



Development of object detection model for sizing safety measures in Human-Industrial mobile robot interaction

Tarik Aslan^{1*}, Mustafa Yağimli²

¹Department of Occupational Health and Safety, Institute of Graduate Studies, Istanbul Gedik University, 34876, Kartal, Istanbul, Türkiye

²Department of Computer Engineering, Faculty of Engineering, Istanbul Gedik University, 34876, Kartal, Istanbul, Türkiye

Highlights:

- Safe work in human - industrial mobile robot interaction
- Sizing Safety Measures
- Determination of protective equipment and authorization level with high accuracy and speed of inference

Keywords:

- Object detection
- Robot safety
- Safe operation
- Yolov5n
- SSD MobileNet V3

Article Info:

Research Article

Received: 30.05.2023

Accepted: 20.11.2023

DOI:

10.17341/gazimmfd.1306981

Acknowledgement:

This work was supported by the Scientific Research Projects Coordination Unit of Istanbul Gedik University. Project number "GDK202207-09"

Correspondence:

Author: Tarik Aslan
e-mail: tarikaskan@ktu.edu.tr
phone: +90 532 304 4987

Graphical/Tabular Abstract

In this comparative study, two architectures belonging to the YOLO family and SSD MobileNet V3 architecture were modeled and analyzed to provide advanced safety measures in mobile robot-human interaction and to minimize safety-related work losses. The names of the methods and their performance values are given in Figure A. The YOLO architecture outperformed the SSD MobileNet V3 architecture.

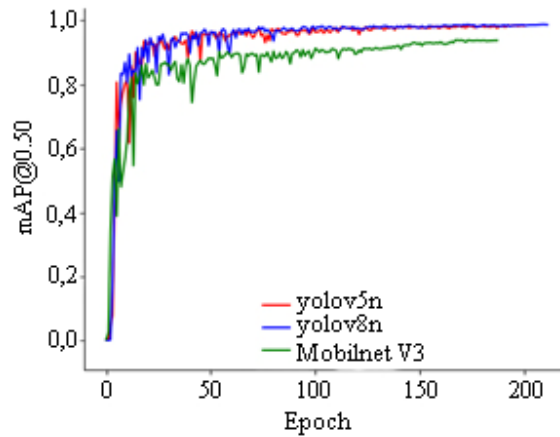


Figure A. Training mAP / Epochs Curve Graphical Outputs

Purpose: The purpose of this study is to develop a new method using object detection technology to determine the risk level of human-robot interaction by identifying employee-specific criteria such as the use of protective equipment and authorization levels. This approach aims to apply different-sized safety measures depending on the assessed risk magnitude, thereby improving safety and operational efficiency in environments where humans interact with robots.

Theory and Methods: In this study, object detection models were developed and analyzed using YOLOv5n, YOLOv8n, and SSD MobileNet V3 object detection architectures to identify employee-specific criteria for interaction with mobile robots. The performance of these models is evaluated based on their speed and accuracy in detecting employee-specific criteria

Results: The findings show that the YOLO (You Only Look Once) family of architectures delivers superior performance in terms of both speed and accuracy compared with SSD MobileNet V3. The YOLOv5n model achieved 650 FPS (frames per second) with GPU acceleration and an F1 accuracy score of 95.7% based on the test data evaluation. These results show that the models built with the YOLOv5n and YOLOv8n architectures accurately detect employee-specific criteria in human-robot interactions and rapidly with the use of a GPU.

Conclusion: This study shows that object detection technology has reached a level of accuracy and speed that enables its integration with proximity sensors. This progress could enable industrial mobile robots to identify employee-specific criteria and assess risks before applying safety measures. Furthermore, this approach creates a safe working environment and increases operational efficiency by eliminating unnecessary safety measures. This methodology has the potential for wide applicability in various industries and fields, and provides a tool for creating safer working environments.



İnsan - endüstriyel mobil robot etkileşiminde güvenlik önlemlerinin boyutlandırılması için nesne tespit modeli geliştirme

Tarık Aslan^{1*}, Mustafa Yağimli²

¹İstanbul Gedik Üniversitesi, Lisansüstü Eğitim Enstitüsü, İş Sağlığı ve Güvenliği Anabilim Dalı, 34876, Kartal, İstanbul, Türkiye

²İstanbul Gedik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34876, Kartal, İstanbul, Türkiye

ÖNEÇIKANLAR

- İnsan-Endüstriyel mobil robot etkileşiminde güvenli çalışma
- Güvenlik önlemlerinin boyutlandırılması
- Koruyucu donanım ve yetki seviyesinin yüksek doğruluk ve çıkarım hızı ile belirlenmesi

Makale Bilgileri

Araştırma Makalesi

Geliş: 30.05.2023

Kabul: 20.11.2023

DOI:

10.17341/gazimmfd.1306981

Anahtar Kelimeler:

Nesne tespiti,
robot güvenliği,
güvenli çalışma,
YOLOv5n,
SSD MobileNet V3

ÖZ

İnsan-robot etkileşiminde, güvenlik önlemleri için geleneksel olarak tek düzey güvenlik önlemleri uygulanır ve çalışanlara ait kriterler dikkate alınmaz. Bununla birlikte nesne tespit teknolojisi kullanılarak yeni bir yöntem geliştirilebilir; koruyucu donanım kullanımı ve yetki seviyeleri gibi çalışanlara özgü kriterleri tespit edilerek insan-robot etkileşimi risk seviyesi belirlenebilir ve risk büyüklüğüne bağlı olarak farklı büyüklükte güvenlik önlemleri uygulanabilir. Bu çalışmada, YOLOv5n, YOLOv8n ve SSD MobileNet V3 nesne tespit modelleri bu amaçla geliştirilmiş ve analiz edilmiştir. Bulgular, YOLO ailesine ait mimarilerin daha hızlı çalıştığını ve daha yüksek doğruluk seviyelerine ulaştığını ortaya koymuştur. YOLOv5n algoritması GPU kullanımı ile 650 FPS hıza ve test verileriyle yapılan değerlendirme sonucunda %95,7'lik bir F1 doğruluk değerine ulaşılmıştır. Sonuçlar, nesne tespit teknolojisinin yakınlık sensörleriyle eş zamanlı olarak uygulanabilecek bir doğruluk ve hıza ulaştığını ve endüstriyel mobil robotların güvenlik önlemleri almadan önce çalışanların özelliklerini tespit edebileceğini ve riskleri derecelendirebileceğini göstermektedir. Bu durum daha güvenli çalışma ortamı oluşmasına, gereksiz önlemlerin elimine ve operasyonel verimliliğin optimize edilmesine olanak verir. Ayrıca bu yöntem, güvenli çalışma ortamlarının sağlanmasına yönelik olarak birçok sektörde ve alanda da uygulanabilir.

Development of object detection model for sizing safety measures in Human-Industrial mobile robot interaction

HIGHLIGHTS

- Safe work in human-industrial mobile robot interaction
- Sizing Safety Measures
- Determination of protective equipment and authorization level with high accuracy and speed of inference

Article Info

Research Article

Received: 30.05.2023

Accepted: 20.11.2023

DOI:

10.17341/gazimmfd.1306981

Keywords:

Object detection,
robot safety, safe operation,
YOLOv5n,
SSD MobileNet V3

ABSTRACT

In human-robot interaction, single-level safety measures are traditionally applied, and employee-specific criteria are not taken into account. However, a new method can be developed using object detection technology, and the risk level of human-robot interaction can be determined by identifying employee-specific criteria such as the use of protective equipment and authorization levels, and different-sized safety measures can be applied depending on the risk magnitude. In this study, YOLOv5n, YOLOv8n, and SSD MobileNet V3 object detection models were developed and analyzed for this purpose. The results show that architectures belonging to the YOLO family run faster and achieve higher levels of accuracy. The YOLOv5n algorithm achieved a speed of 650 FPS with the use of a GPU and an F1 accuracy of 95.7% as a result of the evaluation with test data. The results show that object detection technology has reached an accuracy and speed that can be applied simultaneously with proximity sensors, and that industrial mobile robots can detect worker characteristics and rate risks before taking safety measures. This allows for safer working environments, eliminates unnecessary precautions, and optimizes operational efficiency. In addition, this method can be applied in many sectors and areas to provide safe working environments.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *tarikaslan@ktu.edu.tr, mustafa.yagimli@gedik.edu.tr / Tel: +90 532 304 4987

