

T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



İNSAN - ENDÜSTRİYEL MOBİL ROBOT ETKİLEŞİMİNDE YENİ BİR  
YAKLAŞIM: DERİN ÖĞRENME TABANLI KRİTER TESPİT VE ANALİZİ  
İLE GÜVENLİK ÖNLEM BOYUTU BELİRLEME

DOKTORA TEZİ

Tarık ASLAN

İş Sağlığı ve Güvenliği Anabilim Dalı  
İş Sağlığı ve Güvenliği Doktora Programı

HAZİRAN 2023

T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



İNSAN - ENDÜSTRİYEL MOBİL ROBOT ETKİLEŞİMİNDE YENİ BİR  
YAKLAŞIM: DERİN ÖĞRENME TABANLI KRİTER TESPİT VE ANALİZİ  
İLE GÜVENLİK ÖNLEM BOYUTU BELİRLEME

DOKTORA TEZİ

Tarık ASLAN  
(181215015)

İş Sağlığı ve Güvenliği Anabilim Dalı

İş Sağlığı ve Güvenliği Doktora Programı

Tez Danışmanı: Dr. Öğr. Üyesi Mustafa YAĞIMLI

HAZİRAN 2023



**T.C.**  
**İSTANBUL GEDİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ**

**Doktora Tez Onay Belgesi**

Enstitümüz, İş Sağlığı ve Güvenliği Doktora Programı (181215015) numaralı öğrencisi Tarık Aslan'ın “İnsan - Endüstriyel Mobil Robot Etkileşiminde Yeni bir Yaklaşım: Derin Öğrenme Tabanlı Kriter Tespit ve Analizi ile Güvenlik Önlem Boyutu Belirleme” adlı tez çalışması Enstitümüz Yönetim Kurulunun 23/06/2023 tarihinde oluşturduğu jüri tarafından ***Oy Birliği*** ile ***Doktora Tezi*** olarak ***Kabul*** edilmiştir.

**Öğretim Üyesi Adı Soyadı**

**Tez Savunma Tarihi:** 23.06.2023

- 1) Tez Danışmanı:** Dr. Öğretim Üyesi Mustafa YAĞIMLI
- 2) Jüri Üyesi:** Prof. Dr. Mustafa Caner AKÜNER
- 3) Jüri Üyesi:** Dr. Öğretim Üyesi Aytaç Uğur YERDEN
- 4) Jüri Üyesi:** Prof. Dr. Bahaddin SİNSOYSAL
- 5) Jüri Üyesi:** Dr. Öğretim Üyesi Serap TEPE

## YEMİN METNİ


Doktora tezi olarak sunduđum “İnsan - Endüstriyel Mobil Robot Etkileşiminde Yeni bir Yaklaşım: Derin Öğrenme Tabanlı Kriter Tespit ve Analizi ile Güvenlik Önlem Boyutu Belirleme” adlı tezin, proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuđunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (12/06/2023)

Tarık ASLAN



*Daha çok güneşe, daha çok ışığa ve daha güzel yaşamaya...*

*Sevgiye, daha çok sevgiye ve **Mor Salkım Çiçeğine**...*



## ÖNSÖZ

Dr. Öğr. Üyesi Mustafa YAĞIMLI'ya, doktora programını seçmemdeki katkısı, doktora sürecinde verdiği destek ve danışman hocam olduğu için MÜTEŞEKKİRİM.

Prof. Dr. M. Caner AKÜNER'e, Marmara Üniversitesi Mekatronik Mühendisliği Yüksek Lisans tez çalışmamda danışman hocam olduğu, yüksek lisans eğitimim tamamlandıktan sonra da beni yalnız bırakmadığı, doktora sürecim boyunca da bana yol gösterdiği için MİNNETTARIM. Bir eğitici olarak kendisini her zaman örnek aldığımı tüm içtenliğimle ifade etmek isterim.

Dr. Öğr. Üyesi Aytaç Uğur YERDEN'e doktora çalışmalarımın başında bana yol gösterdiği, doğru kaynaklara yönlendirdiği ve desteğini hiç esirgemediği için TEŞEKKÜR EDERİM.

**Haziran 2023**

**Tarık ASLAN**

(Akademisyen)

## İÇİNDEKİLER

### Sayfa

ÖNSÖZ.....	v
İÇİNDEKİLER .....	vi
KISALTMALAR .....	viii
ÇİZELGE LİSTESİ.....	ix
ŞEKİL LİSTESİ.....	x
ÖZET.....	xii
ABSTRACT .....	xiv
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1 Tezin Konusu .....	1
1.2 Tezin Amacı .....	3
1.3 Literatür Araştırması .....	4
1.3.1 Mobil robot gelişimi .....	4
1.3.2 Derin öğrenmenin gelişimi .....	6
1.3.2.1 Geleneksel nesne algılama (2014 öncesi) dönemi .....	6
1.3.2.2 Derin öğrenmeye dayalı nesne algılama dönemi .....	7
1.3.3 Derin öğrenmenin mobil robot güvenliğinde kullanımı .....	10
1.3.4 Derin öğrenmenin iş sağlığı ve güvenliğinde kullanımı.....	11
1.4 Hipotez .....	13
1.5 Literatüre Katkısı.....	13
<b>2. GENEL BİLGİLER.....</b>	<b>15</b>
2.1 Derin Öğrenme .....	15
2.1.1 Gözetimli öğrenme .....	17
2.1.2 Gözetimsiz öğrenme .....	18
2.1.3 Yarı gözetimli öğrenme .....	18
2.1.4 Takviyeli öğrenme .....	18
2.2 Yapay Sinir Ağları ve Mimarileri .....	19
2.2.1 Tekrarlayan sinir ağları.....	22
2.2.2 Derin inanç ağları .....	23
2.2.3 Çekişmeli üretken ağları .....	23
2.2.4 Konvolüsyonel sinir ağları .....	24
2.2.4.1 Tek çerçeve tabanlı algoritmalar.....	25
2.2.4.2 Bölge tabanlı algoritmalar .....	27
2.3 Endüstriyel Mobil Robotlar ve Güvenlik .....	28
2.3.1 Mobil robotlar için güvenlik standartları.....	32
<b>3. MATERYAL ve YÖNTEM.....</b>	<b>34</b>
3.1 Güvenlik Önlem Boyutunu Belirleyen Kriterler .....	34
3.2 Model Oluşturma.....	34
3.2.1 Veri seti hazırlama ve ayırma .....	35
3.2.1.1 Eğitim veri seti.....	37
3.2.1.2 Doğrulama veri seti.....	37
3.2.1.3 Test veri seti.....	38

3.2.2 Görüntü ölçekleme .....	38
3.2.3 Etiketleme .....	38
3.2.4 Hiper-parametreler.....	40
3.3 Model Performans Ölçüm Kriterleri .....	42
<b>4. ARAŞTIRMA SONUÇLARI .....</b>	<b>47</b>
4.1 Eğitim Sürecinde Modeli Değerlendirme .....	47
4.1.1 Kayıp fonksiyonları değerlendirme .....	47
4.1.2 Model metriklerini değerlendirilme.....	50
4.2 Eğitilmiş Modeli Değerlendirme.....	59
4.3 GPU Üzerinden Değerlendirme .....	62
<b>5. TARTIŞMA .....</b>	<b>69</b>
5.1 Hatalı Kriter Algılamının İş Sağlığı ve Güvenliği Açısından Etkisi .....	69
5.1.1 Eğitimin ön hazırlık çalışmalarındaki eksiklikler.....	70
5.1.2 DSA mimarisine ait zayıflıklar .....	70
5.1.3 Gerçek hayatta karşılaşılan değişkenlikler ve karmaşık koşullar .....	71
5.2 Mobil Robotlarda Güvenlik Önlemleri İçin Derin Öğrenme Kullanımı.....	73
<b>6. SONUÇ VE ÖNERİLER.....</b>	<b>76</b>
<b>KAYNAKLAR .....</b>	<b>78</b>
<b>ÖZGEÇMİŞ.....</b>	<b>86</b>

## KISALTMALAR

<b>AP</b>	: Average Precision (Ortalama Hassasiyet)
<b>Box_loss</b>	: Bounding Box Loss (Sınırlama Kutusu Kaybı)
<b>Cls_loss</b>	: Classification Loss (Sınıflama Kaybı)
<b>ÇÜA</b>	: Çekişmeli Üretken Ağlar (Generative Adversarial Networks)
<b>Dfl_loss</b>	: Distribution Focus Loss (Dağılım Odak Kaybı)
<b>DİA</b>	: Derin İnanç Ağları
<b>DSA</b>	: Derin Sinir Ağları (Deep Neural Networks)
<b>Fast R-CNN</b>	: (Fast Region-based Convolutional Neural Networks (Hızlı Bölge Tabanlı Konvolüsyonel Sinir Ağları))
<b>Faster R-CNN</b>	: (Faster Region-based Convolutional Neural Networks (Daha Hızlı Bölge Tabanlı Konvolüsyonel Sinir Ağları))
<b>FN</b>	: False Negative (Yanlış Negatif)
<b>FP</b>	: False Positive (Yanlış Pozitif)
<b>FPS</b>	: Frame Per Second (Saniyedeki Kare Sayısı)
<b>GPU</b>	: Graphics Processing Unit (Grafik İşlem Birimi)
<b>HOG</b>	: Histogram of Oriented Gradients (Yönlendirilmiş Gradyan Histogramı)
<b>KBM</b>	: Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines)
<b>KKD</b>	: Kişisel Koruyucu Donanım
<b>KSA</b>	: Konvolüsyonel Sinir Ağları (Convolutional Neural Network)
<b>LIDAR</b>	: Laser Imaging Detection And Ranging (Lazer Görüntüleme Algılama ve Uzaklık Ölçümü)
<b>mAP</b>	: Mean Average Precision (Genel Ortalama Hassasiyet)
<b>NASA</b>	: National Aeronautics And Space Administration (Ulusal Havacılık ve Uzay Dairesi)
<b>R-CNN</b>	: Region-based Convolutional Neural Networks (Bölge Tabanlı Konvolüsyonel Sinir Ağları)
<b>RPN</b>	: Region Proposal Network (Bölge Öneri Ağı)
<b>SSD</b>	: Single Shot MultiBox Detector (Tek Atış Kutu Algılama)
<b>TN</b>	: True Negative (Doğru Negatif)
<b>TP</b>	: True Positive (Doğru Pozitif)
<b>TSA</b>	: Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
<b>YOLO</b>	: You Only Look Once (Sadece Bir Kez Bak)
<b>YSA</b>	: Yapay Sinir Ağları

## ÇİZELGE LİSTESİ

	<u>Sayfa</u>
<b>Çizelge 1.1:</b> Mobil Robot Gelişiminin Kilometre Taşları.....	5
<b>Çizelge 1.2:</b> KKD Tespiti İle İlgili Yapılan Çalışmalar .....	12
<b>Çizelge 2.1:</b> YOLO SSD Nesne Algılama Algoritmalarının Genel Karşılaştırması.....	27
<b>Çizelge 2.2:</b> Endüstriyel Devrimlerin Karşılaştırılması.....	29
<b>Çizelge 2.3:</b> Endüstri 3.0'den Endüstri 4.0'e Geçerken Değişen Üretim Modeli ve Risk Farklılıkları .....	29
<b>Çizelge 2.4:</b> Robotlarda Güvenlik Standartları.....	33
<b>Çizelge 3.1:</b> Senaryo 1 Güvenlik Önlemi Almak İçin Kriterler .....	34
<b>Çizelge 3.2:</b> Senaryo 2 Güvenlik Önlemi Almak İçin Kriterler .....	34
<b>Çizelge 3.3:</b> Nesne Tespitinde Kullanılan En Yaygın Algoritma Versiyonlarının Karşılaştırması.....	35
<b>Çizelge 3.4:</b> Model A Veri Seti İstatistikleri .....	36
<b>Çizelge 3.5:</b> Model B Veri Seti İstatistikleri .....	37
<b>Çizelge 3.6:</b> Model A ve Model B Eğitimde Kullanılan Hiper-parametre Değerleri	42
<b>Çizelge 3.7:</b> Karmaşıklık Matris Şablonu.....	43
<b>Çizelge 3.8:</b> Örnek: Beyaz Renk Koruyucu Ekipman Kullanımının Test Edilmesi..	43
<b>Çizelge 3.9:</b> CPU ile GPU Karşılaştırması .....	45
<b>Çizelge 3.10:</b> Uygulamada Kullanılacak Bilgisayarın Teknik Özellikleri .....	46
<b>Çizelge 4.1:</b> Eğitim Modellerinin Sonuçları ve Karşılaştırması.....	59

