştır. Sensör verilerinin birleştirilmesinin insan algılama doğruluğunu arttırdığı ve yeni oluşturulan özgün hibrit veri setinin eğitimi ile bu doğruluğun daha da arttığı gözlemlenmiştir. Füzyon yönteminin performansı, füzyon süresi ve tespit doğruluğu ile literatürde var olan diğer füzyon yöntemleriyle de karşılaştırılmıştır. Karşılaştırmalara bakıldığında yöntemimizin daha iyi sonuçlar verdiğini gösterilmiştir.

Çalışmanın son bölümünde açıklanan çok modlu yapay sinir ağı literatürdeki az sayıdaki örneğinin yanında yerinde olacaktır. Çok modlu YSA ile önceki bölümlerde yapılan ön işlemlere gerek duymadan termal ve optik veriler birlikte kullanılarak insan tespit başarısının artırıldığı gözlenmiştir. Özgün veri seti ile yapılan eğitim sonrasında F1 puanı, precision ve recall ölçütleri ile sına yapılmış ve sonuçlar karşılaştırmalı olarak verilmiştir. Sonuçlar incelendiğinde F1 puanına göre başarımın %16 artırıldığı gözlenmiştir. Önceki bölümlerde yapılan ön birleştirme işlemine ihtiyaç duymadan tespit yapılabilmesi bu ağın avantajı olmuştur.

Bu çalışmanın sonuçlarına dayanarak önerilen füzyon yöntemi, insan gözetimi ve afet sonrası arama kurtarma operasyonları gibi gerçek zamanlı problemlerde daha kesin bir algılama sistemi elde etmek için kullanılabilir. Önerilen füzyon yönteminin sensör üreticisi ve markasından bağımsız olması ve düşük hesaplama maliyeti gerektirmesi nedeniyle, İHA'lar gibi robotik sistemlerde daha yüksek doğruluk oranları elde etmek için kolaylıkla uygulanabilir. Çalışmanın literatüre katkısı kullanılarak daha iyi sonuçlar elde etmek için YOLO yerine özelleştirilmiş bir ağı kullanılabilir. Ayrıca yöntem kullanılarak farklı benzersiz özellikleri elde etmek için çeşitli özellikleri algılayan sensörlerin verileri topluca eşleştirilebilir. Çevrenin daha geniş görünümü elde etmek için aynı tip sensörlerin sayısı artırabilir. Tespit edilen insanlar, nesnelerin sıcaklığının ve mesafesinin daha doğru olarak belirlenebildiği segmentasyon yöntemleri kullanılarak da sınıflandırılabilir. Ayrıca, yöntemin başarısı, mobil robotların çalıştığı bir afet bölgesinde veya gözetleme konumunda sınanabilir. Son bölümde açıklanan çok modlu yapay sinir ağı literatürde var olan hibrit veri setleri ile sınanarak başarımı ispatlanabilir. Ayrıca yapay sinir ağında kullanılan omurga ağılar literatürdeki farklı ağılar ile değiştirilerek başarımların kıyaslaması yapılabilir. Yapılacak bu değişim ve kıyaslamalarla literatüre katkı sağlanabilir.

## KAYNAKÇA

- Alparslan, Ö., & Çetin, Ö. (2021, June). Comparison of Object Detection and Classification Methods For Mobile Robots. *Sakarya University Journal of Science*, 25, 764–778. doi:10.16984/saufenbilder.828841
- Aman, M. S., Mahmud, M. A., Jiang, H., Abdelgawad, A., & Yelamarthi, K. (2016). A sensor fusion methodology for obstacle avoidance robot. *2016 IEEE International Conference on Electro Information Technology (EIT)*, (s. 458-463). doi:10.1109/EIT.2016.7535284
- Ambrosch, K., Zinner, C., & Leopold, H. (2010). A miniature embedded stereo vision system for automotive applications. *2010 IEEE 26-th Convention of Electrical and Electronics Engineers in Israel*, (s. 786-789). doi:10.1109/EEEI.2010.5662105
- Bastanlar, Y., Temizel, A., & Yardimci, Y. (2009). Automatic point matching and robust fundamental matrix estimation for hybrid camera scenarios. *2009 IEEE 17th Signal Processing and Communications Applications Conference*, (s. 177-180). doi:10.1109/SIU.2009.5136361
- Ben-Ari, R., & Sochen, N. (2010). Stereo Matching with Mumford-Shah Regularization and Occlusion Handling. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32, 2071-2084. doi:10.1109/TPAMI.2010.32
- Ben-Artzi, G., Halperin, T., Werman, M., & Peleg, S. (2016). Epipolar geometry based on line similarity. *2016 23rd International Conference on Pattern Recognition (ICPR)*, (s. 1864-1869). doi:10.1109/ICPR.2016.7899908
- Bleyer, M., & Gelautz, M. (2005, May). A layered stereo matching algorithm using image segmentation and global visibility constraints. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59, 128–150. doi:10.1016/j.isprsjprs.2005.02.008
- Boudjit, K., & Ramzan, N. (2021, April). Human detection based on deep learning YOLO-v2 for real-time UAV applications. *Journal of Experimental & Theoretical Artificial Intelligence*, 34, 527–544. doi:10.1080/0952813x.2021.1907793
- Can, G. N., Cakir, B., Namli, A. T., & Dutagaci, H. (2016, May). Detection of humans from depth images. *2016 24th Signal Processing and Communication Application Conference (SIU)*. IEEE. doi:10.1109/siu.2016.7496030

- Cao, Y., Xu, B., Ye, Z., Yang, J., Cao, Y., Tisse, C.-L., & Li, X. (2018, March). Depth and thermal sensor fusion to enhance 3D thermographic reconstruction. *Optics Express*, 26, 8179. doi:10.1364/oe.26.008179
- Carrio, A., Lin, Y., Saripalli, S., & Campoy, P. (2017, March). Obstacle Detection System for Small UAVs using ADS-B and Thermal Imaging. *Journal of Intelligent & Robotic Systems*, 88, 583–595. doi:10.1007/s10846-017-0529-2
- Centore, P. (2022, 10 22). *sRGB Centroids for the ISCC-NBS Colour System*. The Munsell Colour System: <https://www.munsellcolourscienceforpainters.com/ColourSciencePapers/sRGBCentroidsForTheISCCNBSColourSystem.pdf> adresinden alındı
- Chen, X., Kundu, K., Zhu, Y., Ma, H., Fidler, S., & Urtasun, R. (2018, May). 3D Object Proposals Using Stereo Imagery for Accurate Object Class Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40, 1259–1272. doi:10.1109/tpami.2017.2706685
- Chen, X., Tian, G., Wu, J., Tang, C., & Li, K. (2019). Feature-Based Registration for 3D Eddy Current Pulsed Thermography. *IEEE Sensors Journal*, 19, 6998–7004. doi:10.1109/JSEN.2019.2911699
- Cook, B., & Cohen, K. (2017). Multi-source sensor fusion for small unmanned aircraft systems using fuzzy logic. *2017 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, (s. 1-6). doi:10.1109/FUZZ-IEEE.2017.8015593
- Correa, M., Hermosilla, G., Verschae, R., & del-Solar, J. R. (2011, July). Human Detection and Identification by Robots Using Thermal and Visual Information in Domestic Environments. *Journal of Intelligent & Robotic Systems*, 66, 223–243. doi:10.1007/s10846-011-9612-2
- Dai, B., He, Y., Yang, L., Su, Y., Yue, Y., & Xu, W. (2020). SIMSF: A Scale Insensitive Multi-Sensor Fusion Framework for Unmanned Aerial Vehicles Based on Graph Optimization. *IEEE Access*, 8, 118273–118284. doi:10.1109/ACCESS.2020.3000555
- Dieterle, T., Particke, F., Patino-Studencki, L., & Thielecke, J. (2017). Sensor data fusion of LIDAR with stereo RGB-D camera for object tracking. *2017 IEEE SENSORS*, (s. 1-3). doi:10.1109/ICSENS.2017.8234267
- Dobrev, Y., Flores, S., & Vossiek, M. (2016). Multi-modal sensor fusion for indoor mobile robot pose estimation. *2016 IEEE/ION Position, Location and Navigation Symposium (PLANS)*, (s. 553-556). doi:10.1109/PLANS.2016.7479745
- Dolinay, V., Pivnickova, L., & Vasek, V. (2014, May). Objectivization of traditional otoneurological examinations based on Kinect sensor Hautant\textquotesingles test based on Kinect. *Proceedings of the 2014 15th*