1. Giriş (Introduction)

Endüstriyel mobil robotlar, görevleri yerine getirmek için konum değiştirebilen çok yönlü makinelerdir. Çeşitli hareket sistemlerine ve otonom yeteneklere sahip olmaları onları endüstriyel ve ticari uygulamalar için ideal hale getirmektedir [1]. Konum değişikliği için kılavuzlu, programlanmış, uzaktan kumandalı, hat takipli veya otonom olabilirler [2]. Mobil robotlar endüstride raylarda veya önceden tanımlanmış yollar üzerinde hareket eden ve genellikle operatör gözetimi gerektiren öncüllerinden sonra günümüzde tam otonom aygıtlar haline dönüşmüştür. Otonom mobil robotlar çalışma alanında güvenli gezinmek, konumlarını tespit etmek, çevrelerini yorumlamak için özelleştirilmiş sensörler, haritalandırma (çevrelerini 2 veya 3 boyutlu şekilde oluşturma), derin öğrenme ve benzeri teknolojiler kullanırlar [3]. Hareket sistemlerine göre mobil robotlar kara tabanlı (tekerlekli), yürüten (bacaklı), paletli ve pervaneli şeklinde birkaç ana kategoride sınıflandırılabilir [4].

Mobil robotların endüstriyel alanda kullanımı gelişme aşamasında olup daha çok depolama tesislerinde malzeme taşımacılığında otonom olarak kullanılmaktadır [5]. Genel anlamı ile endüstriyel mobil robotların görev şekli tehlikeli/çok tehlikeli, çalışma alanı da karmaşık olabilmektedir. Bunlarla birlikte sınırlı bir alanda, önceden tanımlanmış bir işlem ya da görevi yüksek hassasiyet ve kararlılıkla gerçekleştirmek için özelleştirilmiş mobil robotlar da vardır [6, 7]. Endüstriyel mobil robotların insanlarla etkileşim hala tamamen güvenli değildir ve ciddi riskler içerir. Mobil robotları da kapsayacak şekilde insan robot etkileşiminde bazı güvenlik önlemlerine ihtiyaç duyulması; güvenlik dereceli izlenen durdurma, elle yönlendirme, hız/mesafe izleme ve güç/kuvvet sınırlaması şeklinde standartlaşmıştır [1, 8, 9].

Güvenlik dereceli izlenen durdurma: Beklenmedik veya olağan dışı bir durumda devreye giren otonom durumda sistemdir. İnsan robot çarpışması gerçekleşmeden devreye giren önleyici bir sistemdir. Bu sistemin sağlıklı işlemesi için robot, tehlikeleri algılayan sensörlerle donatılmıştır.

Elle yönlendirme: Bir mobil robotun uzaktan kontrol edilmesidir. Elle yönlendirmede insan düşüncesi ve algıları devrede olduğundan robotun tehlikeli şekilde hareket etmesi ve çalışana zarar vermesi engellenmiş olur. Böylece mobil robotun karmaşık bir ortamda gezinmesi, insanlara yakın olması ve hassas görevleri yerine getirmesi güvenli şekilde sağlanır.

Hız/Mesafe İzleme: Güvenlik sensörleri ile mobil robotun insan ve nesnelere olan yakınlığı ölçülebilir. Bu da mobil robotun çalışana ile arasındaki mesafeyi korumasını ve engellerden kaçınmasını sağlar.

Güç/kuvvet sınırlaması: Robotun bir çalışana çarpması halinde çalışana zarar vermeyecek şekilde bir kuvvet ile hareket etmesinin sağlanmasıdır. Mobil robota ait kuvvetin azaltılması veya frenlenmesidir.

Endüstriyel mobil robotlarda standartlar doğrultusunda belirlenen güvenlik önlemleri çalışana ait kriterler değerlendirilmeden, tüm çalışanlar için aynı düzeyde uygulanmaktadır [10]. Örneğin güvenlik önlemi hız/mesafe izleme ise, endüstriyel mobil robot operasyon süresince çalışan ayırt etmeksizin tüm çalışanlar için önceden programlanan hız/mesafe büyüklüğünü uygular. Bu da tek düzey bir güvenlik önlemi ve mobil robotlar için zaman zaman verimsiz bir çalışma getirir. Oysa endüstriyel mobil robotlar güvenlik önlemleri uygulamadan önce çalışanları analiz edebilirse, gerektiğinde daha katı güvenlik önlemleri uygulayarak kazaları engelleyebilir; gerektiğinde ise daha esnek güvenlik önlemi olarak verimini artırılabilir [11].

Endüstriyel mobil robotların güvenlik boyutunu belirlemek için çalışanların risk seviyelerini tespit etmeleri gerekmektedir. Bu amaçla, derin öğrenmeye dayalı nesne tespiti teknolojisi oldukça kullanışlı bir araçtır. Ancak, nesne tespiti teknolojisinin pratik uygulanabilirliği bazı önemli zorluklarla karşı karşıyadır. Bu zorluklar, derin öğrenme tabanlı yaklaşımların doğruluk seviyelerinin yetersiz olması ve güvenlik önleminin zamanında sağlanması için gerekli olan hızlı karşılayamaması gibi faktörlerden kaynaklanmaktadır.

Son birkaç yıldır nesne tespit teknolojisindeki gelişmeler, doğruluk ve hız açısından önemli iyileştirmeler sunmuştur. Özellikle tek çerçeveli nesne tespit algoritmalarındaki ilerlemeler, mobil robotların yakınlık sensörleri ile birlikte uygulanabilir bir seviyeye taşınması; kabul edilebilir doğruluk ve hız seviyelerine ulaşmasını mümkün kılmıştır [12]. Bu çalışmanın amacı, nesne tespit teknolojisinin endüstriyel mobil robotlar için güvenlik seviyelerini belirleme de kullanılabilirliğini veya bu tür hızlı ve yüksek doğruluk gerektiren kritik işlemler veya durumlar için ne kadar uygun olduğunu değerlendirmektir.

1.1. Nesne Tespitinin Gelişimi (Development of Object Detection)

Nesne tespit teknolojisi iki farklı dönemden geçerek gelişmiştir: geleneksel nesne tespit dönemi ve derin öğrenmeye dayalı nesne tespit dönemidir [13].

Geleneksel Nesne Tespiti (2014 Öncesi) Dönemi: Nesnelere erken dönem bilgisayarlar kullanılarak tespit edilmeye çalışıldığı dönemdir. Tasarlanmış öznetelik çıkarma ve kural tabanlı sistemlere dayalı ilk nesne tespit algoritmaları bu dönemde oluşturulmuştur. Nesne ölçeğinin, açısının ve aydınlatma koşullarının değişmesi tespitlerde sorunları oluşmasına neden olabiliyordu. Bu nedenle etkili görüntü temsilleri gerçekleştirilmeyordu [14].

Derin Öğrenmeye Dayalı Nesne Tespit Dönemi: 2014 yılında derin öğrenme tabanlı, karmaşık ve dağınık sahnelerdeki nesnelere yüksek doğruluk başarısı ile tespit edilebilen R-CNN (Bölge-Evrimsel Sinir Ağı) mimarisi önemli bir kilometre taşı ve dönüm noktası oldu [15]. Ancak R-CNN nesne tespitinin zayıflığı görseli 2000 bölgeye ayırması, bu bölgeleri tek tek sınıflandırmasıydı [14]. Bu işlem nesnelere tespitinin yavaş gerçekleşmesini sağlıyordu. Bu gelişimin hemen ardından gerçek zamanlı tespit üzerine çalışmalar yapıldı ve 2016 yılında YOLO (Sadece Bir Kez Bak) ailesinin ilk versiyonu olan YOLOv1 [16] ve ardından SSD (Tek Çerçeve Çok Kutu Dedektörü) [17] yayımlanarak tek çerçeveli yeni bir nesne tespit yöntemi geliştirildi [14]. YOLO ve SSD, tek çerçeveli bu yöntemi geliştirerek, daha sonraki yıllarda yeni versiyonlarını piyasaya sürdüler. 2019 yılında SSD MobileNet V3 versiyonu yayımlandı [18]. Ardından, 2022'de YOLOv5 ve 2023'te YOLOv8 gibi yeni YOLO sürümleri ortaya çıktı [19]. Bu yeni versiyonlar, hem doğruluk hem de hız konusunda etkileyici sonuçlar sağladı. Örneğin, YOLOv8n versiyonu ile eğitilen bir model, 227 FPS (Saniyede Kare Sayısı) hızında çalışırken %94,3'lük mAP (genel Ortalama Hassasiyet) doğruluğuna ulaştı [20].