## ŞEKİL LİSTESİ

### Sayfa

Şekil 2.1: Derin Öğrenmenin Yapay Zeka İçindeki Konumu .....	15
Şekil 2.2: Yapay Bir Sinir Ağına Kıyasla Biyolojik Bir Nöron: (a) Biyolojik Nöron; (b) Sinir Ağlarının Temel Yapısı; (c) Yapay Nöron (Perceptron) .....	22
Şekil 2.3: Konvolüsyonel Sinir Ağı Modeli .....	24
Şekil 2.4: Endüstriyel Robotların Kafes İçinde Çalışması .....	31
Şekil 2.5: İnsan Robot Etkileşimi .....	32
Şekil 3.1: Model A Veri Setinde Yer Alan Görüntü Örnekleri .....	36
Şekil 3.2: Model B Veri Setinde Yer Alan Görüntü Örnekleri .....	37
Şekil 3.3: Model A a: Sınırlama Kutusunun Belirlenmesi, b: Sınıf ve Koordinat Bilgisinin Txt Uzantılı Dosyaya Kaydedilme Biçimi .....	39
Şekil 3.4: Model B a: Sınırlama Kutusunun Belirlenmesi, b: Sınıf ve Koordinat Bilgisinin Txt Uzantılı Dosyaya Kaydedilme Biçimi .....	39
Şekil 3.5: Model B sınıfı için a: Doğru Pozitif (TP), b: Yanlış Negatif (FN), c: Yanlış Pozitif (FP) .....	43
Şekil 3.6: Nvidia RTX A4000 16GB Modül .....	45
Şekil 4.1: Model A Eğitimi Sınırlama Kutusu Kaybı/Devir Eğrisi Grafiği .....	48
Şekil 4.2: Model B Eğitimi Sınırlama Kutusu Kaybı/Devir Eğrisi Grafiği .....	48
Şekil 4.3: Model A Eğitimi Sınıflandırma Kaybı/Devir Eğrisi Grafiği .....	49
Şekil 4.4: Model B Eğitimi Sınıflandırma Kaybı/Devir Eğrisi Grafiği .....	49
Şekil 4.5: Model A Eğitimi Dağılım Odak Kaybı/Devir Eğrisi Grafiği .....	50
Şekil 4.6: Model B Eğitimi Dağılım Odak Kaybı/Devir Eğrisi Grafiği .....	50
Şekil 4.7: Model A YOLOv5n Versiyonunun Eğitimi Karışıklık Matrisi .....	51
Şekil 4.8: Model A YOLOv8n Versiyonunun Eğitimi Karışıklık Matrisi .....	52
Şekil 4.9: Model B YOLOv5n Versiyonunun Eğitimi Karışıklık Matrisi .....	52
Şekil 4.10: Model B YOLOv8n Versiyonunun Eğitimi Karışıklık Matrisi .....	53
Şekil 4.11: Model A Eğitimi Kesinlik – Devir Eğrisi Grafiği .....	54
Şekil 4.12: Model B Eğitimi Kesinlik – Devir Eğrisi Grafiği .....	54
Şekil 4.13: Model A Eğitimi Duyarlılık – Devir Eğrisi Grafiği .....	55
Şekil 4.14: Model B Eğitimi Duyarlılık – Devir Eğrisi Grafiği .....	55
Şekil 4.15: Model A Eğitimi Duyarlılık - Kesinlik Eğrisi Grafiği .....	56
Şekil 4.16: Model B Eğitimi Duyarlılık - Kesinlik Eğrisi Grafiği .....	56
Şekil 4.17: Model A Eğitimi 0.5 Güven Eşiğinde Map – Devir Eğrisi Grafiği .....	57
Şekil 4.18: Model B Eğitimi 0.5 Güven Eşiğinde Map – Devir Eğrisi Grafiği .....	57
Şekil 4.19: Model A Eğitimi 0.5 – 0.95 Güven Eşiğinde Map – Devir Eğrisi Grafiği .....	58
Şekil 4.20: Model B Eğitimi 0.5 – 0.95 Güven Eşiğinde Map – Devir Eğrisi Grafiği .....	58
Şekil 4.21: Eğitilmiş Model A YOLOv5n Versiyonunun Karışıklık Matrisi .....	60
Şekil 4.22: Eğitilmiş Model A YOLOv5n Versiyonunun Değerlendirmesi .....	60
Şekil 4.23: Eğitilmiş Model A YOLOv8n Versiyonunun Karışıklık Matrisi .....	60
Şekil 4.24: Eğitilmiş Model A YOLOv8n Versiyonunun Değerlendirmesi .....	61

<b>Şekil 4.25:</b> Eğitilmiş Model B YOLOv5n Versiyonun Karışıklık Matrisi .....	61
<b>Şekil 4.26:</b> Eğitilmiş Model B YOLOv5n Versiyonun Değerlendirmesi .....	61
<b>Şekil 4.27:</b> Eğitilmiş Model B YOLOv8n Versiyonun Karışıklık Matrisi .....	62
<b>Şekil 4.28:</b> Eğitilmiş Model B YOLOv8n Versiyonun Değerlendirmesi .....	62
<b>Şekil 4.29:</b> Model A YOLOv5n Tüm Sınıflar için Uygulaması .....	63
<b>Şekil 4.30:</b> Model A YOLOv8n Tüm Sınıflar için Uygulaması .....	64
<b>Şekil 4.31:</b> Model B YOLOv5n Tüm Sınıflar için Uygulaması .....	65
<b>Şekil 4.32:</b> Model B YOLOv8n Tüm Sınıflar için Uygulaması .....	66
<b>Şekil 4.33:</b> Hareketlerde Kriterin Anlık Tespit Edilememesi .....	67
<b>Şekil 4.34:</b> Hareketli Durumda Tespit Edilemeyen Karelerden Bir Örnek .....	67
<b>Şekil 4.35:</b> Hareketlilik Durumunda Doğru Tespit Yapılan Örnekler.....	68



# **İNSAN - ENDÜSTRİYEL MOBİL ROBOT ETKİLEŞİMİNDE YENİ BİR YAKLAŞIM: DERİN ÖĞRENME TABANLI KRİTER TESPİT VE ANALİZİ İLE GÜVENLİK ÖNLEM BOYUTU BELİRLEME**

## **ÖZET**

İnsan-robot etkileşiminde, standartlaşan temel güvenlik önlemleri; güvenlik dereceli izlenen durdurma, elle yönlendirme, hız/mesafe izleme ve güç/kuvvet sınırlaması olmak üzere, dört ana teknik ile tanımlanmaktadır. Bu teknikler genellikle yakınlık sensörlerinden elde edilen verilere dayanarak, mobil robotlar tarafından etkileşimde olduğu insanlara, yetki, davranış veya güvenlik kriterini değerlendirmeden, standart veya tek boyutlu olarak uygulanır. İş sağlığı ve güvenliğinde kaynakların doğru kullanılması, aşırı güvenlik önlemlerin çalışma hızını düşürmemesi ve verimliliğin sağlanması için güvenlik önlemleri tek düze uygulanmak yerine derecelendirilir. Risk yüksekse önlemler daha katı ve sıkı, düşükse daha esnek veya hafif olabilir. Aynı prensibin insan-mobil robot etkileşiminde de geçerli olması beklenir ancak mobil robotların insanlarla etkileşiminde uygulanacak güvenlik önlemleri, etkileşimde bulunduğu çalışan türüne veya yetkisine göre değişmemektedir. Bu durumda belirlenecek güvenlik önlemi katı olması durumunda aşırı güvenlik önlemleri mobil robotların verimliliğini düşürecek, esnek ya da hafif olması durumunda ise kaza riskini artıracaktır. Mobil robotun değişen durumlara göre kriter belirlemesi gerekir. Belirlediği kriterlere göre gerektiğinde katı güvenlik önlemlerinin sağlanması ile güvenliğe odaklanmalı, gerektiğinde esnek ya da hafif güvenlik önlemlerine geçerek verimi arttırabilmelidir. Kısacası, bu çalışmanın amacı; insan-mobil robot etkileşiminde hem güvenliği hem de verimliliği daha üst seviyeye taşıyacak yeni bir yaklaşım geliştirmektir.

Günümüzde bu yaklaşımın uygulanmamasının ve insan mobil robot etkileşiminde, standart tek boyutlu önlemlerin uygulanmasının birkaç sebebi bulunmaktadır. Bu sebeplerinden biri, otonom mobil robotların çalışanlara zarar verme potansiyelinin tüm boyutları ile keşfedilememiş olması, dolayısıyla hala güvenlik konusunda esnetilebilir veya hafifletilebilir bir güven verememesidir. Bu da kriter ve koşullardan bağımsız güvenlik önlemlerinin standart ve katı bir şekilde uygulanmasını getirmiştir. Diğer bir sebep ise teknolojik olarak mobil robotların insanlarla ilgili kriterleri tespit etmesinin masraflı, doğruluk seviyesinin düşük ve güvenlik durumu için kriter belirleme hızının yavaş kalmasıydı. Ancak mobil robotların daha fazla üretime girmesi, literatürde daha fazla insan robot iş birliğine, yakın çalışmasına, hatta fiziksel temas kurmasına dair çalışmaların görülmesi, derin öğrenme teknolojisindeki gelişmeler, nesne tespitinde yüksek doğruluk seviyelerine ulaşılması, GPU'lu sistemlerin kullanılması ile nesne tespit sürelerini önemli ölçüde kısaltılması, insan mobil robot etkileşimindeki katı güvenlik önlemlerinin yeniden değerlendirilmesi gerektiğini göstermektedir.

İnsan mobil robotun etkileşimde tespit edebilecek kriterlerin başında kişisel koruyucu ekipman kullanımı ve yetki seviyesi gelmektedir. Bu çalışmada, bu iki kriter ön planda tutularak, YOLO ailesinin en hızlı çıkarım yapabilen modellerinden olan YOLOv5n ve en son sürümü olan YOLOv8n kullanılmıştır. Özellikle

yetkililerin belirlenmesinde hangi yaklaşımın daha etkili olabileceğini belirlemek amacıyla iki farklı veri seti üzerinde iki ayrı model oluşturulmuştur. Veri setine bağlı olarak modellerden biri çalışanların baret renginden, diğeri ise giydikleri yelek tipinden yetkili kişiyi tespit etmeyi hedeflenmiştir. Böylece iki ayrı model ve iki ayrı veri seti kullanılarak toplam dört model çalışmada karşılaştırılarak hangi modelin daha geçerli olduğu incelenmiştir.

Eğitimin sonucunda, tüm modellerin genel ortalama hassasiyeti (mAP'si) metrik değerinin %98'dan daha yüksek olduğu ve GPU kullanımıyla 500 FPS daha hızlı çıkarım yaptıkları görülmüştür. Bu sonuç derin öğrenmenin insan- mobil robot etkileşiminde güvenlik önlemi uygulanmadan önce kriter tespit edilebileceğini böylece insan-mobil robot etkileşiminin daha güvenli hale getirilebileceğini ve aynı zamanda mobil robotların daha verimli çalışabileceğini göstermektedir.

**Anahtar Kelimeler:** *Mobil Robot, İnsan Robot Etkileşimi, Derin Öğrenme, Kriter Tespiti, Güvenlik Önlemi Derecelendirme*



# **IN HUMAN - INDUSTRIAL MOBILE ROBOT INTERACTION A NEW APPROACH: SAFETY MEASURE SIZE DETERMINATION WITH DEEP LEARNING BASED CRITERIA DETECTION AND ANALYSIS**

## **ABSTRACT**

In human-robot interaction, the main standardized safety measures are defined by four main techniques: safety-rated monitored stop, hand-guiding, speed and separation monitoring and power and force limiting. These techniques are usually applied in a standard or one-dimensional manner based on the data obtained from proximity sensors, without evaluating the authority, behavior, or safety criteria of people interacting with mobile robots. In occupational health and safety, safety measures are graded instead of being applied uniformly to ensure that resources are used correctly, and excessive safety measures do not reduce the speed of work and ensure efficiency. If the risk is high, the measures can be stricter, and if the risk is low, they can be more flexible or lighter. The same principle is expected to be applied in human-mobile robot interaction, but the safety measures to be applied in the interaction of mobile robots with humans do not change according to the type or authority of the employee they interact with. In this case, if the safety measure to be determined is strict, excessive safety measures will reduce the efficiency of mobile robots, and if it is flexible or lightweight, it will increase the risk of accidents. The mobile robot must set criteria according to changing situations. According to the set criteria, it should focus on safety by providing strict safety measures when necessary, and it should be able to increase efficiency by switching to flexible or light safety measures when necessary. In short, this study aims to develop a new approach that will maximize both safety and efficiency in human-mobile robot interaction.

Currently, there are several reasons why this approach is not practiced, and standard one-dimensional measures are applied in human-mobile robot interactions. One of these reasons is that the potential of autonomous mobile robots to harm workers has not been fully explored, and thus, they still cannot provide flexible or mitigated confidence in safety. This has led to the standardized and rigid application of safety measures, regardless of the criteria and conditions. Another reason was that technologically, mobile robots' detection of human-related criteria was costly, the level of accuracy was low, and the speed of determining the criteria for safety status was slow. However, the introduction of mobile robots into more production, more studies in the literature on human-robot cooperation, close work, and even physical contact, advances in deep learning technology, achieving high levels of accuracy in object detection, and significantly shortening object detection times with the use of GPU systems, all of which show that strict security measures in human-mobile robot interaction need to be re-evaluated.