*International Carpathian Control Conference (ICCC)*. IEEE.  
doi:10.1109/carpathiancc.2014.6843575

- Dong, J., Ota, K., & Dong, M. (2021, December). UAV-Based Real-Time Survivor Detection System in Post-Disaster Search and Rescue Operations. *IEEE Journal on Miniaturization for Air and Space Systems*, 2, 209–219.  
doi:10.1109/jmass.2021.3083659
- Dutta, A., & Zisserman, A. (2019, October). The VIA Annotation Software for Images, Audio and Video. *Proceedings of the 27th ACM International Conference on Multimedia*. ACM. doi:10.1145/3343031.3350535
- Gehrig, S., Schneider, N., Stalder, R., & Franke, U. (2017, December). Stereo vision during adverse weather — Using priors to increase robustness in real-time stereo vision. *Image and Vision Computing*, 68, 28–39.  
doi:10.1016/j.imavis.2017.07.008
- George, A., & Marcel, S. (2020). Can Your Face Detector Do Anti-spoofing? Face Presentation Attack Detection with a Multi-Channel Face Detector. *Can Your Face Detector Do Anti-spoofing? Face Presentation Attack Detection with a Multi-Channel Face Detector*. arXiv. doi:10.48550/ARXIV.2006.16836
- Ghazali, K. H., & Jadin, M. S. (2014, March). Detection Improvised Explosive Device (IED) Emplacement Using Infrared Image. *2014 UKSim-AMSS 16th International Conference on Computer Modelling and Simulation*. IEEE.  
doi:10.1109/uksim.2014.111
- Gonçalves, V. P., Silva, L. P., Nunes, F. L., Ferreira, J. E., & Araújo, L. V. (2021). Evaluation of Traditional and Deep Learning Human Detection Techniques Applied to Surveillance: A Performance Comparison at Distinct Object Sizes. *2021 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)*, (s. 1-5).  
doi:10.1109/ICSPCC52875.2021.9564442
- González, A., Fang, Z., Socarras, Y., Serrat, J., Vázquez, D., Xu, J., & López, A. (2016, June). Pedestrian Detection at Day/Night Time with Visible and FIR Cameras: A Comparison. *Sensors*, 16, 820. doi:10.3390/s16060820
- Haider, A., Shaukat, F., & Mir, J. (2021, August). Human detection in aerial thermal imaging using a fully convolutional regression network. *Infrared Physics & Technology*, 116, 103796.  
doi:10.1016/j.infrared.2021.103796
- Han, D., & Huh, J. (2019). Thermal Data Fusion for Building Insulation. *2019 International Conference on System Science and Engineering (ICSSE)*, (s. 368-371). doi:10.1109/ICSSE.2019.8823350
- He, K., Gkioxari, G., Dollar, P., & Girshick, R. (2017, October). Mask R-CNN. *2017 IEEE International Conference on Computer Vision (ICCV)*. IEEE.  
doi:10.1109/iccv.2017.322

- Hwang, S., Park, J., Kim, N., Choi, Y., & So Kweon, I. (2015, June). Multispectral Pedestrian Detection: Benchmark Dataset and Baseline. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Jia, X., Zhu, C., Li, M., Tang, W., & Zhou, W. (2021, October). LLVIP: A Visible-Infrared Paired Dataset for Low-Light Vision. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) Workshops*, (s. 3496-3504).
- John, V., Tsuchizawa, S., Liu, Z., & Mita, S. (2016, October). Fusion of thermal and visible cameras for the application of pedestrian detection. *Signal, Image and Video Processing*, 11, 517–524. doi:10.1007/s11760-016-0989-z
- Kim, H., Lee, S., Ahn, E., Shin, M., & Sim, S.-H. (2020, July). Crack identification method for concrete structures considering angle of view using RGB-D camera-based sensor fusion. *Structural Health Monitoring*, 20, 500–512. doi:10.1177/1475921720934758
- Ko, B., Jeong, M., & Nam, J. (2014, November). Fast Human Detection for Intelligent Monitoring Using Surveillance Visible Sensors. *Sensors*, 14, 21247–21257. doi:10.3390/s141121247
- Kong, W., Hong, J., Jia, M., Yao, J., Cong, W., Hu, H., & Zhang, H. (2020). YOLOv3-DPFIN: A Dual-Path Feature Fusion Neural Network for Robust Real-Time Sonar Target Detection. *IEEE Sensors Journal*, 20, 3745-3756. doi:10.1109/JSEN.2019.2960796
- Kumar, K. S., Kavitha, G., Subramanian, R., & Ramesh, G. (2011). Visual and thermal image fusion for UAV based target tracking. *MATLAB-A Ubiquitous Tool for the Practical Engineer*, 307.
- Li, C., Wu, X., Zhao, N., Cao, X., & Tang, J. (2018, March). Fusing two-stream convolutional neural networks for RGB-T object tracking. *Neurocomputing*, 281, 78–85. doi:10.1016/j.neucom.2017.11.068
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., . . . Zitnick, C. L. (2014). Microsoft COCO: Common Objects in Context. *Computer Vision – ECCV 2014* (s. 740–755). içinde Springer International Publishing. doi:10.1007/978-3-319-10602-1\_48
- Liu, S., & Liu, Z. (2017). Multi-Channel CNN-based Object Detection for Enhanced Situation Awareness. *Multi-Channel CNN-based Object Detection for Enhanced Situation Awareness*. arXiv. doi:10.48550/ARXIV.1712.00075
- Liu, W., Hu, J., & Wang, W. (2020, July). A Novel Camera Fusion Method Based on Switching Scheme and Occlusion-Aware Object Detection for Real-Time Robotic Grasping. *Journal of Intelligent & Robotic Systems*, 100, 791–808. doi:10.1007/s10846-020-01236-7
- Masood, S., Sharif, M., Yasmin, M., Shahid, M. A., & Rehman, A. (2017). Image Fusion Methods: A Survey. *Journal of Engineering Science and Technology Review*, 10, 186–195. doi:10.25103/jestr.106.24

- Matía, F., & Jiménez, A. (1998). Multisensor fusion: an autonomous mobile robot. *Journal of Intelligent and robotic systems*, 22, 129–141.
- Nandi, G. C., & Mitra, D. (2001). Development of a sensor integration strategy for robotic application based on geometric optimization. *Sensor Fusion: Architectures, Algorithms, and Applications V*, 4385, s. 282–291.
- Palmero, C., Clapés, A., Bahnsen, C., Møgelmoose, A., Moeslund, T. B., & Escalera, S. (2016, April). Multi-modal RGB–Depth–Thermal Human Body Segmentation. *International Journal of Computer Vision*, 118, 217–239. doi:10.1007/s11263-016-0901-x
- Rahmaniar, W., & Hernawan, A. (2021). Real-Time Human Detection Using Deep Learning on Embedded Platforms: A Review. *Journal of Robotics and Control (JRC)*, 2. doi:10.18196/jrc.26123
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016, June). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE. doi:10.1109/cvpr.2016.91
- Saha, P., & Mukhopadhyay, S. (2020). Multispectral Information Fusion With Reinforcement Learning for Object Tracking in IoT Edge Devices. *IEEE Sensors Journal*, 20, 4333–4344. doi:10.1109/JSEN.2019.2962834
- Sankey, T., Donager, J., McVay, J., & Sankey, J. B. (2017, June). UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. *Remote Sensing of Environment*, 195, 30–43. doi:10.1016/j.rse.2017.04.007
- Schramm, S., Osterhold, P., Schmoll, R., & Kroll, A. (2021, October). Combining modern 3D reconstruction and thermal imaging: generation of large-scale 3D thermograms in real-time. *Quantitative InfraRed Thermography Journal*, 19, 295–311. doi:10.1080/17686733.2021.1991746
- Seek Thermal. (2022, 10 21). *Seek Thermal Compact Series*. Seek Thermal: <https://www.thermal.com/compact-series.html> adresinden alındı
- Sneha, M., Aravindakshan G, A., Sayi Varsha Vardini, S., Akshayaa Rajeshwari, D., Rathna Sastika V A, R., Selvi, J. T., & Sathiyarayanan, M. (2020, October). An Effective Drone Surveillance System Using Thermal Imaging. *2020 International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE)*. IEEE. doi:10.1109/icstcee49637.2020.9277292
- Takumi, K., Watanabe, K., Ha, Q., De-Pablos, A. T., Ushiku, Y., & Harada, T. (2017). Multispectral Object Detection for Autonomous Vehicles. *Proceedings of the on Thematic Workshops of ACM Multimedia 2017 - Thematic Workshops*. ACM Press. doi:10.1145/3126686.3126727
- Tippetts, B., Lee, D. J., Lillywhite, K., & Archibald, J. (2013, January). Review of stereo vision algorithms and their suitability for resource-limited systems.