1.2. Nesne Tespitine Dayalı Güvenli Çalışma Ortamları (Safe Working Environments Based on Object Detection)

Nesne tespiti teknolojisinin gelişimi, nesne tespitinin birçok sektörde ve alanda kullanılmasını sağlamıştır. Bu alanlardan biri güvenli çalışma ortamlarının tespiti ve yönetimidir. Derin öğrenme teknikleri, güvenli çalışma ortamlarının tespiti konusunda büyük bir ilgi çekmiş ve bu alanda kapsamlı bir literatür oluşturulmuştur. Özellikle, koruyucu donanımları temsil eden baretin tespiti için yapılan çalışmalar oldukça yoğundur. Tablo 1'de özetlenen çalışmalar, koruyucu donanımların tespiti için elde edilen doğruluk seviyelerinin

Tablo 1. Baret Tespitine Yönelik Yapılan Çalışmalar (Activities Conducted for Helmet Detection) [21-33]

| Çalışmayı Yapan | Yılı | Tespit edilmesi hedeflenen KKD | Kullanılan Mimari/versiyon/varyant | Hızı (FPS) | Performans |
|-----------------|------|--------------------------------|---------------------------------------|------------|-------------------------------------|
| Fang vd. | 2018 | Baret | Faster R-CNN | 5 | %95,7 Keskinlik ve %94,9 Duyarlılık |
| Wu vd. | 2019 | Baret | "reverse progressive attention" + SSD | 31,30 | %83,89 mAP |
| Zhang vd. | 2020 | Baret | Faster R-CNN | - | % 71,21 Doğruluk |
| Wang vd. | 2020 | Baret | YOLOv3 | 28,57 | %97,79 mAP |
| Kim vd. | 2020 | Baret | Faster R-CNN | - | %82 mAP |
| Saudi vd. | 2020 | Baret, yelek, iş ayakkabısı | Faster R-CNN | - | %70 Doğruluk |
| Casuat vd. | 2020 | Baret | YOLOv3 | - | %79,24 mAP |
| Filatov vd. | 2020 | Baret | SqueezeDet + MobileNet | 18,5 | %75 F1 Skoru |
| Wang vd. | 2020 | Baret | Lightweight CNN | 62 | %89,4 AP |
| Zhou vd. | 2021 | Baret | YOLOv5s | 110 | %93,6 mAP |
| Cengil | 2021 | Baret | YOLOv5 | 0,032 | %90,3 mAP |
| Gallo vd. | 2022 | Tüm KKD'ler | YOLOv4 | 6,8 | %95 Doğruluk |
| Yang vd. | 2023 | Baret ve Maske | YOLOv5s | - | %96 mAP |
| Farooq vd. | 2023 | Baret | YOLOv5n | 70,4 | %94,2 mAP |

%70 ile %98 arasında değiştiğini göstermektedir. Koruyucu donanımların tespit hızı ise en yüksek 110 FPS gibi bir değere ulaşmıştır. Nesne tespit mimarilerine bakıldığında, farklı nesne tespit mimarilerinin kullanıldığı ancak 2021 yılından sonra YOLO ailesine ait versiyonlarının tercih edildiği ve mAP değerlerinin %90'ın altına düşmediği görülmektedir. FPS değeri ise, nesne tespit mimarisinin yanı sıra kullanılan donanıma, özellikle GPU (Grafik İşlem Birimi) kullanımına bağlıdır. GPU donanımlarının kullanımıyla günümüzde nesne tespit hızları çok daha yüksek seviyelere ulaşmıştır. Bu durumda, Tablo 1'deki eğitim modelleri günümüzde yüksek kapasiteli GPU donanımlar kullanılarak uygulanırsa, doğruluk seviyeleri değişmese de FPS değerleri artacaktır.

Endüstriyel mobil robotların, insanlarla güvenli bir şekilde etkileşimde bulunabilmesi için hızlı tepki verme yeteneğine sahip olması gerekir. Tablo 1 incelendiğinde, endüstriyel mobil robotların nesne tespitine dayalı bir yaklaşım kullanarak güvenliği sağlayamamasının temel zorluk nedeni görülebilir. Tablo 1'de yer alan nesne tespit hızları, endüstriyel mobil robotlar için gerekli olan tespit hızları için oldukça yavaştır. Bu nedenle de, yapılan literatür taramasında bu yönde özel bir çalışmaya rastlanmamıştır.

1.3. Mobil Robotlarda Güvenlik ve Yakınlık Sensörlerin Kullanımı (Use of Safety and Proximity Sensors in Mobile Robots)

Günümüzde endüstriyel mobil robotlar gelişim aşamasında olup endüstride hala kendisine yer bulma çabasıdır [34]. Özellikle güvenlik alanındaki endişeler endüstriyel mobil robotların endüstride yaygınlaşmasını yavaşlatmaktadır. Derin öğrenme ise robotik uygulamalarda kullanılsa da, robot güvenliğinde yavaşlığı ve doğruluk seviyesi yeterli düzeyde olmaması nedeniyle tercih edilmemektedir. Güvenlik alanında daha çok lidar ve benzer türdeki yakınlık sensörleri kullanılmaktadır [35]. Tipik bir lidar sisteminin tepki hızı, lidar türüne ve tespit edilen nesnenin uzaklığına bağlı olarak değişse de saniyede yaklaşık 10.000 noktasal bilgi alabilecek kapasitedir ve bu da yaklaşık 100 milisaniye içinde 360°'lik bir alanda tarama yapılmasını sağlar [36]. Bu da güvenliği sağlamak için hızlı bir tepki süresi sağlar. Bu karşın yakınlık sensörleri nesne tespit kadar yetenekli değildir. Çalışanları birbirinden ayıramaz ve buna göre güvenlik önlem boyutunu belirleyemez. Bu nesne tespit ile yapılabilir. Bu çalışma, tek çerçeveli nesne tespit mimarilerindeki en son gelişmelerin, yakınlık sensörleri ile uyumlu mobil robotlarda güvenlik önlemleri için kullanılabilir seviyeye ulaştığıyla ilgilidir. Böylece derin öğrenme ve yakınlık sensörleri birlikte kullanılmasının endüstriyel mobil robotlarda güvenliğin ve verimin artmasına yönelik yeni bir yaklaşım getirmektedir.

2. Deneysel Metot (Experimental Method)

2.1. Kriter Belirleme (Criteria Determination)

Endüstriyel mobil robotlar, çalışma ortamında bulunan insanların güvenliğini sağlamak amacıyla, koruyucu donanım olarak kullanılan baretleri ve bu baretlerin rengini algılayarak, çalışanların yetki seviyelerini belirleyebilir. Bu yaklaşımın modellenmesi yapılırken, farklı çalışanların farklı yetki seviyelerine sahip olabileceği göz önünde bulundurularak, üç farklı baret rengi (mavi, sarı ve beyaz) ile baret kullanılmaması durumu da dahil olmak üzere toplamda dört farklı kriter belirlenmiştir. Örneğin, mavi renkteki baret kullanan bir çalışan tam yetkili olarak sınıflandırılabilirken, sarı baret kullanan bir çalışan kısmi yetkili ve beyaz baret kullanan bir çalışan ise yetkisiz olarak kabul edilebilir.