The use of personal protective equipment and the level of authorization are the main criteria that can determine human-mobile robot interactions. In this study, YOLOv5n, one of the fastest inference models in the YOLO family, and YOLOv8n, the latest version, were used with these two criteria in mind. Two different models were created on two different datasets to determine which approach would be more

effective in determining the authorities. Depending on the dataset, one of the models aims to identify the authorized person from the color of the hard hat of the employees and the other from the type of vest they wear. Thus, a total of four models were compared in the study using two different models and two different datasets, and we examined which model was more valid.

At the end of the training, it was observed that the overall average precision (mAP) metric value of all models was higher than 98%, and they inferred 500 FPS faster with the use of the GPU. This result shows that deep learning can detect criteria in human-mobile robot interaction before applying security measures, thus making human-mobile robot interaction safer and moreover, mobile robots can work more efficiently.

**Keywords:** *Mobile Robot, Human Robot Interaction, Deep Learning, Criteria Detection, Safety Measure Rating*



# 1. GİRİŞ

## 1.1 Tezin Konusu

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. Konum değişikliği için kılavuzlu, programlanmış, uzaktan kumandalı, hat takipli veya otonom olabilirler. 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) ve benzeri teknolojiler kullanırlar (Rajawat ve diğerleri, 2021). Hareket sistemlerine göre mobil robotlar kara tabanlı (tekerlekli), yürüyen (bacaklı), paletli ve pervaneli şeklinde birkaç ana kategoride sınıflandırılabilir (Chernousko, 2017).

Mobil robotların endüstriyel alanda kullanımı gelişme aşamasında olup günümüzde daha sık depolama, çapraz yükleme, terminaller ve hastaneler gibi iç lojistikte otomatik yönlendirmeli araçlar (AGV) ve otonom mobil robotlar (AMR) olarak kullanılmaktadır (Fragapane ve diğerleri, 2021). Bunlarla birlikte sınırlı bir alanda, önceden tanımlanmış bir işlem ya da görevi yüksek hassasiyet ve kararlılıkla gerçekleştirmek için özelleştirilmiş mobil robotlar da vardır. Bu robotlar arama ve kurtarma, maden arama ve benzeri görevler için özelleştirilmiş olabilir. (Gao ve diğerleri, 2008), (Şimşek, Özyer & Özyer 2015), (Topolsky ve diğerleri 2022). Genel anlamı ile mobil robotların görev şekli tehlikeli/çok tehlikeli, çalışma alanı da karmaşık olabilmektedir. Mobil robotların insanlarla etkileşim hala tamamen güvenli değildir ve 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 (Rajawat ve diğerleri, 2021), (Fryman, 2014), (Chinniah, 2016).

*Güvenlik dereceli izlenen durdurma:* Beklenmedik veya olağan dışı bir durumda devreye giren otonom durumda sistemidir. 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 olacağından 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 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.

Mobil robotlar, genellikle yakınlık ve haritalandırma sensörlerindeki verileri işleyerek standartlaşan güvenlik önlemleri aynı düzeyde uygular. Örneğin; bu güvenlik önlemi hız/mesafe izleme ise, hız/mesafe büyüklüğü koşul ve durumlardan bağımsız aynı şekilde uygulanır. Güvenlik önlemlerinin aynı düzeyde değil derecelendirilerek uygulanabilmesi için güvenlik derecesini belirleyecek kriterlerin tespit edilmesi gerekir. Bu kriterleri belirlenmesinin en yaygın ve etkili yöntem ise derin öğrenmeye dayalı nesne algılama algoritmalarıdır. Bununla birlikte nesne algılama algoritmaların da bazı zayıflıkları vardı. Bunlar, doğrulama performansının hala yeterli seviyede olmaması, diğer bir zayıflık ise çıkarım süresinin yakınlık sensörlerine göre oldukça yavaş kalmasıydı.

Ancak nesne algılama algoritmalarındaki gelişmeler doğrulama performans sınırlarını zorlamaya başladı. Nesne algılama mimarileri, çıkarım sürelerini hızlandırmak için optimize edildi ve GPU aygıtının kullanımıyla çıkarım süreleri mikro saniyelere kadar düştü.

Bu durum, insan mobil robot etkileşimde uygulanan güvenlik önlemlerinin yeniden gözden geçirilmesi için bir fırsat sunmaktadır. Yüksek doğruluk seviyelerine ulaşan nesne algılama teknolojisi ve hızlı çıkarım süreleri, mobil robotlarda yakınlık sensörleriyle birlikte kullanılabileceği umudunu vermektedir.

Özetle, nesne algılama teknolojisi mobil robotlar için insan etkileşimi sırasında güvenlik önlemlerini belirleyerek önemli bir rol oynayabilir. İnsan algılama yeteneği sayesinde mobil robotlar, insanın kişisel koruyucu donanım kullanım durumunu ve yetkili seviyesini tespit edebilir, böylece uygulayacağı güvenlik önleminin türünü veya boyutunu belirleyebilir.

Bu durum mobil robotun daha güvenli çalışmasını sağlayacağı gibi daha verimli çalışmasını da sağlar. Çalışma alanındaki veya etkileşimde olduğu insanın statüsünü, rolünü, yaklaşımı, güvenlik önlemlerini alıp almadığını tespit ederek daha katı güvenlik önlemleri veya daha hafif güvenlik önlemlerine karar verebilir. Bu durumun, daha katı güvenlik önlemlerinde güvenliğe, daha hafif güvenlik önlemlerinde verime etkisi olmuş olur. Hafif güvenlik önlemleri ile daha az kesinti ve sınırlama olacağından daha verimli çalışması sağlanabilir (Rezayati ve diğerleri, 2023). Bu şekilde, tüm çalışanlar için aşırı güvenlik kısıtlamaları olan insan-robot etkileşimi (El-Shamouty ve diğerleri, 2020) için yeni bir yaklaşım sağlanabilir.

## **1.2 Tezin Amacı**

İnsan mobil robot etkileşiminde güvenlik önlemlerinin belirlenmesi ve derecelendirilmesi mobil robotlar tarafından gerçekleştirilmekte fakat bu önlemler alınırken değişen koşullar dikkate alınmamakta ve her durum için aynı güvenlik önlemleri uygulanmaktadır. Örneğin; bu güvenlik önlemi hız/mesafe izleme ise, hız/mesafe büyüklüğü her durumda aynı şekilde uygulanır. Güvenlik önlemlerinin derecelendirilerek uygulanabilmesi, ancak derecelendirme için gerekli olan kriterlerin tespit edilmesi ile sağlanabilir. Robot insan etkileşimde çalışanlarla ilgili birçok kriter derin öğrenme ile tespit edilebilir. Böylece mobil robotlar güvenlik önlemlerinin türüne veya boyutuna karar verebilir.

Bu çalışmanın temel amacı mobil robotların insanlarla etkileşim sırasında güvenlik önlemlerinin boyutunu belirlemek için kullanabilecekleri kriterleri tespit edecek bir model oluşturmaktır. Oluşturulacak bu model hem yüksek doğruluk sağlamalı hem de çok hızlı tespit yapabilmelidir. Böylece insan mobil robot etkileşiminde derin öğrenme tekniklerini kullanarak mobil robotların standart, tek düze güvenlik önlemleri alması yerine kriterlere dayalı etkili ve verimli güvenlik önlem boyutunu belirleyebilecektir. Bu işlem bir tür mobil robotun insanlarla etkileşime geçmeden önce risk tespit ve analiz yapması ve riskin boyutuna göre önlem şeklini belirlemesidir. Bu amaç doğrultusunda hedefler;

- Güvenlik önlemi belirlemek için kriter tespiti oluşturma,
- Eğitim verilerini toplama,
- Eğitim modeli oluşturma,
- Model performans ölçüm kriterlerini belirleme,
- Uygulama ve araştırma sonuçlarını elde etme,

şeklinde ifade edilebilir.

### **1.3 Literatür Araştırması**

Bu çalışmada literatür üç kısımda incelenmiştir. Birinci kısımda mobil robotların gelişimi, ikinci kısımda derin öğrenmenin gelişimi ve son kısımda ise derin öğrenmenin iş sağlığı ve güvenliğinde kullanımına bakılmıştır.

#### **1.3.1 Mobil robot gelişimi**

Endüstride kullanılmak için üretilmiş ve programlanabilir ilk robot 1954 yılında tasarlandı (Devol, 1956) ve 1961 yılında endüstride kullanılma fırsatı buldu (Dhillon, Fashandi & Liu, 2002). Eylemleri hakkında muhakeme yapabilen ilk mobil robotlardan biri olan Shakey'in 1966 yılında tasarım ve gelişim süreci başladı (Nilsson, 1984), 1970-1999 yılları arasında mobil robotlar ay ve gezegen keşiflerinin yanı sıra tehlikeli alanlara girme, kurtarma, deneysel amaçlı araştırma ve geliştirme faaliyetleri için üretildi ve geliştirildi (Raj & Kos, 2022). Bu ilk nesil robotların insanlarla etkileşimleri ya sınırlıydı ya da hiç yoktu ve uygulanan güvenlik önlemleri ağırlıklı olarak robotların kendilerini korumasına yönelikti.

Eğlence amaçlı tasarlanmış, boyutu ve gücü sınırlandırılmış, insanlar için zararsız veya sınırlı zarar veren ve bu nedenle güvenli kabul edilen Aibo türü 4 ayaklı mobil robotlar milenyumun başlarında geliştirildi ve ticarileştirildi (Raj & Kos, 2022). Aibo'nun piyasaya sürülmesinin hemen ardından, Honda tarafından insanımsı (humanoid) olarak adlandırılan gelişmiş robotlar tanıtıldı. Asimo adı verilen bu robot insanları tanıyabiliyor, yürüyebiliyor, merdiven çıkabiliyor, hatta dans edebiliyordu (Mobile Robot, 2023).

Daha sonra, ofis ortamlarında basit yardım sağlama veya belgeleri taşıma; tarımda tohum ekme; ev, otel, terminal ve hastane gibi yerlerde temizlik görevlerini yerine getirme yeteneğine sahip otonom ya da akıllı mobil robotlar geliştirildi. Boston

Dynamics araçların giremediği engebeli arazide yük taşıma kabiliyeti olan robot tasarladı (Raj & Kos, 2022), (Mobile Robot, 2023).

Endüstriyel alanda ise ancak 2010'lardan sonra otonom mobil robotlar daha fazla görülmeye başlandı. Bu öncü mobil robotlar madenler, açık denizde bulunan petrol ve gaz tesislerinde, depolama ve lojistik operasyonlarında kullanım alanı buldu. Özellikle Amazon, büyük ve karmaşık depolarda insanlarla aynı ortamda çalışabilen otomatik yönlendirmeli ve otonom mobil robotları geliştirdi ve kullandı (Youssef ve diğerleri, 2022). Çizelge 1.1'de mobil robot gelişiminin kilometre taşları yer almaktadır.