*Journal of Real-Time Image Processing*, 11, 5–25. doi:10.1007/s11554-012-0313-2

- Treible, W., Saponaro, P., Sorensen, S., Kolagunda, A., O’Neal, M., Phelan, B., . . . Kambhamettu, C. (2017). CATS: A Color and Thermal Stereo Benchmark. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (s. 134-142). doi:10.1109/CVPR.2017.22
- Tzafestas, S. (2005, May). Sensor Integration and Fusion Techniques in Robotic Applications. *Journal of Intelligent and Robotic Systems*, 43, v–vi. doi:10.1007/s10846-005-8615-2
- Vidas, S., Moghadam, P., & Sridharan, S. (2015). Real-Time Mobile 3D Temperature Mapping. *IEEE Sensors Journal*, 15, 1145-1152. doi:10.1109/JSEN.2014.2360709
- waspinator. (2022, 10 22). *pycococreator*. Github: <https://github.com/waspinator/pycococreator> adresinden alındı
- Xi, Y. (2019). Improved Intelligent Water Droplet Navigation Method for Mobile Robot Based on Multi-sensor Fusion. *2019 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS)*, (s. 417-420). doi:10.1109/ICPICS47731.2019.8942562
- Xue, Y., Ju, Z., Li, Y., & Zhang, W. (2021, November). MAF-YOLO: Multi-modal attention fusion based YOLO for pedestrian detection. *Infrared Physics & Technology*, 118, 103906. doi:10.1016/j.infrared.2021.103906
- Yang, M.-D., Su, T.-C., & Lin, H.-Y. (2018, June). Fusion of Infrared Thermal Image and Visible Image for 3D Thermal Model Reconstruction Using Smartphone Sensors. *Sensors*, 18, 2003. doi:10.3390/s18072003
- Zhang, Q., Xiao, T., Huang, N., Zhang, D., & Han, J. (2021, May). Revisiting Feature Fusion for RGB-T Salient Object Detection. *IEEE Transactions on Circuits and Systems for Video Technology*, 31, 1804–1818. doi:10.1109/tcsvt.2020.3014663
- Zhang, X., Qiu, Z., Huang, P., Hu, J., & Luo, J. (2018, October). Application Research of YOLO v2 Combined with Color Identification. *2018 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery (CyberC)*. IEEE. doi:10.1109/cyberc.2018.00036
- Zhang, Y., Sidibé, D., Morel, O., & Mériaudeau, F. (2021, January). Deep multimodal fusion for semantic image segmentation: A survey. *Image and Vision Computing*, 105, 104042. doi:10.1016/j.imavis.2020.104042
- Zhang, Y., Wei, X., & Zhou, X. (2019). Dynamic obstacle avoidance based on multi-sensor fusion and Q-learning algorithm. *2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, (s. 1569-1573). doi:10.1109/ITNEC.2019.8729554

Zheng, R., Yang, R., Lu, K., & Zhang, S. (2019, November). A Search and Rescue System for Maritime Personnel in Disaster Carried on Unmanned Aerial Vehicle. *2019 18th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES)*. IEEE. doi:10.1109/dcabes48411.2019.00018



## EKLER

### Ek 1. Farklı Ortamlardaki Sınama Sonuçları

#### Algılama Laboratuvarı Sınama Sonuçları

|                       | AP    | TP  | FP | FN  | IoU  | Recall | Precision | F1   |
|-----------------------|-------|-----|----|-----|------|--------|-----------|------|
| <b>Derinlik</b>       | 18,17 | 5   | 0  | 194 | 0,62 | 0,05   | 0,03      | 1,00 |
| <b>Renkli</b>         | 85,74 | 161 | 51 | 38  | 0,59 | 0,78   | 0,81      | 0,76 |
| <b>Sıcaklık</b>       | 28,39 | 12  | 1  | 187 | 0,77 | 0,11   | 0,06      | 0,92 |
| <b>Sıcaklık (Gri)</b> | 81,31 | 127 | 6  | 72  | 0,77 | 0,77   | 0,64      | 0,95 |
| <b>RGBDT</b>          | 44,60 | 8   | 0  | 191 | 0,64 | 0,08   | 0,04      | 1,00 |
| <b>RGBDT (Gri)</b>    | 51,75 | 63  | 9  | 136 | 0,62 | 0,46   | 0,32      | 0,88 |
| <b>RGBT</b>           | 75,25 | 103 | 25 | 96  | 0,62 | 0,63   | 0,52      | 0,80 |
| <b>RGBT (Gri)</b>     | 82,40 | 151 | 61 | 48  | 0,57 | 0,73   | 0,76      | 0,71 |
| <b>T1R</b>            | 87,88 | 158 | 34 | 41  | 0,66 | 0,81   | 0,79      | 0,82 |
| <b>T1R (Gri)</b>      | 86,01 | 153 | 25 | 46  | 0,68 | 0,81   | 0,77      | 0,86 |
| <b>T2R</b>            | 87,45 | 151 | 55 | 48  | 0,57 | 0,75   | 0,76      | 0,73 |
| <b>T2R (Gri)</b>      | 85,07 | 155 | 50 | 44  | 0,59 | 0,77   | 0,78      | 0,76 |
| <b>T3R</b>            | 86,91 | 147 | 51 | 52  | 0,74 | 0,74   | 0,74      | 0,74 |
| <b>T3R (Gri)</b>      | 85,26 | 144 | 59 | 55  | 0,56 | 0,72   | 0,72      | 0,71 |
| <b>T4R</b>            | 85,70 | 142 | 52 | 57  | 0,57 | 0,72   | 0,71      | 0,73 |
| <b>T4R (Gri)</b>      | 82,88 | 141 | 58 | 58  | 0,56 | 0,71   | 0,71      | 0,71 |
| <b>T5R</b>            | 84,02 | 137 | 51 | 62  | 0,57 | 0,71   | 0,69      | 0,73 |
| <b>T5R (Gri)</b>      | 82,59 | 138 | 60 | 61  | 0,55 | 0,70   | 0,69      | 0,70 |
| <b>T6R</b>            | 81,88 | 132 | 49 | 67  | 0,57 | 0,69   | 0,66      | 0,73 |
| <b>T6R (Gri)</b>      | 82,60 | 143 | 57 | 56  | 0,57 | 0,72   | 0,72      | 0,72 |
| <b>T7R</b>            | 78,29 | 118 | 38 | 81  | 0,59 | 0,66   | 0,59      | 0,76 |
| <b>T7R (Gri)</b>      | 82,38 | 146 | 53 | 53  | 0,58 | 0,73   | 0,73      | 0,73 |
| <b>T8R</b>            | 76,20 | 111 | 31 | 88  | 0,60 | 0,65   | 0,56      | 0,78 |
| <b>T8R (Gri)</b>      | 82,60 | 149 | 56 | 50  | 0,58 | 0,74   | 0,75      | 0,73 |
| <b>T9R</b>            | 72,81 | 92  | 26 | 107 | 0,61 | 0,58   | 0,46      | 0,78 |
| <b>T9R (Gri)</b>      | 81,24 | 147 | 52 | 52  | 0,59 | 0,74   | 0,74      | 0,74 |