2.2. Nesne Tespit Mimarisini Belirleme (Determining the Object Detection Architecture)

Derin öğrenmede, nesne tespit mimarileri yaygın olarak CNN (Evrışimli Sinir Ağı) kullanılarak oluşturulur. CNN'e dayalı nesne tespit mimarileri ikiye ayrılır; bölge tabanlı (region-based) ve tek çerçeve (single-shot) tabanlı algoritmalar olarak. Bölge tabanlı algoritmalarda en yaygın kullanımı olan R-CNN iken tek çerçeveli algoritmalar için ise SSD ve YOLO algoritmalarıdır. Tek çerçeveli algoritmalar bölge algoritmalarına göre daha hızlıdır [14]. İnsan robot etkileşiminde hız oldukça önemli olduğundan, bu çalışmada tek çerçeveli iki farklı mimari olan, YOLO ve SSD değerlendirilmiş ve karşılaştırılmıştır. YOLO için YOLOv5n ve son versiyonu olan YOLOv8n versiyonları kullanırken SSD için SSD MobileNet V3 versiyonu kullanılmıştır. MobileNet, gömülü sistemler ve mobil uygulamalar için geliştirilmiş verimli CNN modelidir [37].

2.3. Veri Seti Hazırlama (Preparing Dataset)

Çalışmada kullanılan verilere ait genel bir bakış Şekil 1'de ve istatistiksel bilgiler Tablo 2'de yer almaktadır. Veri seti, insan yüzleri, aydınlatma koşulları, fotoğraf çekim açısı ve kameraya olan uzaklık gibi faktörlerin yeterli sayıda ve çeşitlilikte olmasına dikkat edilerek oluşturulmuştur. Bu şekilde, veri setinin her bir sınıf için tam bir temsil yetisi sağlanması hedeflenmiş ve aynı zamanda aşırı uyum (aşırı öğrenme) sorununun önüne geçilmiştir.

2.4. Görüntü Ölçekleme (Image Scaling)


Veri ölçeklendirme, bir veri setinde bulunan tüm verilerin belirli bir piksel boyutuna standardize edilmesi, etiketlenmesi, eğitim ve işleme için uygun hale getirilmesi işlemidir. Verilerin çözünürlük büyüklüğü,

tespit edilecek nesnenin türüne (büyük veya küçük olması) ve çalışmanın içeriğine bağlı olarak belirlenir. Ayrıca, hedeflenen sonuca en yakın performansı elde etmek için verilerin boyutu, modelin farklı boyutlarda eğitilmesinin sonuçlarına göre ayarlanabilir [38].

Veri seti farklı piksel boyutlarında eğitilerek, Tablo 3'te yer alan, bir ablasyon çalışması gerçekleştirilmiştir. Sonuç olarak, 416x416 piksel boyutunun diğer piksel boyutlarına benzer doğruluk performansı sunduğu, ancak daha yüksek bir FPS değerine sahip olduğu görülmüştür.

2.5. Etiketleme (Labeling)

Eğitim modelinin doğru tahmin (tespit) yapabilmesi için tam olarak neyi öğrenmesi gerektiği bilgisine sahip olması gerekmektedir. Görsel veride birçok nesne veya örüntü olabilir ve derin öğrenme ile aynı çıkarımda sınıflandırılmış farklı nesne ve örüntülerin tespiti yapılmak istenebilir. Etiketleme, eğitimde kullanılacak bir görsel veride öğrenilmesi gereken nesnenin veya örüntünün sınırlandırma kutusu içine alınarak, sınıfı ve koordinatları ile ilgili bilgilerin, veri ile aynı isimde olacak bir txt uzantılı dosyaya kaydedilmesidir [39].



Şekil 1. Veri setinde yer alan görüntü örnekleri (Image examples from the dataset)

Tablo 2. Veri seti istatistikleri (Statistics of dataset)

| Sınıf | Sınıf tanımı | Eğitim veri seti | Doğrulama veri seti | Test veri seti | Toplam veri adedi |
|--------|---|------------------|---------------------|----------------|-------------------|
| 3 | Mavi koruyucu donanım kullanan yetkili | 315 | 135 | 50 | 500 |
| 2 | Sarı koruyucu donanım kullanan yetkili | 315 | 135 | 50 | 500 |
| 1 | Beyaz koruyucu donanım kullanan yetkili | 315 | 135 | 50 | 500 |
| 0 | Koruyucu donanım kullanılmıyor | 315 | 135 | 50 | 500 |
| Toplam | | 1260 | 540 | 200 | 2000 |

Tablo 3. Veri seti piksel büyüklüğünün ablasyon ile belirlenmesi (Determination of pixel size of dataset by ablation)

| Veri seti piksel büyüklüğü | YOLOv5n | | YOLOv8n | | SSD MobileNet V3 | |
|----------------------------|---------|----------------|---------|----------------|------------------|----------------|
| | mAP (%) | FPS (Ortalama) | mAP (%) | FPS (Ortalama) | mAP (%) | FPS (Ortalama) |
| 416x416 | %98,6 | 650 | %98,8 | 470 | %93,9 | 136 |
| 640x640 | %98,6 | 560 | %98,8 | 410 | %94,2 | 108 |
| 1280x1280 | %98,7 | 430 | %98,9 | 320 | %94,3 | 72 |

Etiketleme ile asıl veri üzerinde değişiklik yapılmaz. Bu işlem ile yapılan txt uzantılı bir yardımcı dosya oluşturmak ve eğitim için gerekli olan bilgilerin eğitimde kullanılmak üzere hazır hale getirilmesidir. Standart ve hassas bir etiketleme eğitim sırasında oluşacak kayıpları azaltır.

2.6. Hiperparametreler (Hyperparameters)

Devir (Epoch): Önceden etiketlerle tanımlanmış veri setinin model eğitimde işleme sayısını ifade eder. Devir veya çevrim sayısı geri besleme verilerini eğitimin tekrarlanması ile pekiştirmeyi sağlayan ve nesne tespit modelinin performansını optimize etmek için ayarlanabilen önemli bir hiperparametredir [40].

Yığın (Batch): Tüm veri setini oluşturan alt veri kümelerini ifade eder. Eğitim sırasında model ağırlıklarının her bir işlenen veriden sonra güncellemesi yerine, ağırlıkların kümelene verilerin her kümedeki veri işlendikten sonra güncellenmesidir. Bu durum işlem sayısını azaltarak eğitim süresini kısaltır ve ağırlık güncellemelerinin kararlılığını artırır. Yığın boyutu küçük olursa ağırlıkların güncellenmesi sıklaşacak bu da yakınsama durumunu hızlandıracak ve sınıfın genelleme eğilimini iyileştirecektir. Yığın boyutunun büyük olması ise istikrarlı ağırlık güncellemelerin gerçekleşmesini sağlayacak ve eğitimi hızlandıracaktır [40].

Önceden Eğitilmiş Model Kullanımı (Pretrained): Bir eğitim modelini sıfırdan eğitmek yerine önceden eğitilmiş bir model üzerinden eğitmek için kullanılan yöntemdir [41]. YOLO'nun 80 nesne için önceden eğitilmiş hazır modelleri bulunur. Veya araştırmacı daha önce eğittiği bir modeli geliştirmek için yeni bir eğitim başlattığında sıfırdan başlamak için önceden tamamladığı eğitimi kullanabilir. Böylece model daha önceden modeldeki özellikler ve temsiller hakkında bilgi sahibi olduğundan eğitim için gerekli işlem sayısını önemli ölçüde azaltır ve eğitim süresini kısaltır.

Optimize Sağlayıcı (Optimizer): Eğitim sırasında yapay sinir ağırları ağırlıkların oluşturulması için kullanılan algoritma türüdür. Bir optimize sağlayıcısının temel amacı çıkışın girişe bağlı oluşturduğu kayıp fonksiyonunu ölçmek ve en aza indirmektir. SGD (Stokastik gradyan inişi), Adam (Uyarlanmış Moment Tahmini), AdamW (Adam Ağırlık Azalması) ve RMSprop (Kök Ortalama Kare Yayılımı) gibi birçok farklı optimizasyon algoritması vardır [42-46]. Her sağlayıcı, modelin performansını artırmak için ayarlanabilen hiperparametre seti sunar [47].