**Çizelge 1.1: Mobil Robot Gelişiminin Kilometre Taşları**

Yıl	Robot Adı	Önemi	Açıklama	Tasarımcısı
1954	Unimate	Endüstride görev alan ilk programlanabilir robot	George Devol tarafından 1954 yılında icat edilen ilk programlanabilir robot, General Motors tarafından 1961 yılında satın alındı ve hemen ardından otomobil montaj hatında kullanılarak fabrikalarda üretim süreçlerine otomasyon getirerek devrim niteliğinde bir dönüşüm başlattı.	G. Devol ve Joseph F. Engelberger
1969	Movbot	Ticari satışı olan ilk mobil robot	Piyasaya sürülen ve otomatik çimen biçebilen ilk mobil robot	Movbot Inc.
1966 1972	Shakey	Mantık yürütebilen mobil robot	Çevresini algılama ve görme yeteneği olan bu robot, bilimsel çalışmalara ilham oldu.	Stanford Araştırma Enstitüsü
1970	Lunokhod	Ay yüzeyini keşfeden ilk mobil robot	Ay yüzeyinde Mare Imbrium (Yağmurlar Denizi) bölgesinde 11 ay boyunca toplam 10,5 km yol kat etti, Ay'ın fiziksel özellikleri ve jeolojik yapısı hakkında önemli bilgiler topladı.	Lavoçkin Araştırma ve Üretim Ortaklığı
1975	Viking 1 ve Viking 2	Mars yüzeyini keşfeden ilk mobil robot	Kamera, gaz analiz cihazları ve mekanik kazıma araçları içeren Viking araçları, Mars yüzeyini detaylı bir şekilde inceleyerek gezegenin atmosferi, toprağı ve yaşamın varlığı hakkında veriler topladılar.	Ulusal Havacılık ve Uzay Dairesi (NASA)
1979	Stanford Cart	Otonom robotların atası	Kameradan aldığı görüntüleri, telsiz aracılığı ile bilgisayara aktardı, bilgisayardan dönen yön ve sürüş komutları ile engelleri tespit etmeyi ve onları aşmayı başardı.	Stanford Yapay Zeka Laboratuvarı
1991	Khepera	Özelleştirilebilir, programlanabilir mobil robot	Küçük boyutu, hafif yapısı ve açık kaynaklı yazılım desteğiyle özellikle akademik araştırmalar için tasarlandı ve birçok bilimsel çalışmada tercih edildi.	Edo. Franzi vd.
1993 1994	Dante-I ve Dante-II	Yeryüzünde tehlikeli görevleri yerine getiren mobil robot	Dante-I başarılmasa da Dante-II, gelişmiş otonom navigasyon sistemi, hassas sensörleri ve güçlü mekanik yapısıyla aktif bir yanardağın derinliklerinde patlama aktivelerini, volkanik oluşumları analiz etti ve bilimsel veri toplamayı başardı.	Jet Propulsion Laboratuvarı
1996	Sojourner	Mars'a gönderilen ilk otonom mobil robot	Pathfinder gezgini aracılığı ile Mars'a ulaştı. Yüzeyinde sensörlerini ve navigasyon sistemini kullanarak otonom olarak hareket etti, engelleri aştı ve önemli bilgiler topladı.	NASA
1999 2006	Aibo	Etkileşim kurabilen mobil robot	Belirgin köpek davranışları gösterebilen ve insanlarla anlamlı şekilde etkileşime girebilen Aibo, potansiyeli ile insanların makinelerle etkileşimi konusunda çığır açtı.	Sony
2000 2018	Asimo	Gelişmiş humanoid	İnsanlar gibi, yürüyebiliyor, koşuyor, merdiven çıkıyor, dans ediyor, nesnelere ve insanlarla etkileşime geçebiliyordu.	Honda
2005 ...	BigDog	Araziye çıkan mobil robot	Araçların giremeyeceği engebeli arazilerde yük taşıma yeteneğe sahip dört ayaklı mobil robotlar geliştirildi.	Boston Dynamics
2016 ...	ARGOS Robotları	Tehlikeli görevler için tasarlanan mobil robotlar	Açık denizde bulunan petrol ve gaz tesislerinde tehlikeli ve zorlu görevler için geliştirildi.	ARGOS Challenge
2022	Proteus	Endüstride tam otonom mobil robot kullanımı	Büyük ve karmaşık depolarda, insanlarla aynı çalışma ortamında yük sepetlerini taşımakla görevlendirilen tam otonom mobil robotlar kullanıldı.	Amazon

### **1.3.2 Derin öğrenmenin gelişimi**

Derin öğrenmeyle ilgili ilk çalışmalar, sensörler aracılığıyla nesnelere algılanmasına yöneliktir ve 1950'lerde başlamıştır. Ancak, asıl önemli gelişmeler 21. yüzyılın başlarında gerçekleşmiştir. Bu dönemde, derin öğrenme alanında büyük ilerlemeler kaydedilmiş ve özellikle derin sinir ağlarıyla nesne algılama ve sınıflandırma konularında önemli başarılar elde edilmiştir. Derin öğrenme teknikleri, büyük veri setlerinin kullanımıyla daha da güçlenmiş; görüntü tanıma ve nesne algılama alanında çığır açıcı sonuçlara varılmıştır. Bu dönemdeki gelişmeler, derin öğrenmeyi çağımızın en önemli yapay zeka alanlarından biri haline getirmiştir.

Bu iki farklı gelişmeden dolayı nesne algılama tarihi iki farklı döneme ayrılır. Bunlar, geleneksel nesne algılama dönemi ve derin öğrenmeye dayalı nesne algılama dönemidir (Zou ve diğerleri, 2023).

#### **1.3.2.1 Geleneksel nesne algılama (2014 öncesi) dönemi**

Nesnelere erken dönemde bilgisayarlar kullanılarak tespit edilmeye çalışıldığı dönem, nesne algılama alanında ilk adımların atıldığı dönemdir. Bu dönemde, manuel özellik çıkarma ve kural tabanlı sistemlere dayalı ilk nesne algılama algoritmaları geliştirilmiştir. Ancak, bu algoritmaların temel sorunu, nesne ölçeğinin, açısının ve aydınlatma koşullarının değişmesiyle ortaya çıkan algılama zorluklarıdır. Bu durum, etkili görüntü temsillerinin oluşturulmasını zorlaştırıyordu (Zou ve diğerleri, 2023). Bu döneme ait önemli çalışmaların sayısı sınırlıdır. Ancak, bu dönemde elde edilen deneyimler ve çalışmalar, sonraki yıllarda daha gelişmiş nesne algılama yöntemlerinin ortaya çıkmasına zemin hazırlamıştır.

Paul Viola ve Michael Jones tarafından 2001 yılında tanıtılan Viola-Jones algoritması, makine öğrenimine dayalı bir nesne algılama yöntemidir. Görüntülerde hızlı ve hassas nesne tespiti elde etmek için basit Haar benzeri özelliklerden oluşan bir basamak kullanır (Viola & Jones, 2001). Bu algoritma bilgisayarla görme topluluğunda çok sık kullanılmış ve sıklıkla referans gösterilmiştir. Çözüm yöntemi sonraki nesne algılama algoritmalarının ilerlemesi üzerinde derin bir etkiye sahip olmuştur.

Navneet Dalal ve Bill Triggs tarafından 2005 yılında kaleme alınan 'Histograms of Oriented Gradients for Human Detection' başlıklı makale, görüntü yamalarında gradyan yönelimlerinin histogramlarını kullanarak nesne tespiti için yeni bir teknik

sunmaktadır. Histogram of Oriented Gradients (HOG) özellik tanımlayıcısı olarak bilinen bu yöntemin özellikle insan tespiti alanında başarılı olduğu görülmüştür (Dalal & Triggs, 2005).

### **1.3.2.2 Derin öğrenmeye dayalı nesne algılama dönemi**

2014 tarihli "OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks" makalesi nesne tespiti, lokalizasyon (yerelleştirme) ve sınıflandırma yapmak için konvolüsyonel ağların kullanılmasına yönelik bir yöntem önermektedir. Bu yöntem ile çok ölçekli ve kayan pencere yaklaşımı kullanmakta ve nesne sınırlarını bastırmak yerine sınırlama kutularını biriktirerek tahmin etmeyi öğrenmektedir. Bu yaklaşımın nesne tespiti için etkili olduğu gösterilmiştir ve bir dizi başarılı nesne tespit sistemi oluşturmak için kullanılmıştır (Sermanet ve diğerleri, 2014).

2014 tarihli "DeepPose: Human Pose Estimation via Deep Neural Networks" makalesi, derin sinir ağları (DSA) kullanarak insan pozu tahmini için bir yöntem önermektedir. Yöntem, çeşitli gerçek dünya görüntülerinden oluşan dört akademik ölçüt üzerinde değerlendirilmiş ve dört ölçütte de son teknoloji ürünü veya daha iyi performans elde etmiştir (Toshev & Szegedy, 2014).

2015 yıllarında konvolüsyonel sinir ağlarının (KSA'nın) etkili olması için "yapay" olan ve keyfi bir boyut/ölçekteki görüntüler veya alt görüntüler için tanıma doğruluğunu azaltabilecek sabit boyutlu bir giriş görüntüsü gerekiyordu. Bu gereksinimi ortadan kaldırmak için uzamsal piramit havuzlama adı verilen yeni bir havuzlama stratejisi önerilmiştir. SPP-net adı verilen yeni ağ yapısı, görüntü boyutu/ölçeğinden bağımsız olarak sabit uzunlukta bir temsil oluşturabiliyordu (He ve diğerleri, 2015).

2015 yılında yayınlanan "Fast R-CNN" adlı çalışma, Ross Girshick tarafından geliştirilmiştir. Fast R-CNN (Fast Region-based Convolutional Neural Networks – Hızlı Bölge Tabanlı Konvolüsyonel Sinir Ağları), nesne algılama ve sınıflandırma için önemli bir ilerleme kaydetmiştir. Aynı zamanda bu çalışma nesnelerin algılmasında hıza vurgu yapmıştır. Fast R-CNN, tek bir ileri geçişte nesne bölgesini önerir, özellikleri çıkarır ve nesnenin sınıflandırmasını ve konumlandırmasını gerçekleştirir. Bu, daha önceki R-CNN (Region-based Convolutional Neural Networks - Bölge Tabanlı Konvolüsyonel Sinir Ağları) yöntemlerine kıyasla daha

hızlı çalışmayı ve daha yüksek hassasiyet sağlamayı mümkün kılmıştır. Ayrıca Fast R-CNN çalışması, nesne algılama alanında bir dönüm noktası olmuş ve birçok başarılı uygulamaya ilham vermiştir. Bu yöntem, diğer nesne algılama tekniklerin de temelini oluşturmuştur. Fast R-CNN, derin öğrenme tabanlı nesne algılamasının yaygınlaşmasına ve daha geniş bir kullanım alanına ulaşmasına katkı sağlamıştır (Girshick, 2015).

2015 yılında da Faster R-CNN yöntemi tanıtılmıştır. Faster R-CNN, bölge öneri ağlarını (RPN'leri) bölge tabanlı KSA ile birleştiren bir nesne algılama algoritmasıdır. RPN aday nesne bölgeleri oluşturur ve R-CNN daha sonra nesne kategorisini ve konumunu tahmin etmek için her bölgeyi sınıflandırır ve regresyona tabi tutar. Daha Hızlı R-CNN, karşılaştırılabilir veya daha iyi doğruluk elde ederken R-CNN'den önemli ölçüde daha hızlıdır (Ren, Girshick & Sun, 2015).

2015 yılında R-CNN, VOC 2012 veri setinde genel ortalama hassasiyeti (mAP) yüzde 50'den fazla artırarak yüzde 62,4'lük bir mAP elde etmiştir. Bu çalışma, nesne algılama ve segmentasyon alanında önemli bir ilerleme kaydetmiş ve daha doğru sonuçlar elde etmeyi sağlamıştır (Girshick ve diğerleri, 2015).

2015 yılında YOLO (You Only Look Once – Sadece Bir kez Bak) yöntemi yayınlanmıştır. YOLO, görüntülerdeki nesnelere için sınırlama kutularını ve sınıf olasılıklarını tek bir değerlendirmede tahmin eden birleşik, gerçek zamanlı bir nesne algılama sistemidir. Doğruluğu korurken veya geliştirirken önceki nesne algılama sistemlerinden önemli ölçüde daha hızlıdır. YOLO, sınırlama kutularını ve sınıf olasılıklarını doğrudan tam görüntülerden tahmin eden tek bir sinir ağıdır (Redmon ve diğerleri, 2015).

2016 yılında SSD (Single Shot Multibox Detector – Tek Atış Kutu Algılama), ağıncı tek bir ileri geçişinde görüntülerdeki nesnelere için sınırlama kutularını ve sınıf olasılıklarını tahmin eden tek atışlı bir nesne algılama algoritmasıdır. Doğruluğu korurken veya geliştirirken önceki nesne algılama algoritmalarından önemli ölçüde daha hızlıdır. SSD, nesne tespiti için çok yönlü ve güçlü bir araçtır (Liu ve diğerleri, 2016).

2017 yılında nesne algılamada sınıf dengesizliği sorununu ele almak için yeni bir odak kaybı (focal loss) işlevi kullanılan tek aşamalı bir nesne algılama mimarisi sunulmaktadır. Odak kaybı işlevi, nadir sınıflara ağırlık vererek sınıf dengesizliği

sorununu azaltır ve algılama performansını iyileştirir. RetinaNet, yoğun nesne tespiti için etkili bir çözüm sunarak, nesne algılamada önemli bir adım olmuştur (Lin ve diğerleri, 2017).

2017 yılında nesne örneği segmentasyonu için kavramsal olarak basit, esnek ve genel bir çerçeve olan Mask R-CNN sunulmuştur. Bu yöntem, bir görüntüdeki nesnelere etkili bir şekilde tespit ederken aynı zamanda her bir örneğin yüksek kaliteli bir segmentasyon maskesi oluşturur. Mask R-CNN, Faster R-CNN'nin temelini oluşturan sınırlama kutusu tanıma dalına ek olarak bir nesne maskesi tahmini dalını ekleyerek genişletilmiştir. Bu sayede hem nesne tespiti hem de nesne örneği segmentasyonu tek bir çerçeve içinde gerçekleştirilebilir hale gelmiştir. Mask R-CNN, nesne örneği segmentasyonu alanında önemli bir adım olarak kabul edilmiş ve geniş bir etkiye sahip olmuştur (He, Dollár & Girshick, 2017).