### Gazino Sınama Sonuçları

|                       | AP    | TP  | FP  | FN  | IoU  | Recall | Precision | F1   |
|-----------------------|-------|-----|-----|-----|------|--------|-----------|------|
| <b>Derinlik</b>       | 0,61  | 0   | 0   | 450 | 0    | -      | 0,00      | -    |
| <b>Renkli</b>         | 93,74 | 397 | 91  | 53  | 0,65 | 0,85   | 0,88      | 0,81 |
| <b>Sıcaklık</b>       | 45,45 | 88  | 6   | 362 | 0,77 | 0,32   | 0,20      | 0,94 |
| <b>Sıcaklık (Gri)</b> | 67,82 | 179 | 23  | 271 | 0,70 | 0,55   | 0,40      | 0,89 |
| <b>RGBDT</b>          | 48,49 | 71  | 4   | 379 | 0,79 | 0,27   | 0,16      | 0,95 |
| <b>RGBDT (Gri)</b>    | 60,48 | 157 | 16  | 293 | 0,75 | 0,50   | 0,35      | 0,91 |
| <b>RGBT</b>           | 86,06 | 293 | 40  | 157 | 0,70 | 0,75   | 0,65      | 0,88 |
| <b>RGBT (Gri)</b>     | 91,27 | 367 | 48  | 83  | 0,71 | 0,85   | 0,82      | 0,88 |
| <b>T1R</b>            | 90,54 | 327 | 37  | 123 | 0,71 | 0,80   | 0,73      | 0,90 |
| <b>T1R (Gri)</b>      | 90,72 | 334 | 56  | 116 | 0,69 | 0,80   | 0,74      | 0,86 |
| <b>T2R</b>            | 92,52 | 397 | 83  | 53  | 0,66 | 0,85   | 0,88      | 0,83 |
| <b>T2R (Gri)</b>      | 93,39 | 397 | 71  | 53  | 0,68 | 0,86   | 0,88      | 0,85 |
| <b>T3R</b>            | 92,18 | 394 | 66  | 56  | 0,69 | 0,87   | 0,88      | 0,86 |
| <b>T3R (Gri)</b>      | 93,30 | 394 | 65  | 56  | 0,69 | 0,87   | 0,88      | 0,86 |
| <b>T4R</b>            | 92,89 | 390 | 61  | 60  | 0,69 | 0,87   | 0,87      | 0,86 |
| <b>T4R (Gri)</b>      | 92,99 | 394 | 55  | 56  | 0,70 | 0,88   | 0,88      | 0,88 |
| <b>T5R</b>            | 93,36 | 383 | 49  | 67  | 0,71 | 0,87   | 0,85      | 0,89 |
| <b>T5R (Gri)</b>      | 92,82 | 390 | 60  | 60  | 0,69 | 0,87   | 0,87      | 0,87 |
| <b>T6R</b>            | 93,35 | 375 | 44  | 75  | 0,72 | 0,86   | 0,83      | 0,89 |
| <b>T6R (Gri)</b>      | 92,74 | 383 | 59  | 67  | 0,70 | 0,86   | 0,85      | 0,87 |
| <b>T7R</b>            | 91,74 | 353 | 43  | 97  | 0,71 | 0,83   | 0,78      | 0,89 |
| <b>T7R (Gri)</b>      | 93,03 | 382 | 54  | 68  | 0,70 | 0,86   | 0,85      | 0,88 |
| <b>T8R</b>            | 89,26 | 327 | 39  | 123 | 0,71 | 0,80   | 0,73      | 0,89 |
| <b>T8R (Gri)</b>      | 92,57 | 380 | 490 | 70  | 0,71 | 0,58   | 0,84      | 0,44 |
| <b>T9R</b>            | 83,72 | 265 | 45  | 185 | 0,68 | 0,70   | 0,59      | 0,85 |
| <b>T9R (Gri)</b>      | 91,15 | 360 | 41  | 90  | 0,72 | 0,85   | 0,80      | 0,90 |

### Kamelya Sınama Sonuçları

|                       | AP    | TP  | FP  | FN  | IoU  | Recall | Precision | F1   |
|-----------------------|-------|-----|-----|-----|------|--------|-----------|------|
| <b>Derinlik</b>       | 0,03  | 0   | 0   | 720 | 0    | -      | 0,00      | -    |
| <b>Renkli</b>         | 92,98 | 644 | 133 | 76  | 0,66 | 0,86   | 0,89      | 0,83 |
| <b>Sıcaklık</b>       | 58,18 | 269 | 12  | 451 | 0,80 | 0,54   | 0,37      | 0,96 |
| <b>Sıcaklık (Gri)</b> | 74,99 | 402 | 44  | 318 | 0,74 | 0,69   | 0,56      | 0,90 |
| <b>RGBDT</b>          | 68,06 | 316 | 27  | 404 | 0,75 | 0,59   | 0,44      | 0,92 |
| <b>RGBDT (Gri)</b>    | 80,64 | 467 | 54  | 253 | 0,73 | 0,75   | 0,65      | 0,90 |
| <b>RGBT</b>           | 83,55 | 515 | 59  | 205 | 0,73 | 0,80   | 0,72      | 0,90 |
| <b>RGBT (Gri)</b>     | 87,53 | 573 | 83  | 147 | 0,70 | 0,83   | 0,80      | 0,87 |
| <b>T1R</b>            | 86,57 | 533 | 63  | 187 | 0,73 | 0,81   | 0,74      | 0,89 |
| <b>T1R (Gri)</b>      | 84,10 | 515 | 64  | 205 | 0,73 | 0,79   | 0,72      | 0,89 |
| <b>T2R</b>            | 90,74 | 622 | 112 | 98  | 0,68 | 0,86   | 0,86      | 0,85 |
| <b>T2R (Gri)</b>      | 89,52 | 606 | 105 | 114 | 0,68 | 0,85   | 0,84      | 0,85 |
| <b>T3R</b>            | 88,80 | 599 | 90  | 121 | 0,70 | 0,85   | 0,83      | 0,87 |
| <b>T3R (Gri)</b>      | 88,66 | 600 | 97  | 120 | 0,69 | 0,85   | 0,83      | 0,86 |
| <b>T4R</b>            | 87,59 | 590 | 83  | 130 | 0,71 | 0,85   | 0,82      | 0,88 |
| <b>T4R (Gri)</b>      | 88,15 | 595 | 95  | 125 | 0,69 | 0,84   | 0,83      | 0,86 |
| <b>T5R</b>            | 86,80 | 572 | 79  | 148 | 0,71 | 0,83   | 0,79      | 0,88 |
| <b>T5R (Gri)</b>      | 88,04 | 600 | 93  | 120 | 0,69 | 0,85   | 0,83      | 0,87 |
| <b>T6R</b>            | 86,40 | 567 | 74  | 153 | 0,72 | 0,83   | 0,79      | 0,88 |
| <b>T6R (Gri)</b>      | 87,97 | 590 | 89  | 130 | 0,70 | 0,84   | 0,82      | 0,87 |
| <b>T7R</b>            | 86,24 | 558 | 70  | 162 | 0,72 | 0,83   | 0,78      | 0,89 |
| <b>T7R (Gri)</b>      | 87,95 | 583 | 93  | 137 | 0,69 | 0,84   | 0,81      | 0,86 |
| <b>T8R</b>            | 85,29 | 542 | 62  | 178 | 0,73 | 0,82   | 0,75      | 0,90 |
| <b>T8R (Gri)</b>      | 87,72 | 579 | 90  | 141 | 0,70 | 0,83   | 0,80      | 0,87 |
| <b>T9R</b>            | 82,57 | 491 | 51  | 229 | 0,74 | 0,78   | 0,68      | 0,91 |
| <b>T9R (Gri)</b>      | 86,9  | 564 | 88  | 156 | 0,69 | 0,82   | 0,78      | 0,87 |