Öğrenme Oranı (Learning Rate): Öğrenme sonucu oluşan ağırlıkların adım boyutunu belirler. Öğrenme oranı büyükse öğrenme hızlı adımlarla gerçekleşeceğinden eğitim hızlı bir şekilde tamamlanır. Ancak bu durum eğitimde ağırlıkların doğru şekilde oluşmamasına ve yakınsamanın başarısız olmasına neden olabilir. Daha küçük öğrenme oranı daha istikrarlı bir yakınsama sağlar ancak eğitim süresi oldukça uzar, sistem donanımının buna uygun olması gerekir [48]. Öğrenme oranının sabit tutulması kullanışlı olmayabilir. Bunun yerine ilk öğrenme oranı (initial learning rate) daha büyük değerle başlar son öğrenme oranı (final learning rate) daha küçük bir değerle sonlandırılır. Bu durum öğrenme işlemini ve süresini optimize eder.

Çalışmada kullanılan tüm modeller, veri kümesi üzerinde Tablo 4'te belirtilen hiperparametre aralıklarında ön eğitime tabi tutulmuş ve model için en yüksek performansı sağlayan hiperparametre değerleri belirlenmiştir.

2.7. Model Performans Ölçüm Kriterleri (Model Performance Measurement Criteria)

Model performanslarını değerlendirmek için kullanılan temel metrikler; Doğru Pozitif (TP), Yanlış Pozitif (FP), Doğru Negatif (TN), Yanlış Negatif (FN) ve bu temel metriklerden türetilmiş duyarlılık (recall), kesinlik (precision), F1 skoru ve genel ortalama hassasiyet (mAP) değerleridir. Modellerin değerlendirilmesi için temel metriklerden oluşan ve şablonu Tablo 5'te verilen karmaşıklık matrisi oluşturulmalıdır. Değerlendirme için kullanılacak her bir görselin tespit edilen durumla gerçek (etiketle önceden tanımlanan durumun) karşılaştırılarak modelin ne kadar doğru tahmin ve hatalı tahmin yaptığı belirlenmelidir. Böylece Eş. 1, Eş. 2, Eş. 3, Eş. 4 ve Eş. 5'te eşitlikleri verilmiş duyarlılık, kesinlik, F1 skoru, ortalama hassasiyet (AP) ve genel ortalama hassasiyet (mAP) metrikleri hesaplanır [49].

$$\text{Kesinlik } (p) = \frac{\text{Tahmin edilen toplam doğru pozitif sayısı}}{\text{Toplam pozitif tahmin sayısı}} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{Duyarlılık } (r) = \frac{\text{Tahmin edilen toplam doğru pozitif sayısı}}{\text{Etiketlenen toplam pozitif doğru sayısı}} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{F1 Skoru} = 2 \times \frac{(\text{Kesinlik} \times \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} = 2 \times \frac{(p \times r)}{(p + r)} \quad (3)$$

$$\text{Ortalama Hassasiyet } (AP) = \int_0^1 p(r) dr \cong \sum_{k=1}^n p(k) \cdot \Delta r(k) \quad (4)$$

Tablo 4. Hiperparametre Değerlerinin Belirlenmesi (Determination of Hyperparameter Values)

| Hiperparametre | Türkçe Karşılığı | Ablasyon Aralığı | Eğitim için Belirlenen Hiperparametreler | | |
|----------------|-----------------------|-----------------------------|--|--------------|-----------------|
| | | | YOLOv5n | YOLOv8n | SSD MobilNet V3 |
| Epoch | Epok ya da Devir | 40 - 500 | 201 | 213 | 188 |
| Batch | Yığın | 8 - 64 | 32 | 32 | 32 |
| Pretrained | Ön Eğitilmiş Kullanım | True/False | True | True | True |
| Optimizer | Optimize Sağlayıcı | SGD, Adam, AdamW ve RMSprop | Adam | Adam | RMSprop |
| Learning Rate | Öğrenme Oranı | 0,1 - 0,001 | 0,01 - 0,001 | 0,01 - 0,001 | 0,01 - 0,001 |

Tablo 5. Karmaşıklık matris şablonu (Confusion matrix template)

| | | Modelin Tahmin Ettiği Durum | |
|---|---------------------|--|---|
| | | Pozitif (Nesne algılandı) | Negatif (Nesne algılanmadı) |
| Etiketleme ile Önceden Tanımlanan Durum | Pozitif (nesne var) | Doğru Pozitif (True Positive – TP) Geçerli Durum | Yanlış Negatif (False Negative – FN) Hatalı Durum |
| | Negatif (nesne yok) | Yanlış Pozitif (False Positive – FP) Hatalı Durum | Doğru Negatif (True Negative – TN) İstenilen Durum |

$$\text{Genel Ortalama Hassasiyet (mAP)} = \frac{\sum AP}{\text{sınıf sayısı}} \quad (5)$$

Keskinlik (ρ), testin sonucunda model tarafından elde edilen toplam pozitif tahmin sayısındaki (içinde hatalı olanlarda vardır) toplam doğru pozitif (hatasız olan) sayı miktarıdır.

Duyarlılık, pozitif olarak etiketlenen toplam veri miktarındaki (ideal durum, hepsinin etiketlendiği gibi model tarafından doğru pozitif (TP) olarak algılanmasıdır) toplam doğru pozitif (hatasız olan) sayı miktarıdır.

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır. Keskinlik veya duyarlılık metriklerinden biri başarılı, diğeri başarısız olabilir. Bu durum veri kümesinde dengesizlik olduğu anlamına gelir. Bu durumu ortaya çıkarır.

Ortalama hassasiyet (AP), Güven eşiği 0 ile 1 arasında olur. Keskinlik-geri çağırma eğrisi, bir modelin güven eşiği aralığında her bir güven eşiği için kesinlik ve geri çağırma değerlerinin grafiksel bir gösterimidir. Ortalama hassasiyet ise kesinlik-geri çağırma grafiğindeki eğrinin altında kalan toplam pozitif alandır.

Genel ortalama hassasiyet (mAP), her model için sınıf sayısı kadar ortalama hassasiyet hesaplanır. Genel ortalama hassasiyet ise ortalama hassasiyetlerin toplanarak sınıf sayısına bölünmesi ile elde edilen genelleşmiş ortalamadır.

GPU kullanımında modellerin tespit hızı FPS değeri hesaplanarak değerlendirilir.

Saniyedeki Kare Sayısı (Frame Per Second - FSP), 1 saniye süre içinde yapılan tespit sayısıdır. Ortalama FSP değeri ise, bir modelin belli sayıdaki tespit sürelerinin aritmetik ortalamasının 1 saniyedeki tekrar sayısıdır.

3. Sonuçlar ve Tartışmalar (Results and Discussions)

3.1. Eğitim Performansı (Training Performance)

Eğitim aşamasında modellerin eğitim performansı her devirde tekrar ölçülerek izlenir. Böylece eğitimde hatalı bir durum veya sapmalar olduğunda eğitim bitirilerek gerekli düzenlemeler yeniden yapılır ve eğitim tekrar baştan alınır. Eğitimin performans değerleri eğitimin sağlıklı geçtiği ve eğitimin ne zaman bitirilmesi gerektiği konusunda ön bilgi sunar. Özellikle doğrulama kayıpların azalmasını durulması eğitimin doygunluğa oluştuğu konusunda fikir verir [50].


Eğitim için oluşturulan verilerin tekrar tekrar kullanılması, bir modelin eğitim verilerindeki örüntüleri aşırı derecede öğrenmesine ve bundan dolayı yeni verileri tahmin ederken daha az başarılı olmasına yol açabilir. Bu nedenle, bir modelin gerçek performansı genellikle test verileri kullanılarak değerlendirilir. Bu çalışmada kullanılan modellerin mAP/devir performans grafikleri, Şekil 2'de karşılaştırmalı olarak verilmiştir.