2019 yılında bir nesnenin merkez noktasının yanı sıra boyutunu, sınıfını ve duruşunu da tahmin edebilen yeni bir sinir ağı mimarisi önerilmiştir. Bu çalışma ile büyük bir görüntü ve nesne etiketi veri kümesi üzerinde uçtan uca eğitilmiştir. Ayrıca GPU'larda gerçek zamanlı nesne algılama hızlarına ulaşabildiği ve çeşitli nesne algılama ölçütlerinde en gelişmiş doğruluğu elde ettiği gösterilmiştir (Zhou, Wang, & Krähenbühl, 2019).

2020 yılında yeni bir nesne tespiti yöntemi sunulmuştur. Bu çalışmada, nesne tespitini bir küme tahmin problemi olarak ele alan bir yaklaşım önerilmektedir. DETR (DEtection TRansformer) algılama işlem hattını kolaylaştırarak, elle tasarlanmış birçok bileşene olan ihtiyacı ortadan kaldırarak görevle ilgili ön bilgileri açıkça kodlamaktadır. Yöntemin ana bileşenleri, küme tabanlı bir küresel kayıp kullanarak benzersiz tahminleri zorlayan bir iki parçalı eşleştirme yöntemi ve bir transformatör kodlayıcı-kod çözücü mimarisidir. DETR, nesne algılama alanında dikkat çeken bir gelişmedir ve Transformer tabanlı bir yaklaşımın nesne tespiti için etkili bir şekilde kullanılabileceğini göstermektedir (Carion ve diğerleri, 2020).

2020 yılında daha az parametre kullanarak en gelişmiş doğruluğu elde etmek için verimli omurga ağları ve bileşik ölçeklendirme kullanan bir nesne algılama mimarisi ailesi olan EfficientDet önerilmiştir. Bu çalışma, verimli bir şekilde çalışan ve hesaplama kaynaklarını daha iyi kullanan bir nesne algılama yöntemi arayan araştırmacılar için önemli bir katkı vermiştir. EfficientDet, EfficientNet omurga

ağlarından yararlanarak daha az parametreyle daha yüksek doğruluk elde etmeyi hedeflemektedir. Bu yaklaşım, nesne algılama alanında daha verimli ve performanslı modellerin geliştirilmesine olanak sağlamaktadır (Tan, Pang & Le, 2020).

### **1.3.3 Derin öğrenmenin mobil robot güvenliğinde kullanımı**

Literatürde robotlarda derin öğrenme kullanımı ile ilgili çalışmalar son birkaç yıl içinde derin öğrenmedeki gelişmelerle paralel artmıştır. Bu çalışmaların çoğu insan robot iş birliği (montaj, nesne devretme, nesne taşıma ve işbirlikçi üretim) üzerinedir ve genellikle kolaboratif robotları kapsar. Derin öğrenmenin güvenlik alanında kullanımı daha sınırlıdır.

Hata ve diğerleri (2019) insan robot etkileşiminde güvenliği arttırmak için yapay zeka kullanımı tartışmaktadır. Çalışmada yakınlık sensörleriyle birlikte yapay zeka kullanımının robotların çalışma alanındaki potansiyel tehlikeleri fark etmesinde etkili olabileceği ve bu nedenle kullanılması gerektiği önerilmiştir. Çalışmanın sonuç kısmında, yapay zeka kullanımının insan mobil robot etkileşiminde güvenliği arttırmak için kullanılabilir olduğu ve yapay zeka ile robotların potansiyel tehlikelerden kaçınabileceği ileri sürülmüştür.

El-Shamouty ve diğerleri (2020) kolaboratif robotlara güvenliği sağlayacak akıllı davranışlar öğretmenin insan robot etkileşiminde güvenlik sağlayabileceğini ileri sürmüştür. Bu hipotezini geliştirmek için içinde ajan bulunan ve ceza ödül yöntemi ile çalışan takviyeli öğrenmeye dayalı bir derin öğrenme mimarisi geliştirmiştir. Bu yapay sinir ağı mimari sayesinde robotlar insanlarla yaklaşık %85'lik bir değerle güvenli hareket etmeyi başarmıştır.

Liu ve diğerleri (2021) DSA takviyeli öğrenme mimarisinin insan kolaboratif robot etkileşiminde güvenliği sağlamak için yaygınlaştırılması gerektiğini ileri sürmektedir. Bu amaçla robotların insanlarla güvenli çalışmasını sağlayacak özel bir ajan geliştirir. Laboratuvar ortamında yapılan testlerin umut verici olduğu görülmüştür.

Rezayati ve diğerleri (2023) fiziksel insan robot etkileşiminde halihazırda geçerli olan basit güvenlik önlemlerinin, insan robot iş birliği ile oluşan üstünlüklerin etkili bir şekilde kullanılmasını engellediğini iddia etmektedir. İnsanların robotlarla daha yakın çalışması için derin metrik öğrenme modeli önerilmektedir. Çalışmada ayrıca

derin metrik öğrenme modelinin insan robot etkileşimde kasıtlı temas kurma durumunu ayırt etmede %98,6'lık bir doğruluk sağladığını ileri sürmektedir.

#### **1.3.4 Derin öğrenmenin iş sağlığı ve güvenliğinde kullanımı**

Literatürde derin öğrenmenin iş sağlığı ve güvenliğinde kullanımı genellikle Kişisel Koruyucu Donanımın tespiti üzerine yapılan çalışmalardan oluşmaktadır. Bu çalışmalara bakıldığında ise nesne algılama mimarisine bağlı olarak farklı sonuçlar elde edilmiştir.

Fang ve diğerleri (2018) tarafından şantiyede çalışan inşaat işçilerinin baret kullanımının tespit edilmesi için yaptığı çalışmada Faster R-CNN kullanılmış ve %90'ın üzerinde performans değeri elde edilmiştir.

Wu ve diğerleri (2019) baret renginin yetki seviyesini belirttiği için renge dayalı baret tespiti yapmıştır. Yaptığı çalışmada farklı ölçeklerde bulunan farklı katmanlardan elde edilen özellikleri ayırmacı bir şekilde birleştiren "reverse progressive attention" yöntemi, ayrıca algılama sonuçlarını tahmin etmesi için ise "Single Shot Multibox Detector (SSD)" algoritması kullanılmıştır. Sonuç olarak, çalışmada %83,89 genel Ortalama Hassasiyet (mAP) metrik değeri elde edilmiştir.

Zhang ve diğerleri (2020), yayınlarında nesne tespitindeki ortalama doğruluk değerinin %67,6 olduğunu ancak yaptıkları çalışmada baret tespiti için %71,2'lik bir doğruluk elde ettiklerini ve bu doğruluk değerinin ortalama değer üstünde olduğunu belirtmişlerdir. Wang, Niu ve diğerleri (2020) gerçek zamanlı olarak baret ve iş elbisesi tespiti üzerine çalışmışlardır. Geliştirdikleri YOLOv3 nesne algılama mimarisini kullanmışlardır. Sonuç olarak, çalışmada YOLOv3 için %97,79'e ulaşan bir mAP metrik değeri elde etmişlerdir. Kim ve diğerleri (2020) tarafından Faster R-CNN mimarisi kullanılarak şantiyelerde baret, işçi ve araç tespit çalışması yapılmış ve baret için %91,3 mAP'lik metrik değeri elde edilmiştir. Saudi ve diğerleri (2020) Faster R-CNN mimarisi kullanarak üç sınıflı bir model eğiterek başta baret olmak üzere iş ayakkabısı ve yelek tespiti için bir çalışma yapmış ve çalışma sonucunda %70'lik bir doğruluk oranı elde etmiştir. Casuat ve diğerleri (2020) baret tespit çalışması için YOLOv3 mimarisi kullanmış ve %79,2'lik bir performans değeri elde etmiştir. Filatov ve diğerleri (2020) inşaat işçileri tarafından kullanılan baret tespit çalışması yapmış, SqueezeDet algoritması ile MobileNet mimarisi kullanılmıştır ve 0.75'lik bir F1 skoru elde edilmiştir. Wang, Xie ve diğerleri (2020) baret kullanan ve

kullanmayan çalışanları sınıflandıran (ayıran) çok ölçekli özelliklere ve yukarıdan aşağıya bir modüle sahip hafif ağırlıklı KSA mimarisi kullanmıştır. %87,4'lük bir mAP'lik metrik değeri elde etmiştir.

Zhou ve diğerleri (2021) YOLOv5 mimarisini kullanarak %94,7'lik bir mAP metrik değeri elde etmiştir. Cengil (2021) doktora tez çalışmasında YOLOv5 versiyonunu kullanarak baret tespit çalışması yapmıştır. Yaklaşım %90'lık bir mAP değeri elde etmiştir.

Gallo ve diğerleri (2022) endüstriyel ortamlarda gerçek zamanlı tespit için bir akıllı sistem önermiştir. Model eğitimi YOLOv3 ile yapılmış ve %95'lik bir mAP doğruluk elde etmiştir.

Yang ve diğerleri (2023) YOLOv5s ile şantiyelerde baret tespiti için yaptıkları çalışmada %96'lık bir mAP elde etmişlerdir. Farooq, Bhutto & Kazi (2023) tarafından YOLOv5 versiyonun tüm varyantları ile Baret tespit çalışması yapılmış ve YOLOv5n varyantının diğer varyantlara göre daha düşük bir mAP doğrulama değeri ancak çok daha büyük oranda çıkarım hızı elde ettiği saptanmıştır.

Baret tespiti ile ilgili yapılan literatür çalışmalar Çizelge 1.2'de sıralanmıştır.

**Çizelge 1.2: KKD Tespiti İle İlgili Yapılan Çalışmalar**

Çalışmayı Yapan	Yılı	Tespit edilmesi hedeflenen KKD	Kullanılan Mimari/versiyon/varyant	Hızı (FPS)	Performans
Fang ve diğerleri	2018	Baret	Faster R-CNN	5	%95,7 Keskinlik ve %94,9 Duyarlılık
Wu ve diğerleri	2019	Baret	"reverse progressive attention" + SSD	31,30	%83,89 mAP
Zhang ve diğerleri	2020	Baret	Faster R-CNN	-	% 71,21
Wang, Niu ve diğerleri	2020	Baret	YOLOv3	28.57	%97,79 mAP
Kim ve diğerleri	2020	Baret	Faster R-CNN	-	%82 mAP
Saudi ve diğerleri	2020	Baret, yelek, iş ayakkabısı	Faster R-CNN	-	%70 Doğruluk
Casuat ve diğerleri	2020	Baret	YOLOv3	-	%79,24 mAP
Filatov ve diğerleri	2020	Baret	SqueezeDet + MobileNet	18,5	0.75 F1 Skoru
Wang, Xie ve diğerleri	2020	Baret	Lightweight CNN	62	%89,4 AP
Zhou ve diğerleri	2021	Baret	YOLOv5s	110	%93,6 mAP
Cengil	2021	Baret	YOLOv5	0,032	%90,3 mAP
Gallo ve diğerleri	2022	Tüm KKD'ler	YOLOv4	6,8	%95
Yang ve diğerleri	2023	Baret ve Maske	YOLOv5s	-	%96 mAP
Farooq ve Kazi	2023	Baret	YOLOv5n	70,4	%94,2 mAP

#### **1.4 Hipotez**

Mobil robotlar güvenli bir şekilde gezinmek için daha çok lidar ve benzer türdeki yakınlık sensörleri kullanırlar (Ghorpade, Thakare & Doiphode, 2017), (Rajawat ve diğerleri, 2021). Yakınlık sensörleri oldukça hızlı olduklarından mobil robotları yavaşlatmadan ya da duraksatmadan yollarını belirlemesini, engellerden kaçınılmasını ve tehlikeleri fark etmesini sağlar. Mobil robotlarda engellerden kaçınma ve güvenlik için derin öğrenme kullanımı pek tercih edilmemektedir. Bunun nedeni robotların seri hareketlerine göre nesne algılama çıkarım süresinin yavaş kalması ve çıkarımların sensör hassasiyeti (doğruluğu) kadar yüksek doğruluk sunamamasıydı (Balasubramanian ve diğerleri, 2009), (Ruppert & George, 2022), (Lee & Lee, 2022).

Yakınlık sensörleri hızlı olsalar da nesne algılama teknolojisi kadar yetenekli değildir. Örneğin çalışanın yetkili olup olmadığı bilgisini algılamakta zayıf kalırlar. Bu nedenle yakınlık sensör verileri ile alınacak güvenlik önlemleri koşullardan bağımsız olarak tek düze uygulanmaktadır. Durum ve nesnelerin algılanmasıyla birlikte insan robot etkileşiminde derin öğrenme kullanımı daha güvenli olabilir (Duque-Suárez ve diğerleri, 2022). Bu çalışmada, son birkaç yıl içindeki nesne algılama mimarilerindeki gelişimlerle birlikte doğruluk ve hız seviyelerinin, mobil robotlarda güvenlik önlemleri için kriter belirleme başarısı incelenecektir. Bu çalışma ile derin öğrenmenin yakınlık sensörleriyle birlikte kullanılması durumunda insan endüstriyel mobil robot etkileşiminin daha güvenli ve verimli olacağı ileri sürülmektedir.