### Koridor 1 Sınama Sonuçları

|                       | AP    | TP  | FP | FN  | IoU  | Recall | Precision | F1   |
|-----------------------|-------|-----|----|-----|------|--------|-----------|------|
| <b>Derinlik</b>       | 10,34 | 17  | 8  | 404 | 0,43 | 0,08   | 0,04      | 0,68 |
| <b>Renkli</b>         | 65,77 | 258 | 33 | 163 | 0,70 | 0,72   | 0,61      | 0,89 |
| <b>Sıcaklık</b>       | 22,07 | 38  | 12 | 383 | 0,60 | 0,16   | 0,09      | 0,76 |
| <b>Sıcaklık (Gri)</b> | 45,48 | 129 | 43 | 292 | 0,54 | 0,44   | 0,31      | 0,75 |
| <b>RGBDT</b>          | 7,59  | 4   | 0  | 417 | 0,64 | 0,02   | 0,01      | 1,00 |
| <b>RGBDT (Gri)</b>    | 23,95 | 58  | 32 | 363 | 0,44 | 0,23   | 0,14      | 0,64 |
| <b>RGBT</b>           | 67,35 | 205 | 55 | 216 | 0,61 | 0,60   | 0,49      | 0,79 |
| <b>RGBT (Gri)</b>     | 86,84 | 326 | 67 | 95  | 0,64 | 0,80   | 0,77      | 0,83 |
| <b>T1R</b>            | 74,85 | 233 | 44 | 188 | 0,66 | 0,67   | 0,55      | 0,84 |
| <b>T1R (Gri)</b>      | 68,29 | 187 | 48 | 234 | 0,60 | 0,57   | 0,44      | 0,80 |
| <b>T2R</b>            | 78,46 | 275 | 31 | 146 | 0,71 | 0,76   | 0,65      | 0,90 |
| <b>T2R (Gri)</b>      | 83,51 | 305 | 31 | 116 | 0,72 | 0,81   | 0,72      | 0,91 |
| <b>T3R</b>            | 77,25 | 266 | 30 | 155 | 0,71 | 0,74   | 0,63      | 0,90 |
| <b>T3R (Gri)</b>      | 87,25 | 325 | 38 | 96  | 0,71 | 0,83   | 0,77      | 0,90 |
| <b>T4R</b>            | 76,60 | 243 | 46 | 178 | 0,67 | 0,68   | 0,58      | 0,84 |
| <b>T4R (Gri)</b>      | 88,36 | 337 | 49 | 84  | 0,69 | 0,84   | 0,80      | 0,87 |
| <b>T5R</b>            | 74,80 | 251 | 51 | 170 | 0,66 | 0,69   | 0,60      | 0,83 |
| <b>T5R (Gri)</b>      | 88,30 | 337 | 56 | 87  | 0,67 | 0,82   | 0,79      | 0,86 |
| <b>T6R</b>            | 73,58 | 243 | 55 | 178 | 0,64 | 0,68   | 0,58      | 0,82 |
| <b>T6R (Gri)</b>      | 88,58 | 335 | 59 | 86  | 0,67 | 0,82   | 0,80      | 0,85 |
| <b>T7R</b>            | 70,94 | 231 | 51 | 190 | 0,64 | 0,66   | 0,55      | 0,82 |
| <b>T7R (Gri)</b>      | 87,72 | 329 | 65 | 92  | 0,65 | 0,81   | 0,78      | 0,84 |
| <b>T8R</b>            | 70,14 | 231 | 44 | 190 | 0,65 | 0,66   | 0,55      | 0,84 |
| <b>T8R (Gri)</b>      | 87,32 | 326 | 68 | 95  | 0,64 | 0,80   | 0,77      | 0,83 |
| <b>T9R</b>            | 63,87 | 184 | 53 | 237 | 0,59 | 0,56   | 0,44      | 0,78 |
| <b>T9R (Gri)</b>      | 85,69 | 315 | 63 | 106 | 0,65 | 0,79   | 0,75      | 0,83 |

### Koridor 2 Sınama Sonuçları

|                       | AP    | TP  | FP | FN  | IoU  | Recall | Precision | F1   |
|-----------------------|-------|-----|----|-----|------|--------|-----------|------|
| <b>Derinlik</b>       | 19,09 | 27  | 5  | 287 | 0,62 | 0,16   | 0,09      | 0,84 |
| <b>Renkli</b>         | 35,70 | 101 | 6  | 213 | 0,81 | 0,48   | 0,32      | 0,94 |
| <b>Sıcaklık</b>       | 64,19 | 113 | 10 | 201 | 0,80 | 0,52   | 0,36      | 0,92 |
| <b>Sıcaklık (Gri)</b> | 83,74 | 217 | 9  | 97  | 0,83 | 0,80   | 0,69      | 0,96 |
| <b>RGBDT</b>          | 40,90 | 50  | 4  | 264 | 0,77 | 0,27   | 0,16      | 0,93 |
| <b>RGBDT (Gri)</b>    | 64,36 | 158 | 19 | 156 | 0,75 | 0,64   | 0,50      | 0,89 |
| <b>RGBT</b>           | 72,26 | 140 | 7  | 174 | 0,82 | 0,61   | 0,45      | 0,95 |
| <b>RGBT (Gri)</b>     | 88,78 | 243 | 10 | 71  | 0,82 | 0,86   | 0,77      | 0,96 |
| <b>T1R</b>            | 88,74 | 231 | 9  | 83  | 0,83 | 0,83   | 0,74      | 0,96 |
| <b>T1R (Gri)</b>      | 87,96 | 231 | 9  | 83  | 0,83 | 0,83   | 0,74      | 0,96 |
| <b>T2R</b>            | 81,40 | 176 | 11 | 138 | 0,81 | 0,70   | 0,56      | 0,94 |
| <b>T2R (Gri)</b>      | 85,43 | 206 | 16 | 108 | 0,80 | 0,77   | 0,66      | 0,93 |
| <b>T3R</b>            | 76,17 | 164 | 7  | 150 | 0,83 | 0,68   | 0,52      | 0,96 |
| <b>T3R (Gri)</b>      | 89,07 | 236 | 13 | 78  | 0,82 | 0,84   | 0,75      | 0,95 |
| <b>T4R</b>            | 74,42 | 152 | 5  | 162 | 0,84 | 0,65   | 0,48      | 0,97 |
| <b>T4R (Gri)</b>      | 90,07 | 245 | 11 | 69  | 0,82 | 0,86   | 0,78      | 0,96 |
| <b>T5R</b>            | 72,99 | 150 | 7  | 164 | 0,83 | 0,64   | 0,48      | 0,96 |
| <b>T5R (Gri)</b>      | 90,32 | 246 | 9  | 68  | 0,83 | 0,86   | 0,78      | 0,96 |
| <b>T6R</b>            | 72,25 | 146 | 7  | 168 | 0,83 | 0,63   | 0,46      | 0,95 |
| <b>T6R (Gri)</b>      | 90,44 | 249 | 10 | 65  | 0,82 | 0,87   | 0,79      | 0,96 |
| <b>T7R</b>            | 72,67 | 149 | 8  | 165 | 0,82 | 0,63   | 0,47      | 0,95 |
| <b>T7R (Gri)</b>      | 89,81 | 250 | 12 | 64  | 0,82 | 0,87   | 0,80      | 0,95 |
| <b>T8R</b>            | 72,24 | 148 | 7  | 166 | 0,82 | 0,63   | 0,47      | 0,95 |
| <b>T8R (Gri)</b>      | 89,22 | 249 | 10 | 65  | 0,82 | 0,87   | 0,79      | 0,96 |
| <b>T9R</b>            | 71,77 | 143 | 5  | 171 | 0,83 | 0,62   | 0,46      | 0,97 |
| <b>T9R (Gri)</b>      | 88,18 | 241 | 10 | 73  | 0,82 | 0,85   | 0,77      | 0,96 |