3.2. Test Verileri Kullanılarak Eğitim Modellerinin Performans Değerlendirmesi

(Performance Evaluation of Training Models Using Test Dat)

Eğitim aşamasında aşırı uyum ve benzer durumlar ortaya çıkmış ve yanıltıcı performans değerlerine yol açmış olabilir. Eğitim sonrası elde edilen modelin taze, kullanılmamış yeni verilerle tekrar test edilmesi gerekir. Daha önce her sınıf için 50 adet olarak hazırlanan toplam 200 adet test verisi bu amaçla eğitim modeli tarafından yeniden değerlendirilmiş ve sonuçlar Tablo 7'de listelenmiştir. Değerlendirme sonucunda 0,5 güven eşik değerinde YOLOv5n'in

ortalama 95,7, YOLOv8n'in ortalama 96,4, SSD MobileNet V3'ün ise %87,9 büyüklüğünde F1 skoru elde ettiği görülmüştür. Bu sonuçlar eğitim performansı ile elde edilen değere yakındır ve modelin yeni verilere iyi genelleme yapabildiğini ortaya çıkarmıştır.



Şekil 2. Eğitim mAP / Devir Eğrisi Grafik Çıktıları (Training mAP / Epochs Curve Graphical Outputs)

Tablo 6. Eğitimin mAP Metrik Değerleri (Training mAP Metric Values of Models)

| Model | mAP (%) |
|------------------|---------|
| YOLOv5n | %98,6 |
| YOLOv8n | %98,8 |
| SSD MobileNet V3 | %93,9 |

Ayrıca METU-ALET veri setinde ile yapılan testler de eğitimin başarılı olduğu görülmüştür [51]. Bu verilerden en karışık arka planı olan ve üstten çekilen görsellerden bir örnek Şekil 3'te gösterilmiştir. Bu örnekte sadece bir çalışanın tespiti gerçekleştirilmiştir.



Şekil 3. METU-ALET veri seti ile yapılan teste ait örnek bir görsel ve YOLOv5n ile elde edilen sonucu

(A sample image of the test with the METU-ALET dataset and the result obtained with YOLOv5n)

Tablo 7. Eğitim Modellerinin Test Verileri ile Değerlendirmesi (Evaluation of Training Models with Test Data)

| Model | Sınıf | Karışıklık Matrisi | | | | | Performans | | | | | | | | | |
|------------------|-------------|--------------------|-------------|------------|------------|-----------|------------|----|----|-----------|------------|----------|--------------------|---------------------|-------------------|--|
| | | Baret Yok | Beyaz Baret | Sarı Baret | Mavi Baret | Arka Plan | TP | FP | FN | Keskinlik | Duyarlılık | F1 Skoru | Ortalama Keskinlik | Ortalama Duyarlılık | Ortalama F1 Skoru | |
| Yolov5n | Baret Yok | 48 | 0 | 0 | 0 | 2 | 48 | 1 | 2 | 0,98 | 0,96 | 0,97 | %97,5 | %94 | %95,7 | |
| | Beyaz Baret | 1 | 47 | 0 | 0 | 2 | 47 | 4 | 3 | 0,92 | 0,94 | 0,93 | | | | |
| | Sarı Baret | 0 | 4 | 45 | 0 | 1 | 45 | 0 | 5 | 1 | 0,9 | 0,95 | | | | |
| | Mavi Baret | 0 | 0 | 0 | 48 | 2 | 48 | 0 | 2 | 1 | 0,96 | 0,98 | | | | |
| Yolov8n | Baret Yok | 48 | 0 | 0 | 0 | 2 | 48 | 1 | 2 | 0,98 | 0,96 | 0,97 | %98 | %95 | %96,4 | |
| | Beyaz Baret | 1 | 48 | 0 | 0 | 1 | 48 | 3 | 2 | 0,94 | 0,96 | 0,95 | | | | |
| | Sarı Baret | 0 | 3 | 45 | 0 | 2 | 45 | 1 | 5 | 1 | 0,9 | 0,95 | | | | |
| | Mavi Baret | 0 | 0 | 0 | 49 | 1 | 49 | 1 | 1 | 1 | 0,98 | 0,99 | | | | |
| SSD MobileNet V3 | Baret Yok | 48 | 0 | 0 | 0 | 2 | 48 | 4 | 2 | 0,92 | 0,96 | 0,94 | %89,5 | %86,4 | %87,9 | |
| | Beyaz Baret | 2 | 40 | 4 | 3 | 1 | 40 | 6 | 10 | 0,87 | 0,8 | 0,83 | | | | |
| | Sarı Baret | 1 | 4 | 41 | 2 | 2 | 41 | 5 | 9 | 0,89 | 0,82 | 0,85 | | | | |
| | Mavi Baret | 1 | 2 | 1 | 43 | 2 | 43 | 5 | 6 | 0,9 | 0,88 | 0,89 | | | | |

Tablo 8. 320x416 Piksel Kamera Çekiminde Tespit Hızları (Detection Speeds in 320x416 Pixel Camera Capture)

| Modeller | Baret Yok | Beyaz Baret | Sarı Baret | Mavi Baret | Ortalama FSP |
|------------------|-----------|-------------|------------|------------|--------------|
| Yolov5n | 1,5 ms | 2 ms | 5 ms | 5 ms | 650 |
| | 2 ms | 2 ms | 3,7 ms | 0,1 ms | |
| | 0,1 ms | 1 ms | 0,1 ms | 3 ms | |
| | 0,1 ms | 0,1 ms | 0,1 ms | 1 ms | |
| | 0,1 ms | 1 ms | 5,8 ms | 0,1 ms | |
| | 0,1 ms | 0,1 ms | 0,1 ms | 0,1 ms | |
| | 5,5 ms | 1 ms | 5,6 ms | 0,1 ms | |
| | 0,1 ms | 1,5 ms | 0,1 ms | 1 ms | |
| | 0,1 ms | 0,1 ms | 0,1 ms | 6,6 ms | |
| | 3 ms | 0,1 ms | 0,1 ms | 2,3 ms | |
| Yolov8n | 1 ms | 10,4 ms | 7,1 ms | 2 ms | 470 |
| | 0,1 ms | 0,1 ms | 0,1 ms | 0,1 ms | |
| | 0,1 ms | 3,5 ms | 0,1 ms | 0,1 ms | |
| | 1,5 ms | 4,5 ms | 1,5 ms | 4 ms | |
| | 0,1 ms | 5 ms | 0,1 ms | 0,1 ms | |
| | 5,1 ms | 0,1 ms | 0,1 ms | 0,1 ms | |
| | 6 ms | 0,1 ms | 1 ms | 0,1 ms | |
| | 0,1 ms | 0,1 ms | 0,1 ms | 0,1 ms | |
| | 0,1 ms | 0,1 ms | 1 ms | 0,1 ms | |
| | 5,5 ms | 9 ms | 5,5 ms | 9,4 ms | |
| SSD MobileNet V3 | 7 ms | 10 ms | 6 ms | 7 ms | 136 |
| | 7 ms | 6 ms | 6 ms | 13 ms | |
| | 6 ms | 6 ms | 12 ms | 12 ms | |
| | 7 ms | 5 ms | 7 ms | 6 ms | |
| | 7 ms | 7 ms | 6 ms | 5 ms | |
| | 6,5 ms | 10 ms | 8 ms | 6,5 ms | |
| | 7 ms | 8 ms | 11 ms | 5 ms | |
| | 13 ms | 7,5 ms | 6 ms | 5 ms | |
| | 7 ms | 9 ms | 6 ms | 6 ms | |
| | 7 ms | 5 ms | 6 ms | 7 ms | |

3.3. Model Tespit Hızlarının GPU Kullanarak Değerlendirmesi (Detection Speed Evaluation of Models Using GPU)

Modellerin tespit hızlarını GPU işlemcisiyle gerçek zamanlı olarak değerlendirebilmesi için kamera kullanması gereklidir. Bu çalışmada, 30 FPS değerine sahip Full HD standart bir bilgisayar kamerası

kullanılmıştır. Değerlendirme, GPU işlemcili Nvidia RTX A4000 ekran kartı ve 320x416 piksel görüntüler kullanılarak gerçekleştirilmiştir. Model tespit hızları Tablo 8'de karşılaştırılmalı olarak listelenmiştir. Değerlendirme aşamasında, hızlı hareketlerin veya düşük ışık koşullarının olduğu durumlarda, bazen tespitin anlık olarak gerçekleştirilemediği gözlenmiştir. Bu durumun nedeni,

kamera çekim hızının tespit hızına kıyasla oldukça düşük olması ve kameraların ışığı yeterince alamamasıdır. Tablo 9'da yer alan kayıta bu durumu gösteren bir örnek bulunmaktadır ve Şekil 4'te ise tespitin gerçekleşmediği o anın görüntüsü yer almaktadır. Kamera kullanarak yapılan tespitlerin daha yüksek bir başarı elde etmesi için, kamera çekim kalitesi oldukça önemlidir. Modellere uygun bir kamera kullanılmamasına rağmen tespitlerin neredeyse tamamı doğru bir şekilde gerçekleştirilmiştir. Ani hareketlerin bile tespit edildiğini gösteren birkaç örnek Şekil 5'te görülebilir.