#### **1.5 Literatüre Katkısı**

Bu çalışma, insan mobil robot etkileşiminde güvenlik için kullanılan yakınlık sensörleriyle birlikte DSA'nın da kullanılabileceğine yönelik yeni bir yaklaşım sunmuştur. Bu yaklaşımın endüstriyel mobil robotların insanlarla daha verimli çalışmasını ve etkili güvenlik önlemleri almasını sağlayacağı ileri sürülmüştür. Araştırmada, bu amaca yönelik olarak geliştirilen bir nesne algılama algoritması modeli değerlendirilmiştir. Değerlendirme sonuçları, bu yaklaşımın mobil robotlarda yakınlık sensörleriyle birlikte derin öğrenmenin kullanılabileceğini ve güvenlik açısından kabul edilebilir hız seviyelerine ulaşabileceğini göstermiştir.

Bu çalışmanın, insan mobil robot etkileşimine yeni bir yaklaşım getirmesi, bu alanda yeni bir boyut kazandırması ve diğer çalışmalara ilham kaynağı olması, özellikle mobil robotlarla çalışan endüstrilerde güvenlik önlemlerinin daha etkili bir şekilde uygulanmasına ve insan robot etkileşimindeki güvenliğin artırılmasına katkı sağlaması öngörülmektedir.



## 2. GENEL BİLGİLER

### 2.1 Derin Öğrenme

Derin öğrenme, yapay sinir ağlarını kullanan bir makine öğrenimi türüdür. Makine öğrenimi ise yapay zekanın bir alt dalıdır. (Aktürk ve diğerleri, 2022). Derin öğrenmenin yapay zeka içindeki konumu Şekil 2.1’de gösterilmiştir.



**Şekil 2.1:** Derin Öğrenmenin Yapay Zeka İçindeki Konumu

Derin öğrenme yapay zeka içinde en popüler olan çalışma alanlarından biridir. İnsan beyni model alınarak oluşturulduğundan, makinelerin insana benzer öğrenme yeteneği göstermeye başlamış olması oldukça heyecanlı ve ilham vericidir. Derin öğrenme ile makineler çevreleriyle, nesnelere ve insanlarla etkileşim kurmaya başlamış ve karmaşık problemleri çözebilir olmuştur (Kotu & Deshpande, 2019).

Derin öğrenme, nesne algılama, sınıflandırma, doğal dil işleme, konuşma tanıma, tıbbi uygulamalar, tanı koyma, akıllı ulaşım sistemleri dahil birçok görevi başarı ile yerine getirebilir (Dong, Wang & Abbas, 2021). Bununla birlikte bazı zayıflıkları ve sınırlamaları da vardır. Bunların başında öğrenme aşamasında çok fazla veriye

ihtiyaç duyması gelir. Karmaşık problemleri etkili bir şekilde çözmesi çok fazla ve kapsayıcı veriler kullanılarak eğitilmesiyle gerçekleşir. Ancak eğitim aşamasında yüksek donanıma da ihtiyaç duyabilir (Bengio, Courville & Vincent, 2013). Nesne algılama algoritmalarında olduğu gibi pekiştirmeli eğitim uygulayacaksa verilerin önceden hazırlanması da oldukça zahmetli olabilir (Bengio, 2013) & (Harrison ve diğerleri, 2021).

Derin öğrenmenin yapay sinir ağlarının modellenmesi için mühendislik bilimine, sinir ağı ile elde edilen verilerin anlamlandırılması için istatistiksel matematiğe dayanır. İstatistikte, örneklemeler üzerinden bütünü kapsayacak genel açıklamalar elde etme çıkarım, bu çıkarımlarınla yeni veriler hakkında yorum yapmak ise öğrenme veya kestirim olarak adlandırılır. Aynı durum derin öğrenme için de geçerlidir. Ayrıca yapay öğrenme, mühendislik alanında kullanılan matematiksel ifadeleri ve istatistiksel çıkarımları kullanarak örüntüler arasındaki genel ilişkileri bulma ve çıkarım yapma temeline dayanır (Alpaydın, 2020). Bu durumda örüntü tanıma ve istatistiksel çıkarım, her ikisi de makine öğrenimi için önemli araçlardır. Yapay sinir ağları örüntü tanıma için ağırlıkların oluşmasını sağlarken, bu ağırlıklardan türetilen matematiksel ifadelerin bir sonuca dönüşmesi ise istatistiksel çıkarım olarak ifade edilebilir. İstatistiksel çıkarım, tahminlerde bulunmak için bir temel sağlarken, örüntü tanıma verilerdeki gizli örüntüleri bulmak için kullanılır. Amaç, kestirmek istediğimiz yeni verilerden çıkarım elde edecek bir model oluşturmaktır.

Derin öğrenme mühendislik bilimi ve istatistiksel matematiğe dayansa da günümüzde multidisipliner bir çalışma alanı olmuştur. Mühendislik bilimiyle birlikte Sosyal bilimlerden sağlık bilimlerine, finansa her alanda derin öğrenme ile ilgili çalışmalar yapılmaktadır. Derin öğrenmenin tüm bilimlerle ve sektörlerle etkileşim içinde olduğu düşünülürse oldukça yüksek bir potansiyele sahip olduğu görülür.

Derin öğrenme olasılığa dayalı bir çıkarıma dayanır ancak araştırmacılar genellikle deterministik uygulamalar kullanmaya alışıktır. Determinist bir algoritma hesaplanabilir sonuçlar verir. Örneğin fiziksel sistemlerin davranışları determinist bir yaklaşımla hesaplanırsa davranışı gerçekleştirmek için gerekli olan kuvvet, ısı veya radyasyon öngörülebilir bir sonuç olarak elde edilir. Derin öğrenme olasılıksal bir uygulamadır. Bu, derin öğrenme modellerinin hesaplanabilir bir sonuç vermek yerine kuvvetli tahminler yaptığı anlamına gelir (Bishop & Nasrabadi, 2006).

Derin öğrenme makine öğrenmesinin bir uygulaması olduğu için makine öğrenmesinde kullanılan öğrenme türleri derin öğrenme içinde geçerlidir. Bu öğrenme türleri; gözetimli öğrenme, gözetimsiz öğrenme, yarı gözetimli öğrenme ve takviyeli öğrenmedir (Ashenden ve diğerleri, 2021).

### 2.1.1 Gözetimli öğrenme

Gözetimli öğrenmede model eğitiminde kullanılacak veri setlerinin toplanması ve eğitim için hazır hale getirilmesi gerekir. Eğitimin zahmetli ve uzun zaman alan bir ön işlem süreci vardır. Eğitim verileri kullanılmadan önce, tam temsiliyeti sağlayacak şekilde verilerin toplanması, ölçeklendirilmesi, etiketlenmesi vb. işlemlere tabi tutulması gerekebilir.

Verilerin tam temsiliyeti sağlayacak şekilde toplanması, eğitimde kullanılacak verilerinin olası tüm biçimleri, açıları, boyutları, renkleri, kategorileri ve benzeri unsurları dengeli bir şekilde kapsamaları işlemidir.

Veri ölçeklendirme, verilerin eğitimde kullanılacak ölçek boyutuna getirilmesidir.

Etiketleme, model tarafından oluşturulacak ideal hedef çıktısının modelin eğitiminde referans oluşturması için eğitim başlamadan yeterli sayıda veri toplanarak manuel olarak (elle) oluşturma işlemidir.

Tüm bu işlemler yapıldıktan sonra eğitim etiketlenen verileri referans olarak gerçekleşir. Özellikle nesne ya da örüntü algılamada, örüntünün yeni verileri tam temsil edebilmesi, yeteri kadar örnek üzerinden kendisini eğitmesi ile mümkün olur. Nesnenin farklı biçimleri, her biçimin farklı açıları, farklı ışık koşulları altındaki görüntüsü, görsel verideki boyutu, konumu yeteri veri ile karşılanamıyorsa eğitimde beklenen performansı sağlamayabilir. Bununla birlikte yetersiz veri kümeleri, özellikle gerçek hayatta olmasına rağmen veri kümesinde olmayan örneklerin eksikliği eğitim performansını manipüle edebilir. Modül nesneyi tam temsil edecek verilerle değil, bir durumunu ya da biçimini, açısını temsil eden bir eğitim gerçekleştirebilir ve eğitim başarılı görünse de nesnenin gerçek hayatta farklı biçimleri ile karşılaştığında eğitim sırasında ölçülen performansından çok düşük performans gösterebilir. Bu duruma örneklem içinde bir biçimi aşırı öğrenmesinden dolayı aşırı uyum (overfitting) denir. Buna rağmen derin öğrenme dağınık verileri işlemekte yine de iyidir. Odak kaybı fonksiyonlarını kullanarak veri dengesizliğinden kaynaklı zorlukları en aza indirebilir.

Denetimli öğrenmenin içinde aktarım öğrenimi (transfer learning) kullanılabilir. Aktarım öğrenimi, daha önce bir görev için eğitilmiş bir modelin yeni eğitilecek modelde kullanılması ile eğitim sürecinin kısaltılması ve daha az veri ile öğrenmenin gerçekleşmesini sağlar. Örneğin baret kullanan insan tespitinde insan tespiti için eğitilmiş yüksek performanslı bir modelin aktarılması yeni oluşturulacak modelin daha hızlı ve daha yüksek doğruluk oranı elde etmesini sağlayabilir.

### **2.1.2 Gözetimsiz öğrenme**

Denetimsiz öğrenme olarak da adlandırılır. Gözetimsiz öğrenmede verilerin etiketlenmesine gerek yoktur (Harrison ve diğerleri, 2021). Bu durum zaman alıcı manuel bir işlemin ortadan kaldırır. Fakat eğitim denetimli öğrenmedeki kadar yüksek performanslı olmayabilir.

### **2.1.3 Yarı gözetimli öğrenme**

Hem etiketli hem de etiketlenmemiş verilerden faydalanılarak modellenen öğrenme yaklaşımıdır. Genelde eğitimde kullanılan etiketli veriler daha az, etiketlenmemiş veriler daha fazladır. Etiketli verilerden elde edilen bilgiler, etiketlenmemiş verilerin öğrenilmesini ve modellerin genelleme yeteneklerinin iyileştirilmesini için kullanılır. Diğer bir ifade ile etiketli verilerle ince ayar yapılır.

### **2.1.4 Takviyeli öğrenme**

Öğrenmede ödül ve ceza yaklaşımından esinlenerek oluşturulmuş bir modeldir. Modelde bir ajan tanımlanır ve ajan görevi ile ilgili işlemleri gerçekleştirmek için bulunduğu platformda etkileşime girer. Başlangıçta neyi nasıl öğrenmesi gerektiğini bilmez. Ancak çevreden aldığı ödüller (bilgi veya davranışın onaylanması) ve cezalar (bilgi ve davranışının yanlışlanması) ile hangi davranışlarının daha doğru olduğunu öğrenir.

Ajanın amacı, ödülleri artırmak ve cezaları azaltmak için stratejilerini geliştirmektir. Bu doğrultuda, ajan çevreyle etkileşim içinde kalarak farklı eylemler deneyerek ve elde ettiği sonuçlara dayanarak öğrenme sürecini gerçekleştirir. Ajan, çevreyle etkileşim halindeyken karşılaştığı durumları ve ödül/ceza sinyallerini kullanarak gelecekteki kararlarını şekillendirir.

Sonuç olarak, takviyeli öğrenme sürecinde ajan, ödül ve ceza sinyallerine dayanarak parametrelerini güncelleyerek öğrenme gerçekleştirir. Bu süreçte, ajanın hedefi, daha fazla ödül elde etmek ve cezalardan kaçınmak için en doğru davranış stratejisini geliştirmektir.

Tüm bu öğrenme türleri derin öğrenme ile gerçekleştirilebilir. Sonuç olarak, derin öğrenme, tüm bu öğrenme türlerini kullanarak, karmaşık örüntüleri anlamlandırma ve akıllı kararlar alabilme becerisine, yapay zekanın geleceğini şekillendirme potansiyeline ve dünyada devrim yaratabilecek bir sinerjiye sahiptir. Derin öğrenmeyi daha detaylı anlayabilmek için ise bu tekniğin temel yapı taşı, yapay sinir ağlarını daha yakından incelemek gerekir.

## **2.2 Yapay Sinir Ağları ve Mimarileri**

Yapay sinir ağları, derin öğrenme modellerinin temelini oluşturur ve insan beynindeki nöronların davranışını taklit eder. Bu nedenle yapay sinir ağlarının anlaşılması için öncelikle insan beyninde de bulunan biyolojik nöronlara bakmak gerekir.