### İHA Laboratuvarı 1 Sınama Sonuçları

|                       | AP    | TP  | FP  | FN  | IoU  | Recall | Precision | F1   |
|-----------------------|-------|-----|-----|-----|------|--------|-----------|------|
| <b>Derinlik</b>       | 5,71  | 5   | 2   | 576 | 0,53 | 0,02   | 0,01      | 0,71 |
| <b>Renkli</b>         | 93,55 | 518 | 114 | 63  | 0,68 | 0,85   | 0,89      | 0,82 |
| <b>Sıcaklık</b>       | 49,16 | 166 | 14  | 415 | 0,77 | 0,44   | 0,29      | 0,92 |
| <b>Sıcaklık (Gri)</b> | 73,18 | 308 | 39  | 273 | 0,71 | 0,66   | 0,53      | 0,89 |
| <b>RGBDT</b>          | 30,78 | 46  | 2   | 535 | 0,75 | 0,15   | 0,08      | 0,96 |
| <b>RGBDT (Gri)</b>    | 41,31 | 140 | 20  | 441 | 0,70 | 0,38   | 0,24      | 0,88 |
| <b>RGBT</b>           | 77,50 | 338 | 46  | 243 | 0,75 | 0,70   | 0,58      | 0,88 |
| <b>RGBT (Gri)</b>     | 87,34 | 454 | 64  | 127 | 0,74 | 0,83   | 0,78      | 0,88 |
| <b>T1R</b>            | 87,45 | 442 | 50  | 139 | 0,75 | 0,82   | 0,76      | 0,90 |
| <b>T1R (Gri)</b>      | 81,53 | 359 | 38  | 222 | 0,75 | 0,73   | 0,62      | 0,90 |
| <b>T2R</b>            | 92,77 | 507 | 101 | 74  | 0,70 | 0,85   | 0,87      | 0,83 |
| <b>T2R (Gri)</b>      | 91,61 | 502 | 89  | 79  | 0,70 | 0,86   | 0,86      | 0,85 |
| <b>T3R</b>            | 91,01 | 486 | 85  | 95  | 0,71 | 0,84   | 0,84      | 0,85 |
| <b>T3R (Gri)</b>      | 90,89 | 491 | 56  | 90  | 0,71 | 0,87   | 0,85      | 0,90 |
| <b>T4R</b>            | 89,30 | 470 | 73  | 111 | 0,72 | 0,84   | 0,81      | 0,87 |
| <b>T4R (Gri)</b>      | 90,35 | 486 | 86  | 95  | 0,71 | 0,84   | 0,84      | 0,85 |
| <b>T5R</b>            | 87,82 | 456 | 63  | 125 | 0,74 | 0,83   | 0,78      | 0,88 |
| <b>T5R (Gri)</b>      | 90,28 | 478 | 84  | 103 | 0,71 | 0,84   | 0,82      | 0,85 |
| <b>T6R</b>            | 85,89 | 431 | 62  | 150 | 0,74 | 0,80   | 0,74      | 0,87 |
| <b>T6R (Gri)</b>      | 88,95 | 475 | 80  | 106 | 0,72 | 0,84   | 0,82      | 0,86 |
| <b>T7R</b>            | 83,69 | 400 | 57  | 181 | 0,74 | 0,77   | 0,69      | 0,88 |
| <b>T7R (Gri)</b>      | 88,42 | 470 | 72  | 111 | 0,72 | 0,84   | 0,81      | 0,87 |
| <b>T8R</b>            | 81,11 | 373 | 47  | 208 | 0,75 | 0,75   | 0,64      | 0,89 |
| <b>T8R (Gri)</b>      | 87,10 | 459 | 70  | 122 | 0,72 | 0,83   | 0,79      | 0,87 |
| <b>T9R</b>            | 75,03 | 316 | 32  | 265 | 0,77 | 0,68   | 0,54      | 0,91 |
| <b>T9R (Gri)</b>      | 86,91 | 451 | 60  | 130 | 0,74 | 0,83   | 0,78      | 0,88 |

### İHA Laboratuvarı 2 Sınama Sonuçları

|                       | AP    | TP  | FP  | FN  | IoU  | Recall | Precision | F1   |
|-----------------------|-------|-----|-----|-----|------|--------|-----------|------|
| <b>Derinlik</b>       | 5,74  | 12  | 15  | 610 | 0,30 | 0,04   | 0,02      | 0,44 |
| <b>Renkli</b>         | 80,18 | 449 | 172 | 173 | 0,58 | 0,72   | 0,72      | 0,72 |
| <b>Sıcaklık</b>       | 27,65 | 72  | 1   | 550 | 0,80 | 0,21   | 0,12      | 0,99 |
| <b>Sıcaklık (Gri)</b> | 57,58 | 200 | 19  | 422 | 0,71 | 0,48   | 0,32      | 0,91 |
| <b>RGBDT</b>          | 17,77 | 24  | 11  | 598 | 0,50 | 0,07   | 0,04      | 0,69 |
| <b>RGBDT (Gri)</b>    | 28,31 | 97  | 40  | 525 | 0,53 | 0,26   | 0,16      | 0,71 |
| <b>RGBT</b>           | 64,72 | 319 | 61  | 303 | 0,69 | 0,64   | 0,51      | 0,84 |
| <b>RGBT (Gri)</b>     | 78,06 | 424 | 83  | 198 | 0,68 | 0,75   | 0,68      | 0,84 |
| <b>T1R</b>            | 80,59 | 409 | 90  | 213 | 0,65 | 0,73   | 0,66      | 0,82 |
| <b>T1R (Gri)</b>      | 74,83 | 349 | 54  | 273 | 0,69 | 0,68   | 0,56      | 0,87 |
| <b>T2R</b>            | 78,19 | 421 | 150 | 201 | 0,60 | 0,71   | 0,68      | 0,74 |
| <b>T2R (Gri)</b>      | 83,38 | 472 | 137 | 150 | 0,62 | 0,77   | 0,76      | 0,78 |
| <b>T3R</b>            | 74,50 | 397 | 130 | 225 | 0,62 | 0,69   | 0,64      | 0,75 |
| <b>T3R (Gri)</b>      | 81,99 | 458 | 142 | 164 | 0,62 | 0,75   | 0,74      | 0,76 |
| <b>T4R</b>            | 71,63 | 384 | 122 | 238 | 0,63 | 0,68   | 0,62      | 0,76 |
| <b>T4R (Gri)</b>      | 80,40 | 453 | 129 | 169 | 0,63 | 0,75   | 0,73      | 0,78 |
| <b>T5R</b>            | 70,25 | 372 | 103 | 250 | 0,65 | 0,68   | 0,60      | 0,78 |
| <b>T5R (Gri)</b>      | 79,09 | 448 | 114 | 174 | 0,64 | 0,76   | 0,72      | 0,80 |
| <b>T6R</b>            | 69,94 | 366 | 86  | 256 | 0,66 | 0,68   | 0,59      | 0,81 |
| <b>T6R (Gri)</b>      | 77,79 | 440 | 110 | 182 | 0,65 | 0,75   | 0,71      | 0,80 |
| <b>T7R</b>            | 68,55 | 361 | 72  | 261 | 0,68 | 0,68   | 0,58      | 0,83 |
| <b>T7R (Gri)</b>      | 76,85 | 433 | 100 | 189 | 0,66 | 0,75   | 0,70      | 0,81 |
| <b>T8R</b>            | 66,69 | 346 | 63  | 276 | 0,69 | 0,67   | 0,56      | 0,85 |
| <b>T8R (Gri)</b>      | 77,62 | 434 | 93  | 188 | 0,66 | 0,76   | 0,70      | 0,82 |
| <b>T9R</b>            | 63,29 | 293 | 52  | 329 | 0,69 | 0,61   | 0,47      | 0,85 |
| <b>T9R (Gri)</b>      | 78,67 | 425 | 81  | 197 | 0,68 | 0,75   | 0,68      | 0,84 |