Tablo 9. 320x416 Piksel Kamera Çekiminde Kameranın veya Çalışanın Hızlı Hareketine Bağlı Tespit Hatası
(Detection Error in 320x416 Pixel Camera Capture to Rapid Movement of Camera or Employee)

| Model | Tespit Edilen | Tespit Hızı |
|---------|----------------------|-------------|
| Yolov5n | Beyaz Baret Kullanan | 0,1 ms |
| | Beyaz Baret Kullanan | 0,1 ms |
| | Beyaz Baret Kullanan | 6,1 ms |
| | Tespit Yapılmadı | 3,5 ms |
| | Tespit Yapılmadı | 0,1 ms |
| | Tespit Yapılmadı | 5,5 ms |
| | Tespit Yapılmadı | 0,1 ms |
| | Tespit Yapılmadı | 5,4 ms |
| | Beyaz Baret Kullanan | 0,1 ms |
| | Beyaz Baret Kullanan | 0,1 ms |



Şekil 4. Hızlı Hareketlerde Tespit Hatasına Neden Olan Görüntü
(Image Causing Detection Error in Rapid Movements)



Şekil 5. Hızlı Hareketlerde Doğru Tespit Örnekleri
(Examples of Correct Detection in Rapid Movements)

4. Simgeler (Symbols)

r : Duyarlılık (Recall)
 p : Keskinlik (Precision)

4.1. Kısaltmalar (Abbreviations)

Adam : Uyarlanmış Moment Tahmini (Adaptive Moment Estimation)
AdamW : Adam Ağırlık Azalması (Adam Weight Decay)
AP : Ortalama Hassasiyet (Average Precision)
CNN : Evrişimli Sinir Ağı (Convolutional Neural Network)
FN : Yanlış Negatif (False Negative)
FP : Yanlış Pozitif (False Positive)
FPS : Saniyedeki Kare Sayısı (Frame Per Second)
GPU : Grafik İşlem Birimi (Graphics Processing Unit)
mAP : genel Ortalama Hassasiyet (mean Average Precision)
R-CNN : Bölge-Evrimsel Sinir Ağı (Region-Convolutional Neural Network)
RMSprop : Kök Ortalama Kare Yayılımı
SGD : Stokastik Gradyan İnişi (Stochastic Gradient Descent)
SSD : Tek Çerçeveli Çok Kutu Dedektörü (Single Shot MultiBox Detector)
TN : Doğru Negatif (True Negative)
TP : Doğru Pozitif (True Positive)

5. Sonuçlar (Conclusions)

Bu çalışmada, YOLOv5n, YOLOv8n ve SSD MobileNet V3 nesne tespit algoritmalarını kullanarak, güvenli çalışma ortamında riskleri hızla sınıflandırabilen modellerin geliştirilmesine odaklanılmıştır. Modeller, eğitim sürecinde ayrıca test verileri ve GPU işlemcisi kullanılarak değerlendirilmiş, YOLOv5n modelinin YOLOv8n modeliyle benzer bir performans sergilediği, her iki modelin SSD MobileNet V3 modeline göre daha yüksek doğruluk ve hız elde ettiği gözlemlenmiştir. Özellikle YOLOv5n ve YOLOv8n modellerinin, yakınlık sensörleriyle uyumlu bir şekilde çalışabilecek bir hız ulaştıkları ve insan-endüstriyel mobil robot etkileşiminde güvenliği artırmaya yönelik uygulanabilir olabileceği görülmüştür. Uygulanması durumunda, endüstriyel mobil robotlar tarafından, çalışanların risk seviyelerini belirlenebilir ve ihtiyaca göre farklı büyüklükte güvenlik önlemleri uygulanabilir.

Bu çalışmaya, çalışma ortamının analizi ve risk seviyesinin tespiti gibi endüstriyel mobil robotlarda güvenliği daha da arttıracak başka faktörler de eklenebilir. Ayrıca bu çalışma, mobil robotlarla sınırlı kalmayıp, güvenli çalışma ortamları ilgili daha geniş bir perspektif için uygulanabilir.

Teşekkür (Acknowledgement)

Bu çalışma İstanbul Gedik Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje numarası "GDK202207-09"

Kaynaklar (References)

1. Rajawat A.S., Bedi P., Goyal S.B., Shukla P.K., Zaguia A., Jain A., Khan M.M., Reformist framework for improving human security for mobile robots in industry 4.0, *Mobile Inf. Syst.*, 2021, 1-10, 2021.
2. Şimşek E., Ozyer Tumuklu G., Ozyer B., Direction and Position Reconstruction on Mobile Robots, *Balkan Journal of Electrical and Computer Engineering*, 3 (Special Issue), 196-201, 2015.
3. Fragapane G., De Koster R., Sgarbossa F., Strandhagen J.O., Planning and control of autonomous mobile robots for intralogistics: Literature review and research agenda, *Eur. J. Oper. Res.*, 294 (2), 405-426, 2021.
4. Chernousko F.L., *Locomotion Principles for Mobile Robotic Systems*, *Procedia Comput. Sci.*, 103, 613-617, 2017.
5. Belzile B., St-Onge D., Safety first: On the safe deployment of robotic systems, In *Foundations of Robotics: A Multidisciplinary Approach with Python and ROS*, 415-439, Springer Nature Singapore, 2022.
6. Junyao G., Xueshan G., Wei Z., Jianguo Z., Boyu W., Coal Mine Detect and Rescue Robot Design and Research, *IEEE International*