Biyolojik nöronlar sinir sisteminin temel yapı taşıdır. Elektriksel uyarıları üreterek ve ileterek bilgiyi işleyen ve ileten özel hücrelerdir. Biyolojik bir nöron, hücre gövdesi, dendritler, akson ve akson terminallerinden oluşur. Modellenmiş bir biyolojik nöron Şekil 2.2 a'da verilmiştir. Öğrenme ve hafıza için birçok nöronun bir araya gelerek sinir ağı oluşturmaları gerekir. Bu durumda elektrik sinyallerin iletimi aşamasında nöronu oluşturan parçacıklar farklı görevleri yerine getirir. Dendritler diğer nöronlardan elektrik sinyalini alır, aksonlar elektrik sinyalini taşır ve terminal aksonlar ise diğer başka nöronlara elektriksel sinyali iletir. Bu durumda bir nöronun akson terminali ile yanında bulunan diğer nöronun dendriti birbirine çok yakın olmalıdır. Akson terminali ile dendrit arasında elektrik sinyalinin (buna bilgi de diyebiliriz) geçişini anlamlandıracak bir yarık (boşluk) vardır, buna sinaptik yarık denir. Akson terminalinden salınan nörotransmitterlerin sinaptik yarığı geçerek dendrit üzerindeki reseptörlere bağlanırsa bilgi iletimi sağlanmış olur. Bu yarıklar güçlü sinyallerin geçtiği, zayıf sinyallerin geçemediği bir boşluktur. Diğer bir ifadeyle, aksiyon potansiyeli olarak bilinen bir elektrik sinyali, bir akson terminaline ulaştığında, nörotransmitterlerin sinaptik yarığa salınmasını tetikler. Bu nörotransmitterler, alıcı nöronun (postsinaptik nöron) dendritleri veya hücre gövdesi

üzerindeki reseptörlere bağlanır ve giriş yeterince güçlüyse yeni bir elektrik sinyali üretir. Böylece bilginin sürekliliği sağlanır. Bu yapı matematiksel bir modellemeye dönüştürülerek yapay sinir ağları oluşturulmuştur. Yapay sinir ağları, nöronların çalışma prensibinin matematiksel ifadeleridir.

Bu durumun daha anlaşılabilir olması için 1957 yılında tek katmanlı olarak modellenen algılayıcı (perceptron) yapay sinir ağı incelenebilir. Bu algılayıcı biyolojik nöronlarda olduğu gibi giriş verilerini alır, işlem yapar ve çıktı üretir. Algılayıcının tipik modeli Şekil 2.2 b'de gösterilmektedir. Algılayıcının temel matematiksel ifadesi Denklem 2.1'de gösterildiği şekildedir.

$$f(x) = w \cdot x + b \quad (2.1)$$

$b$ : bias (yanlılık)

$w$ : ağırlık

$x$ : girdi

$f(x)$ : çıktıdır.

Bu matematiksel ifade de ağırlık değeri sürekli güncellenir. Bias ise yapay sinir ağının öğrenme yeteneğini arttırmak için kullanılır. Bias verilerin dağılımına göre belirlenerek daha doğru sonuçların çıkmasını sağlar. Diğer bir ifade ile modelin hedef çıktıya uyum sağlaması için ağı daha esnek hale getiren parametredir.


Algılayıcılar, bir karar çizgisi (sınırı) oluşturarak pozitif (hedeflenen içeri, doğru olan) giriş değerleri ile negatif (hedeflenen içeri olmayan, hatalı olan) giriş değerlerini sınıflandırır. Doğru bir karar çizgisi için giriş verilerinin çok fazla olması gerekir. Böylece doğru ağırlıklandırma yaparak, pozitif ve negatif girişleri doğru sınıflandırabilir.

Örnek verilen bu temel yapıdaki algılayıcı oldukça sınırlıdır. Günümüzde daha etkili yapay sinir ağı mimarileri kullanılır. Ancak bir yapay sinir ağı tipik olarak şöyle tarif edilebilir; giriş sinyallerini alır, ağırlıkları ve aktivasyon fonksiyonlarını kullanarak bir hesaplama gerçekleştirir ve bir çıktı üretir. Bu çıktı başka bir yapay sinir ağının girdisi olabilir. Böylece her sinir ağı bir ağırlık edinir ve eğitim boyunca ağın performansını optimize etmek için ağırlıklar güncellenir. Eğitim bittiğinde bu ağırlıklar oluşmuş olur ve giriş verisinin tanınmasını sağlar.

Günümüzde karmaşık verilerin yapısının daha doğru analiz edilmesi için yapay sinir ağları daha gelişmiş ve karmaşık bir modele dönüşmüştür. Bir modelde tek tip yapay sinir ağlarının kullanımı başarılı olamadığından yapay sinir ağları katmanlara ayrılmıştır. Böylece her katman ayrı görevleri gerçekleştirmek için özelleştirilmiştir. Diğer bir ifade ile bir yapay sinir ağının her katmanı, girdi verilerini sonraki katmanlarda daha karmaşık temsillerin öğrenilmesini kolaylaştıracak şekilde dönüştürmek üzere tasarlanmıştır. Böylece katman sayısı arttıkça karmaşık örüntüleri öğrenebilmektedir. Bu da yapay sinir ağları ile oluşan derinliği oluşturur ve bu yöntem adı verir (LeCun, Bengio & Hinton, 2015). Bununla birlikte, sinir ağı modellerindeki katman sayısının artırılması karmaşıklığı, hesap sayısını ve eğitim süresini artırmakta ve eğitim sırasında zorluklara yol açarak daha yüksek eğitim hatalarına neden olmaktadır (He ve diğerleri, 2016). Ayrıca, katman sayısı fazla bir model ile sınırlı miktarda veri kullanılarak eğitim gerçekleştiriliyorsa modelin eğitim verilerine aşırı uyum sağlama ve genelleme yeteneğini kaybetme riski vardır. Bu durum, modelin eğitim verilerinde yüksek performans sergilemesine rağmen, gerçek dünyadaki yeni verilere karşı düşük performans gösterme durumunu ifade eden aşırı uyum (overfitting) olarak bilinir (Hilton ve diğerleri, 2012).

Derin öğrenme modelleri genellikle en az üç katman blogundan oluşur. Ham verileri alan giriş katmanı, veri özellikleri veya öznitelikleri çıkarmak için tasarlanmış olan gizli katman ve ağın nihai çıktısını üreten çıkış katmanıdır. (Chowdhury ve diğerleri, 2019). Bu yapı Şekil 2.2 c'de modellenmiştir. Ayrıca bu katmanların her biri kendi içinde de özelleştirilmiş katmanlar bulundurabilir. Eğitim sırasında ağın ağırlıkları, ağın tahminleri ile gerçek çıktı arasındaki farkı ölçen bir kayıp fonksiyonunu en aza indirecek şekilde ayarlanır (Xu ve diğerleri, 2018). Böylece yüksek performansa sahip bir eğitim modeli oluşturulur. Bu eğitim modeli ile yeni, ağın hiç karşılaşmadığı verilerden çıkarım elde edilebilir.

Özetle, yapay sinir ağı için genellikle bilgi işleme ve veri temsillerini öğrenme yeteneğine sahip birbirine bağlı düğümlerden oluşan, düğüm türleri, düğümler arasındaki bağlantılar, bağlantıların ağırlıklandırılması ve ağ üzerinden bilgi akışı birden fazla gizli katmanla gerçekleştirilen ve gizli katman sayısı ile derinleşen sistemler denilebilir.



**Şekil 2.2:** Yapay Bir Sinir Ağına Kıyasla Biyolojik Bir Nöron: (a) Biyolojik Nöron; (b) Sinir Ağlarının Temel Yapısı; (c) Yapay Nöron (Perceptron)

**Kaynak:** (Çalışkan & Demir, 2022)

Yapay sinir ağları (YSA), çeşitli türlere ayrılan genel bir terimdir. DSA, derin öğrenmede en çok kullanılan YSA türüdür. Ayrıca DSA da kendi içinde çok fazla mimariye ayrılır (Minaee ve diğerleri, 2022). Onlarca ağ mimarisi arasından bu çalışmada konunun anlaşılması için tekrarlayan sinir ağları (TSA), derin inanç ağları (DİA), çekişmeli üretken ağlar (ÇÜA) ve çalışmanın temelini oluşturan KSA incelenecektir.

### 2.2.1 Tekrarlayan sinir ağları

Literatürde RNN (recurrent neural networks) olarak giren TSA, doğal dil işleme, metin üretimi, konuşma tanıma, çeviri, fiyat tahmini gibi zaman ve sıralı bağlantılara sahip verileri işlemek için geliştirilmiş bir yapay sinir ağı türüdür. Bu türün önemli avantajlarından biri geçmiş bilgileri hafızalarında tutabilir ve yeni verileri işlerken hafızasında bulunan verileri kullanabilir. Bunun için mimarisinde hafıza hücreleri olarak adlandırılan içsel bellekler bulunur. Bu bellekler çıktıları etkiler ve sonucun doğruluğunu, tutarlılığını artırır. En tipik ve yaygın kullanılan ‘uzun-kısa süreli hafıza (long short-term memory veya LSTM) olarak adlandırılan yapılarıdır.

TSA geri beslemeli olup çıktıyı aynı zamanda girdi olarak kullanır. Bu durum sıralı veriler için, metin oluşturmak için bir üstünlük sağlar ve bu tür görevler için uygun hale getirir.

### 2.2.2 Derin inanç ağıları

Derin İnanç Ağları, birden daha fazla kısıtlı Boltzmann makinelerinden (KBM'den) oluşan bir DSA mimarisidir (Hinton, Osindero & Teh, 2006). Genellikle gözetimsiz öğrenme yaklaşımları için tercih edilir. Bu nedenle etiketlemeye ihtiyaç duymaz. Nesne algılama, doğal dil işleme, konuşma tanıma gibi görevleri yerine getirebilir.

DİA, katmanlardaki KBM'lerin etkileştirilmesi ile oluşturulur. Her bir KBM, iki katmandan oluşur ve enerji tabanlı bir olasılık modeli şeklinde çalışır. Alt katmandaki girdilerden elde edilen öznitelikler üst katmanda temsil edilir. Çok sayıda KBM'e kullanılması, verilerin temsillerini öğrenme ve karmaşık yapıları yakalama da oldukça etkili olur (Ghojogh ve diğerleri, 2021).

DİA, ön eğitim olarak gözetimsiz aşamalı öğrenmeyi uygular. İlk aşamada, KBM'ler, alt katmandan gelen girdiler ve üst katmandaki gizli niteliklerle katman katman eğitilir. Bu, ağın katmanlar arasında ilerledikçe eğitim verilerinin daha üst düzey özelliklerini öğrenmesini sağlar. Denetimsiz ön eğitim tamamlandıktan sonra, kötü niyetli faaliyetleri tespit etmedeki doğruluğunu artırmak için etiketli eğitim verileri kullanılarak ağa ince ayar (fine-tuning) yapılır (Sohn, 2021).

DİA, özellik öğrenme ve temsil öğrenme konusunda üstündür. Derin yapıları sayesinde, verilerdeki karmaşık ve hiyerarşik ilişkileri yakalayabilirler. Bu nedenle, görüntü işleme, doğal dil işleme, ses işleme gibi alanlarda kullanılarak çeşitli görevlerde başarılı sonuçlar elde edilebilir.

Ancak, derin inanç ağlarının eğitimi ve kullanımı bazı zorluklar içerebilir. Eğitim süreci zaman alabilir ve hesaplama gücüne ve veri miktarına bağlı olarak yoğun olabilir.

### 2.2.3 Çekişmeli üretken ağları

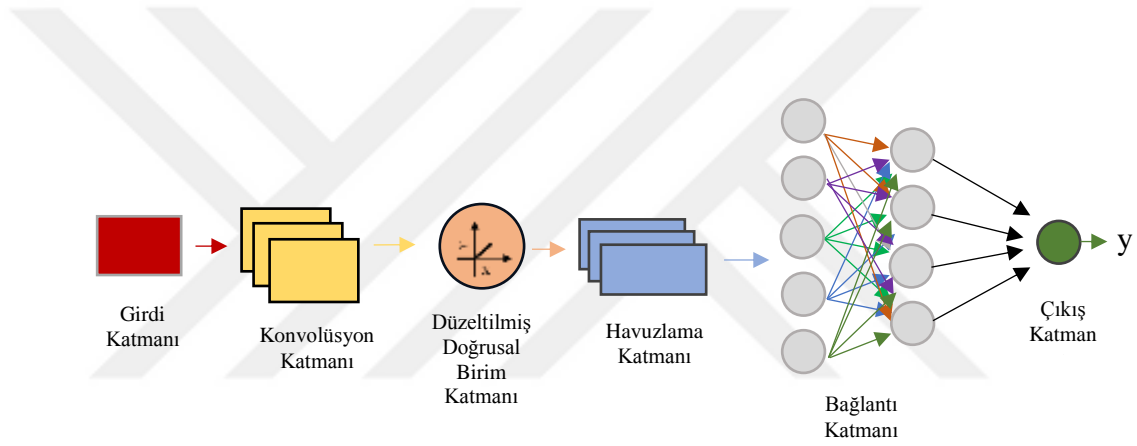
Düşman üretken ağları olarak da bilinir. Literatüre GAN (Generative Adversarial Networks) olarak geçmiştir. Mimarisinde birbiri ile rekabet eden iki ağ yapısı bulunur. Bu ağ yapılarından biri üreteç (generator), yapay zekadan istenilen ve olmayan veriyi üretmeye çalışan yapı, diğeri ise ayırt edici (discriminator), gerçekçilik düzeyini ve kalitesini belirleyen ilk ağ yapısına göre daha tutucu olan yapı yer alır. Bu iki yapı bir dengelem sağlar ve model hiç olmayan ama benzerlerine benzeyen yeni örnekler üretebilir. Gerçekçi görüntü, animasyon ve video sentezinde,

yetersiz veri olması durumunda veri çoğaltmakta, yaratıcı müzik, metin ve benzeri içerik üretiminde bu ağ mimarisi kullanılabilir.