**Çalışma Odası Sınama Sonuçları**

|                       | <b>AP</b> | <b>TP</b> | <b>FP</b> | <b>FN</b> | <b>IoU</b> | <b>Recall</b> | <b>Precision</b> | <b>F1</b> |
|-----------------------|-----------|-----------|-----------|-----------|------------|---------------|------------------|-----------|
| <b>Derinlik</b>       | 5,90      | 2         | 1         | 347       | 0,55       | 0,01          | 0,01             | 0,67      |
| <b>Renkli</b>         | 84,11     | 292       | 88        | 57        | 0,62       | 0,80          | 0,84             | 0,77      |
| <b>Sıcaklık</b>       | 50,53     | 98        | 14        | 251       | 0,72       | 0,43          | 0,28             | 0,88      |
| <b>Sıcaklık (Gri)</b> | 70,80     | 189       | 37        | 160       | 0,66       | 0,66          | 0,54             | 0,84      |
| <b>RGBDT</b>          | 34,18     | 15        | 3         | 334       | 0,67       | 0,08          | 0,04             | 0,83      |
| <b>RGBDT (Gri)</b>    | 54,94     | 117       | 12        | 232       | 0,72       | 0,49          | 0,34             | 0,91      |
| <b>RGBT</b>           | 72,18     | 213       | 37        | 136       | 0,71       | 0,71          | 0,61             | 0,85      |
| <b>RGBT (Gri)</b>     | 84,65     | 272       | 59        | 77        | 0,68       | 0,80          | 0,78             | 0,82      |
| <b>T1R</b>            | 86,56     | 243       | 37        | 106       | 0,72       | 0,77          | 0,70             | 0,87      |
| <b>T1R (Gri)</b>      | 85,99     | 242       | 23        | 107       | 0,75       | 0,79          | 0,69             | 0,91      |
| <b>T2R</b>            | 84,50     | 293       | 81        | 56        | 0,63       | 0,81          | 0,84             | 0,78      |
| <b>T2R (Gri)</b>      | 86,75     | 299       | 71        | 50        | 0,65       | 0,83          | 0,86             | 0,81      |
| <b>T3R</b>            | 84,54     | 293       | 71        | 56        | 0,65       | 0,82          | 0,84             | 0,80      |
| <b>T3R (Gri)</b>      | 86,96     | 296       | 71        | 53        | 0,66       | 0,83          | 0,85             | 0,81      |
| <b>T4R</b>            | 84,43     | 278       | 70        | 71        | 0,65       | 0,80          | 0,80             | 0,80      |
| <b>T4R (Gri)</b>      | 87,47     | 294       | 68        | 55        | 0,66       | 0,83          | 0,84             | 0,81      |
| <b>T5R</b>            | 84,40     | 277       | 56        | 72        | 0,68       | 0,81          | 0,79             | 0,83      |
| <b>T5R (Gri)</b>      | 87,51     | 294       | 62        | 55        | 0,67       | 0,83          | 0,84             | 0,83      |
| <b>T6R</b>            | 81,79     | 261       | 49        | 88        | 0,69       | 0,79          | 0,75             | 0,84      |
| <b>T6R (Gri)</b>      | 87,20     | 286       | 59        | 63        | 0,68       | 0,82          | 0,82             | 0,83      |
| <b>T7R</b>            | 77,71     | 244       | 45        | 105       | 0,70       | 0,76          | 0,70             | 0,84      |
| <b>T7R (Gri)</b>      | 86,60     | 282       | 58        | 67        | 0,68       | 0,82          | 0,81             | 0,83      |
| <b>T8R</b>            | 74,22     | 227       | 41        | 122       | 0,70       | 0,74          | 0,65             | 0,85      |
| <b>T8R (Gri)</b>      | 85,95     | 280       | 59        | 69        | 0,68       | 0,81          | 0,80             | 0,83      |
| <b>T9R</b>            | 69,75     | 197       | 31        | 152       | 0,72       | 0,68          | 0,56             | 0,86      |
| <b>T9R (Gri)</b>      | 83,90     | 270       | 53        | 79        | 0,69       | 0,80          | 0,77             | 0,84      |

**Sınıf 1 Sınama Sonuçları**

|                       | <b>AP</b> | <b>TP</b> | <b>FP</b> | <b>FN</b> | <b>IoU</b> | <b>Recall</b> | <b>Precision</b> | <b>F1</b> |
|-----------------------|-----------|-----------|-----------|-----------|------------|---------------|------------------|-----------|
| <b>Derinlik</b>       | 3,93      | 26        | 20        | 979       | 0,35       | 0,05          | 0,03             | 0,57      |
| <b>Renkli</b>         | 85,48     | 896       | 216       | 109       | 0,58       | 0,85          | 0,89             | 0,81      |
| <b>Sıcaklık</b>       | 31,11     | 202       | 62        | 803       | 0,49       | 0,32          | 0,20             | 0,77      |
| <b>Sıcaklık (Gri)</b> | 56,86     | 446       | 169       | 559       | 0,47       | 0,55          | 0,44             | 0,73      |
| <b>RGBDT</b>          | 54,12     | 347       | 61        | 658       | 0,55       | 0,49          | 0,35             | 0,85      |
| <b>RGBDT (Gri)</b>    | 61,82     | 457       | 141       | 548       | 0,50       | 0,57          | 0,45             | 0,76      |
| <b>RGBT</b>           | 72,91     | 609       | 102       | 396       | 0,60       | 0,71          | 0,61             | 0,86      |
| <b>RGBT (Gri)</b>     | 83,45     | 839       | 141       | 166       | 0,61       | 0,85          | 0,83             | 0,86      |
| <b>T1R</b>            | 79,23     | 750       | 149       | 255       | 0,58       | 0,79          | 0,75             | 0,83      |
| <b>T1R (Gri)</b>      | 80,67     | 776       | 112       | 229       | 0,62       | 0,82          | 0,77             | 0,87      |
| <b>T2R</b>            | 86,31     | 903       | 206       | 102       | 0,58       | 0,85          | 0,90             | 0,81      |
| <b>T2R (Gri)</b>      | 85,47     | 902       | 205       | 103       | 0,59       | 0,85          | 0,90             | 0,81      |
| <b>T3R</b>            | 84,99     | 885       | 197       | 120       | 0,59       | 0,85          | 0,88             | 0,82      |
| <b>T3R (Gri)</b>      | 85,01     | 896       | 197       | 109       | 0,59       | 0,85          | 0,89             | 0,82      |
| <b>T4R</b>            | 83,78     | 862       | 192       | 143       | 0,59       | 0,84          | 0,86             | 0,82      |
| <b>T4R (Gri)</b>      | 84,99     | 888       | 191       | 117       | 0,59       | 0,85          | 0,88             | 0,82      |
| <b>T5R</b>            | 83,74     | 840       | 176       | 165       | 0,59       | 0,83          | 0,84             | 0,83      |
| <b>T5R (Gri)</b>      | 85,05     | 880       | 184       | 125       | 0,59       | 0,85          | 0,88             | 0,83      |
| <b>T6R</b>            | 82,45     | 813       | 174       | 192       | 0,59       | 0,82          | 0,81             | 0,82      |
| <b>T6R (Gri)</b>      | 85,19     | 872       | 177       | 133       | 0,59       | 0,85          | 0,87             | 0,83      |
| <b>T7R</b>            | 81,65     | 788       | 139       | 217       | 0,61       | 0,82          | 0,78             | 0,85      |
| <b>T7R (Gri)</b>      | 84,35     | 856       | 168       | 149       | 0,60       | 0,84          | 0,85             | 0,84      |
| <b>T8R</b>            | 78,43     | 714       | 131       | 291       | 0,60       | 0,77          | 0,71             | 0,84      |
| <b>T8R (Gri)</b>      | 83,81     | 842       | 162       | 163       | 0,60       | 0,84          | 0,84             | 0,84      |
| <b>T9R</b>            | 67,73     | 530       | 94        | 475       | 0,60       | 0,65          | 0,53             | 0,85      |
| <b>T9R (Gri)</b>      | 83,21     | 828       | 140       | 177       | 0,61       | 0,84          | 0,82             | 0,86      |