- Conference on Networking, Sensing and Control, Sanya, China, 780-785, 2008.
7. Topolsky D., Topolskaya I., Plaksina I., Shaburov P., Yumagulov N., Fedorov D., Zvereva E., Development of a mobile robot for mine exploration, *Processes*, 10 (5), 865, 2022.
 8. Fryman J., Updating the Industrial Robot Safety Standard, In *ISR/Robotik 2014; 41st International Symposium on Robotics*, 1-4, Munich, Germany, 2014.
 9. Chinniah Y., Robot safety: overview of risk assessment and reduction, *Advances in Robotics & Automation*, 5 (01), 1-5, 2016.
 10. Markis A., Papa M., Kaselautzke D., Rathmair M., Sattinger V., Brandstötter M., Safety of mobile robot systems in industrial applications, *Proceedings of the ARW & OAGM Workshop*, 26-31, 2019.
 11. Rezayati M., Zanni G., Zaoshi Y., Scaramuzza D., van de Venn H.W., Improving safety in physical human-robot collaboration via deep metric learning, *2022 IEEE 27th International Conference on Emerging Technologies and Factory Automation (ETFA)*, Stuttgart, Germany, 1-8, 2022.
 12. Rath S., Gupta V., Performance Comparison of YOLO Object Detection Models-An Intensive Study, <https://learnopencv.com/performance-comparison-of-yolo-models/>, Yayın tarihi Kasım 29, 2022. Erişim tarihi: August 9, 2023.
 13. Belzile B., Wanang-Siyapdjie T., Karimi S., Gomes Braga R., Iordanova I., St-Onge D., From safety standards to safe operation with mobile robotic systems deployment, *20th International Conference on Advanced Robotics (ICAR 2021)*, 2021.
 14. Zou Z., Chen K., Shi Z., Guo Y., Ye J., Object detection in 20 years: A survey, *Proc. IEEE*, 111 (3), 257-276, 2023.
 15. Girshick R., Donahue J., Darrell T., Malik J., Rich feature hierarchies for accurate object detection and semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 580-587, 2014.
 16. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.Y., Berg A.C., SSD: Single shot multibox detector, In *Computer Vision-ECCV 2016: 14th European Conference*, Amsterdam, The Netherlands, 11-14, 2016.
 17. Redmon J., Divvala S., Girshick R., Farhadi A., You only look once: Unified, real-time object detection, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788, 2016.
 18. Howard A., Sandler M., Chu G., Chen L.C., Chen B., Tan M., Adam H., Searching for mobilenetv3, *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 1314-1324, 2019.
 19. Reis D., Kupec J., Hong J., Daoudi A., Real-Time Flying Object Detection with YOLOv8, *arXiv preprint arXiv:2305.09972*, 1-10, 2023.
 20. Ban X., Liu P., Xu L., Zhao J., A lightweight model based on YOLOv8n in wheat spike detection, *2023 11th International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*, Wuhan, China, 1-6, 2023.
 21. Fang Q., Li H., Luo X., Ding L., Luo H., Rose T.M., An W., Detecting non-hardhat-use by a deep learning method from far-field surveillance videos, *Autom. Constr.*, 85, 1-9, 2018.
 22. Wu J., Cai N., Chen W., Wang H., Wang G., Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset, *Autom. Constr.*, 106, 102894, 2019.
 23. Zhang W., Yang C.F., Jiang F., Gao X.Z., Zhang X., Safety Helmet Wearing Detection Based on Image Processing and Deep Learning, *2020 International Conference on Communications, Information System and Computer Engineering (CISCE)*, Kuala Lumpur, Malaysia, 343-347, 2020.
 24. Kim D., Kong J., Lim J., Sho B., A Study on Data Collection and Object Detection using Faster R-CNN for Application to Construction Site Safety, *Journal of the Korean Society of Hazard Mitigation*, 20 (1), 119-126, 2020.
 25. Saudi M., Hakim A., Ahmad A., Saudi M., Shakir A., Image Detection Model for Construction Worker Safety Conditions using Faster R-CNN, *Int. J. Adv. Comput. Sci. Appl.*, 11, 246-250, 2020.
 26. Casuat C.D., Merencilla N.E., Reyes R.C., Sevilla R.V., Pascion C.G., Deep-Hat: An Inference Deep Learning Approach of Hard Hat Detection for Work Safety and Surveillance, *2020 IEEE 7th International Conference on Engineering Technologies and Applied Sciences (ICETAS)*, Kuala Lumpur, Malaysia, 1-4, 2020.
 27. Filatov N., Maltseva N., Bakhshiev A., Development of Hard Hat Wearing Monitoring System Using Deep Neural Networks with High Inference Speed, *2020 International Russian Automation Conference (RusAutoCon)*, Sochi, Russia, 459-463, 2020.
 28. Wang L., Xie L., Yang P., Deng Q., Du S., Xu L., Hardhat-Wearing Detection Based on a Lightweight Convolutional Neural Network with Multi-Scale Features and a Top-Down Module, *Sensors*, 20(7), 1868, 2020.
 29. Zhou F., Zhao H., Nie Z., Safety Helmet Detection Based on YOLOv5, *2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA)*, Shenyang, China, 6-11, 2021.
 30. Cengil E., İki Boyutlu Sağlık, Tarım ve İş Güvenliği İmgeleri Üzerinde Sınıflandırma ve Nesne Tespiti, *Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ*, 2022.
 31. Gallo G., Di Rienzo F., Garzelli F., Ducange P., Vallati C., A Smart System for Personal Protective Equipment Detection in Industrial Environments Based on Deep Learning at the Edge, *IEEE Access*, 10, 110862-110878, 2022.
 32. Yang X., Xie Y., Yang S., Liang P., He Y., Yang J., Research on application of object detection based on yolov5 in construction site, *2023 15th International Conference on Advanced Computational Intelligence (ICACI)*, Seoul, Korea, 1-6, 2023.
 33. Farooq M.U., Bhutto M.A., Kazi A.K., Real-Time Safety Helmet Detection Using YOLOv5 at Construction Sites, *Intell. Autom. Soft Comput.*, 36(1), 911-927, 2023.
 34. Grand View Research, *Industrial Mobile Robots Market - Global Industry Analysis, Size, Share, Growth, Trends, and Forecast 2022-2030*, 2022.
 35. Ghorpade D., Thakare A.D., Doiphode S., Obstacle detection and avoidance algorithm for autonomous mobile robot using 2D LiDAR, *2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA)*, Pune, India, 1-6, 2017.
 36. Han W., Zhang Z., Caine B., Yang B., Sprunk C., Alsharif O., Ngiam J., Vasudevan V., Shlens J., Chen Z., Streaming object detection for 3-d point clouds, *European Conference on Computer Vision (ECCV)*, 423-441, 2020.
 37. Şafak E., Barışçı N., Real-time fire and smoke detection for mobile devices using deep learning, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (4), 2179-2190, 2023.
 38. Balmik A., Barik S., Nandy A., A Robust Object Recognition Using Modified YOLOv5 Neural Network, *2023 10th International Conference on Signal Processing and Integrated Networks (SPIN)*, Noida, India, 462-467, 2023.
 39. Khalid S., Oqaibi H.M., Aqib M., Hafeez Y., Small Pests Detection in Field Crops Using Deep Learning Object Detection, *Sustainability*, 15 (8), 6815, 2023.
 40. Brownlee J., What is the Difference Between a Batch and an Epoch in a Neural Network, *Machine Learning Mastery*, 20, 1-5, 2018.
 41. Bozinovski S., Fulgosi A., The influence of pattern similarity and transfer learning upon training of a base perceptron b2, *Proceedings of Symposium Informatica*, 3, 121-126, 1976.
 42. Robbins H., Monro S., A stochastic approximation method, *Ann. Math. Stat.*, 22, 400-407, 1951.
 43. Kinga D., Adam J.B., A method for stochastic optimization, *International Conference on Learning Representations (ICLR)*, 2014.
 44. Loshchilov I., Hutter F., Decoupled weight decay regularization, *International Conference on Learning Representations (ICLR)*, 2017.
 45. Tieleman T., Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude, *COURSERA: Neural networks for machine learning*, 4 (2), 26-31, 2012.
 46. Goodfellow I., Bengio Y., Courville A., *Deep Learning*, Buzdağı Yayınları, Ankara, 2018.
 47. Prasanna S., El-Sharkawy M., Hyperparameter Optimization for Object Detection Network, *Proceedings of the Seventh International Congress on Information and Communication Technology: ICICT 2022*, London, 4, 761-776, Springer Nature Singapore, August 2022.
 48. Oyelade O.N., Ezugwu A.E., A comparative performance study of random-grid model for hyperparameters selection in detection of abnormalities in digital breast images, *Concurrency Comput. Pract. Exper.*, 34 (13), 1-23, 2022.
 49. Zhu L., Zhang J., Jia C., An Improved YOLOv5-based Method for Surface Defect Detection of Steel Plate, *China Automation Congress (CAC)*, Xiamen, China, 2233-2238, 2022.

50. Nath N.D., Behzadan A.H., Deep convolutional networks for construction object detection under different visual conditions, *Frontiers in Built Environment*, 6, 97, 2020.
51. Kurnaz F.C., Hocaođlu B., Yılmaz M.K., Sũlo İ., Kalkan S., Alet (automated labeling of equipment and tools): A dataset for tool detection and human worker safety detection, *European Conference on Computer Vision (ECCV) 2020 Workshops*, Springer International Publishing, Glasgow, UK., 12538, 371-386, 2020.