**Sınıf 2 Sınama Sonuçları**

|                       | <b>AP</b> | <b>TP</b> | <b>FP</b> | <b>FN</b> | <b>IoU</b> | <b>Recall</b> | <b>Precision</b> | <b>F1</b> |
|-----------------------|-----------|-----------|-----------|-----------|------------|---------------|------------------|-----------|
| <b>Derinlik</b>       | 3,93      | 26        | 20        | 979       | 0,35       | 0,05          | 0,03             | 0,57      |
| <b>Renkli</b>         | 85,48     | 896       | 216       | 109       | 0,58       | 0,85          | 0,89             | 0,81      |
| <b>Sıcaklık</b>       | 31,11     | 202       | 62        | 803       | 0,49       | 0,32          | 0,20             | 0,77      |
| <b>Sıcaklık (Gri)</b> | 56,86     | 446       | 169       | 559       | 0,47       | 0,55          | 0,44             | 0,73      |
| <b>RGBDT</b>          | 54,12     | 347       | 61        | 658       | 0,55       | 0,49          | 0,35             | 0,85      |
| <b>RGBDT (Gri)</b>    | 61,82     | 457       | 141       | 548       | 0,50       | 0,57          | 0,45             | 0,76      |
| <b>RGBT</b>           | 72,91     | 609       | 102       | 396       | 0,60       | 0,71          | 0,61             | 0,86      |
| <b>RGBT (Gri)</b>     | 83,45     | 839       | 141       | 166       | 0,61       | 0,85          | 0,83             | 0,86      |
| <b>T1R</b>            | 79,23     | 750       | 149       | 255       | 0,58       | 0,79          | 0,75             | 0,83      |
| <b>T1R (Gri)</b>      | 80,67     | 776       | 112       | 229       | 0,62       | 0,82          | 0,77             | 0,87      |
| <b>T2R</b>            | 86,31     | 903       | 206       | 102       | 0,58       | 0,85          | 0,90             | 0,81      |
| <b>T2R (Gri)</b>      | 85,47     | 902       | 205       | 103       | 0,59       | 0,85          | 0,90             | 0,81      |
| <b>T3R</b>            | 84,99     | 885       | 197       | 120       | 0,59       | 0,85          | 0,88             | 0,82      |
| <b>T3R (Gri)</b>      | 85,01     | 896       | 197       | 109       | 0,59       | 0,85          | 0,89             | 0,82      |
| <b>T4R</b>            | 83,78     | 862       | 192       | 143       | 0,59       | 0,84          | 0,86             | 0,82      |
| <b>T4R (Gri)</b>      | 84,99     | 888       | 191       | 117       | 0,59       | 0,85          | 0,88             | 0,82      |
| <b>T5R</b>            | 83,74     | 840       | 176       | 165       | 0,59       | 0,83          | 0,84             | 0,83      |
| <b>T5R (Gri)</b>      | 85,05     | 880       | 184       | 125       | 0,59       | 0,85          | 0,88             | 0,83      |
| <b>T6R</b>            | 82,45     | 813       | 174       | 192       | 0,59       | 0,82          | 0,81             | 0,82      |
| <b>T6R (Gri)</b>      | 85,19     | 872       | 177       | 133       | 0,59       | 0,85          | 0,87             | 0,83      |
| <b>T7R</b>            | 81,65     | 788       | 139       | 217       | 0,61       | 0,82          | 0,78             | 0,85      |
| <b>T7R (Gri)</b>      | 84,35     | 856       | 168       | 149       | 0,60       | 0,84          | 0,85             | 0,84      |
| <b>T8R</b>            | 78,43     | 714       | 131       | 291       | 0,60       | 0,77          | 0,71             | 0,84      |
| <b>T8R (Gri)</b>      | 83,81     | 842       | 162       | 163       | 0,60       | 0,84          | 0,84             | 0,84      |
| <b>T9R</b>            | 67,73     | 530       | 94        | 475       | 0,60       | 0,65          | 0,53             | 0,85      |
| <b>T9R (Gri)</b>      | 83,21     | 828       | 140       | 177       | 0,61       | 0,84          | 0,82             | 0,86      |

### Uzaktan Eğitim Sınıfı Sınama Sonuçları

|                       | AP    | TP  | FP  | FN  | IoU  | Recall | Precision | F1   |
|-----------------------|-------|-----|-----|-----|------|--------|-----------|------|
| <b>Derinlik</b>       | 4,00  | 5   | 1   | 980 | 0,56 | 0,01   | 0,01      | 0,83 |
| <b>Renkli</b>         | 44,86 | 382 | 159 | 603 | 0,55 | 0,50   | 0,39      | 0,71 |
| <b>Sıcaklık</b>       | 32,47 | 146 | 30  | 839 | 0,67 | 0,25   | 0,15      | 0,83 |
| <b>Sıcaklık (Gri)</b> | 55,76 | 301 | 49  | 684 | 0,68 | 0,45   | 0,31      | 0,86 |
| <b>RGBDT</b>          | 10,10 | 29  | 5   | 956 | 0,68 | 0,06   | 0,03      | 0,85 |
| <b>RGBDT (Gri)</b>    | 13,49 | 55  | 12  | 930 | 0,64 | 0,10   | 0,06      | 0,82 |
| <b>RGBT</b>           | 46,05 | 341 | 118 | 644 | 0,59 | 0,47   | 0,35      | 0,74 |
| <b>RGBT (Gri)</b>     | 64,63 | 500 | 155 | 485 | 0,60 | 0,61   | 0,51      | 0,76 |
| <b>T1R</b>            | 64,15 | 465 | 134 | 520 | 0,62 | 0,59   | 0,47      | 0,78 |
| <b>T1R (Gri)</b>      | 59,32 | 411 | 113 | 574 | 0,61 | 0,54   | 0,42      | 0,78 |
| <b>T2R</b>            | 53,15 | 400 | 146 | 585 | 0,41 | 0,52   | 0,41      | 0,73 |
| <b>T2R (Gri)</b>      | 60,05 | 438 | 160 | 547 | 0,57 | 0,55   | 0,44      | 0,73 |
| <b>T3R</b>            | 52,76 | 399 | 154 | 586 | 0,57 | 0,52   | 0,41      | 0,72 |
| <b>T3R (Gri)</b>      | 65,15 | 482 | 165 | 503 | 0,58 | 0,59   | 0,49      | 0,74 |
| <b>T4R</b>            | 52,23 | 404 | 155 | 581 | 0,57 | 0,52   | 0,41      | 0,72 |
| <b>T4R (Gri)</b>      | 66,82 | 508 | 167 | 477 | 0,59 | 0,61   | 0,52      | 0,75 |
| <b>T5R</b>            | 51,31 | 397 | 145 | 588 | 0,58 | 0,52   | 0,40      | 0,73 |
| <b>T5R (Gri)</b>      | 67,05 | 518 | 180 | 467 | 0,59 | 0,62   | 0,53      | 0,74 |
| <b>T6R</b>            | 49,60 | 382 | 144 | 603 | 0,58 | 0,51   | 0,39      | 0,73 |
| <b>T6R (Gri)</b>      | 66,73 | 513 | 178 | 472 | 0,59 | 0,61   | 0,52      | 0,74 |
| <b>T7R</b>            | 48,68 | 374 | 138 | 611 | 0,58 | 0,50   | 0,38      | 0,73 |
| <b>T7R (Gri)</b>      | 66,26 | 518 | 171 | 467 | 0,59 | 0,62   | 0,53      | 0,75 |
| <b>T8R</b>            | 47,45 | 360 | 123 | 625 | 0,59 | 0,49   | 0,37      | 0,75 |
| <b>T8R (Gri)</b>      | 65,42 | 515 | 172 | 470 | 0,59 | 0,62   | 0,52      | 0,75 |
| <b>T9R</b>            | 45,28 | 331 | 109 | 654 | 0,60 | 0,46   | 0,34      | 0,75 |
| <b>T9R (Gri)</b>      | 63,81 | 490 | 158 | 495 | 0,60 | 0,60   | 0,50      | 0,76 |

## ÖZGEÇMİŞ

### Kişisel Bilgiler

Soyadı, adı : ÖZCAN, Ahmet  
Uyruğu : T.C.

### Eğitim

| Derece        | Üniversite ve Bölüm  | Mezuniyet tarihi |
|---------------|----------------------|------------------|
| Lisans        | Erciyes Üniversitesi | 10.02.2011       |
| Yüksek Lisans | Erciyes Üniversitesi | 19.09.2016       |

### Yabancı Dil

İngilizce

### Yayınları

Ozcan A., Alparslan O., Cetin O. (2022, Şubat). Nesne Tespit Yöntemlerinin Robotik Uygulamalar İçin Optimize Edilerek Performanslarının Karşılaştırılması. 3. Uluslararası Mühendislik Bilimleri ve Multidisipliner Yaklaşımlar Kongresi, 266-273, İstanbul.

Alparslan, Ö., Özcan, A., & Çetin, Ö. (2022). Model ve Veri Odaklı Yaklaşımlar ile Nesne Tespit Başarısının Arttırılmasına Yönelik ESA ve Veri Seti Optimizasyonları. Mühendislik Bilimleri ve Araştırmaları Dergisi, 4(2), 121-128.

### Tezden Türetilen Yayınları/Sunumları

ÖZCAN, A., & ÇETİN, Ö. (2022). Örnek Bölütlemesi ile Nesne ve Renk Sınıflandırması. İçinde Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi (ss. 182-189). SDU Journal of Natural and Applied Sciences. <https://doi.org/10.19113/sdufenbed.1023674>

Ozcan, A., & Cetin, O. (2022). A Novel Fusion Method With Thermal and RGB-D Sensor Data for Human Detection. İçinde IEEE Access (C. 10, ss. 66831-66843). Institute of Electrical and Electronics Engineers (IEEE). <https://doi.org/10.1109/access.2022.3185402>