#### 2.2.4 Konvolüsyonel sinir ağları

KSA, fotoğraf, video vb. görsel verilerin işlenmesi ve analizi için geliştirilmiş bir mimaridir. Görüntü sınıflandırma, nesne algılama, yüz tanıma, tıbbi görüntüleme gibi görevleri yüksek performansla yerine getirebilir (Shruti & Rekha, 2023).

Şekil 2.3'de KSA'nın temel mimari yapısı gösterilmiştir. Tipik bir KSA mimarisi, giriş ve çıkış katmanlarının yanı sıra konvolüsyon (convolution) katman, düzeltilmiş doğrusal birim (rectified linear unit) katmanı, havuzlama (pooling) katmanı ve tam bağlı (fully connected) katmandan oluşur (Gu ve diğerleri, 2018) (Erdoğan, 2019).



Şekil 2.3: Konvolüsyonel Sinir Ağı Modeli

*Konvolüsyon Katmanı:* Konvolüsyon katmanları, girdi veri üzerinde belirli filtrelerin uygulanmasıyla yeni özellik haritalarının oluşturulmasını sağlar. Her bir filtre, görüntü üzerinde belirli özellikleri (kenarlar, köşeler vb.) yakalamak için kullanılır. Bu filtreler, genellikle küçük boyutlu pencere (çekirdek) üzerinde kaydırılarak uygulanır ve farklı bölgelerdeki özellikleri algılamaya yöneliktir.

*Düzeltilmiş Doğrusal Birim Katmanı:* Düzeltilmiş doğrusal birim katmanı konvolüsyon katmanlarının çıkışına uygulanan bir aktivasyon fonksiyonu (örneğin ReLU) ile non-lineerlik ekler. Bu, ağın daha karmaşık özellikleri öğrenebilmesini sağlar ve aynı zamanda doğrusal olmayan ilişkileri yakalamasına yardımcı olur.

*Havuzlama Katmanı:* Havuzlama katmanları, özellik haritalarının boyutunu ve hesaplama yükünü azaltmak için kullanılır. Bunun için belirli bir bölgede bulunan

özellik haritalarını toplar ve özetler. Bunun için maksimum havuzlama veya ortalama havuzlama yöntemini kullanır.

Genellikle bu katmanların birleşimiyle oluşan tekrarlayan bir yapıya sahiptir. Birden çok konvolüsyon katmanı, aktivasyon katmanları ve havuzlama katmanları bir araya gelerek, görsel verilerin daha yüksek seviyede temsilini elde eder. Bu tekrarlayan yapı, daha düşük seviyedeki özellikleri tespit etmek ve bu özellikleri birleştirerek daha soyut, karmaşık özellikler oluşturmak için ağın derinliklerine doğru ilerlemeyi sağlar.

Bu tekrarlayan yapı, önceki katmanlarda yakalanmış temel desenlere dayalı olarak daha yüksek düzeyde özelliklerin çıkarılmasına olanak tanır. İlk katmanlar genellikle basit kenar veya köşe gibi düşük seviyeli özellikleri algılamak, daha sonraki katmanlar, bu düşük seviyeli özelliklerin kombinasyonunu kullanarak daha karmaşık özelliklere (örneğin göz veya yüz gibi) tepki verebilir. Böylelikle daha yüksek seviyeli görsel temsiller oluşturur.

*Tam Bağlı Katmanlar:* Yüksek seviyeli görsel temsiller oluşuktan sonra ağırlıkları kullanarak uygun etiketi tahmin eden son katmandır.

Tüm bu işlemlerden sonra model sınıflandırma, nesne tespiti veya diğer görsel görevleri başarı ile gerçekleştirir. Bu amaçla, KSA mimarisi ile özelleştirilmiş birçok algoritma vardır. Bu algoritmaların genel yapıları ve yaygın kullanılanları dikkate alındığında, tek çerçeve (single-shot) tabanlı algoritmalar ve bölge tabanlı (region-based) algoritmalar olarak iki ana gruba ayrılabilir.

#### **2.2.4.1 Tek çerçeve tabanlı algoritmalar**

Görsel verilerdeki nesnelerin sınıflandırılması ve sınırlama kutularının tahmin edilmesi işlemini tek bir geçişle gerçekleştirirler. Tek çerçeve tabanlı algoritmaların üstün oldukları taraf nesnelere tek bir adımla tespit ederek hızlı çıkarım elde etmektir. Bu da gerçek zamanlı tespiti sağlar. Gerçek zamanlı tespiti insan odaklı değerlendirirsek, bir nesnenin 24 ile 30 saniye başına kare (FPS) arasında algılanması yeterlidir. Günümüzde teknolojinin ilerlemesi insan odaklı algılamadan daha hızlı tespit gerçekleştirilebilmektedir. Bu da derin öğrenme kullanacak mobil robotların insan algısından önce tespit etme yeteneğine sahip olmaları anlamına gelir. Bu durumda güvenlik önlemleri belirlemeden risk boyutu tespiti edilmesini sağlayabilir.

Tek Çerçeve tabanlı algoritmaların temel felsefesi, nesne tespiti için hızlı ve gerçek zamanlı bir yaklaşım sunmaktır. Bu algoritmaların amacı, bir görüntüdeki tüm nesnelere tek bir adımda tespit etmektir, bu da diğer yöntemlere kıyasla daha hızlı çalışmalarını sağlar.

Tek Çerçeve tabanlı algoritmaların avantajları arasında hızlı çalışma süreleri, gerçek zamanlı nesne algılama yetenekleri ve daha az hesaplama maliyeti bulunur. Bunlar, özellikle uygulamalarda hızın ve anlık tepki süresinin önemli olduğu durumlarda tercih edilen algoritmalarlardır. Ancak, bazı durumlarda daha yüksek hassasiyet ve detaylı nesne tespiti gerektiren senaryolarda bölge tabanlı algoritmalara kıyasla daha düşük bir doğruluk seviyesine sahip olabilirler. Bu grupta yer alan ve en çok tercih YOLO (You Only Look Once - Sadece Bir Kez Bak) ve SSD (Single Shot MultiBox Detector - Tek Atış Kutu Algılama) algoritmalarıdır.

*YOLO nesne algılama algoritması:* görüntü öncelikle bir özellik haritasına dönüştürülür. Dönüştürülen özellik haritası işlenerek sınıflandırma ve sınırlama kutusu tahminlerini gerçekleştirilir. Birden çok ölçekli özellik haritalarını kullanıldığından her ölçekte nesnelere tespiti sağlayan sınırlama kutusu tahminleri gerçekleşmiş olur.

Özetle bu ağ, görsel girdiyi birden çok konvolüsyon ve havuzlama katmanı ile işler ve özellik haritasını çıkarır. Özellik haritası üzerinde sınıflandırma ve sınırlama kutusu tahminleri tam bağlantılı katmanları kullanarak gerçekleştirir. Böylece görsel girdide varsa nesne, nesnenin tespiti sınırlama kutusu ile gerçekleşmiş olur.

YOLO tek bir geçişle nesne tespiti yaptığından diğer algoritmalara kıyasla daha az hesaplama içerir. Hızlı olmasının nedenlerinden bir de budur. Böylece mikrodenetleyiciler gibi gömülü sistemler için de kullanılabilir.

YOLO nesne algılama algoritması ilk defa 2016 yılında kullanılmıştır. İlk sürüm YOLOv1'den sonra YOLOv8'e kadar çok farklı sürümleri yayınlanmıştır. Literatürde YOLO ailesindeki en hızlı algoritmalarından biri YOLOv5, en son sürümü ise YOLOv8'dir.

*SSD nesne algılama algoritması:* Çoklu ölçekli özellik haritaları kullanarak nesne algılamayı gerçekleştirir. Farklı ölçeklerdeki özellik haritalarından sınıflandırma ve sınırlama kutusu tahminlerini birleştirir. Bu birleştirmeyi sağlamak için konvolüsyon tabanlı bağlantı katmanlarını kullanılır. Böylece özellik haritalarına ait ölçekler

arasında bilgi akışı gerçekleşmiş olur ve nesne algılama performansını artırır. Birden çok ölçekli özellik haritaların kullanılması tespit edilen nesnenin farklı boyutlarda olmasının zorluğunun üstesinden gelinmesini de sağlar.

SSD nesne algılama algoritmaları için farklı varyasyonlar kullanılır. En yaygın kullanılan SSD300 ve SSD512 varyasyonlarıdır.

Çizelge 2.1’de YOLO ve SSD nesne algılama algoritmalarının karşılaştırılması yapılmıştır. Bu karşılaştırma genel bir yaklaşımdır. YOLO ve SSD sürümlerine ve varyasyonlarına bağlı olarak değişebilir.

**Çizelge 2.1:** YOLO SSD Nesne Algılama Algoritmaların Genel Karşılaştırması

	<b>YOLO</b>	<b>SSD</b>
<b>Yaklaşım</b>	Giriş görüntüsünü bir özellik haritasına dönüştürür ve tek bir geçişle tüm sınıflandırma ve sınırlama kutusu tahminlerini gerçekleştirir	Farklı ölçekli özellik haritalarını kullanarak nesne algılama yapar. Birden çok ölçekli özellik haritasından sınıflandırma ve sınırlama kutusu tahminlerini birleştirir.
<b>Ölçek çeşitliliği</b>	Bir özellik haritası üzerinde nesne tespiti yaptığından algılanan ölçek çeşitliliği küçük boyutlar için daha sınırlıdır.	Farklı ölçeklerdeki nesnelere algılama yeteneğinden dolayı algılanan ölçek çeşitliliği daha geniştir.
<b>Hassasiyet</b>	Daha büyük nesnelere daha iyi algılamaya odaklanır.	Daha küçük nesnelere daha iyi algılama eğilimindedir.
<b>Hız</b>	Tek geçişle tüm nesne tespiti işlemini gerçekleştirdiğinden hızlıdır.	Farklı ölçekli özellik haritalarının birleştirilmesine gerektiğinden işlem sayısı artacağından daha yavaş olabilir.
<b>Performans</b>	Daha büyük nesnelere tespitinde daha başarılıdır. Genel başarısı uygulamayla ilgilidir.	Farklı ölçeklerdeki nesnelere algılama yeteneğiyle daha başarılıdır. Genel başarısı uygulamayla ilgilidir.

#### 2.2.4.2 Bölge tabanlı algoritmalar

Bölge tabanlı algoritmalar görüntüleri tek seferde değil belli bölgeleri inceleyerek nesne tespiti gerçekleştirirler. Bu algoritmalarla bölge seçimi ve nesne sınırlama kutularının saptanmasına daha fazla odaklanılmıştır. Bölge tabanlı algoritmaların ilk sürümü R-CNN, gelişmiş sürümü Fast R-CNN ve daha da gelişmiş olan sürümü Faster R-CNN’dir. Bu üç versiyon arasındaki en temel farklılıklar bölge önerisindeki değişimdir. Faster R-CNN diğer versiyonlarda yer alan seçici arama yerine RPN kullanır. Faster R-CNN’de aynı zamanda diğer versiyonlarda bulunmayan “Nokta-Kutu Regresyon Ağı” da vardır.

*Bölge Öneri Ağı (RPN):* farklı boyutlarda ve oranlarda "ankar kutucuklar" (anchor boxes) adı verilen önceden tanımlanmış kutucuklar oluşturur ve bu kutucuklara, içerdikleri nesneyle ilgili olasılık değerlerini tahmin eder. Bu tahminler, potansiyel

nesne bölgelerini belirlemek için bir eşik değeri kullanılarak filtrelenir ve önemli olanlar daha sonra daha ayrıntılı olarak incelenmek üzere ilerleyen adımlara aktarılır.

*Nokta-Kutu Regresyon Ağı:* RPN tarafından belirlenen potansiyel nesne bölgeleri, daha sonra nokta-kutu regresyon ağına yönlendirilir. Bu ağ, her bir potansiyel bölge için gerçek nesne sınıfını tahmin etmek ve bu bölgeye ait doğru sınırlama kutusunu (bounding box) hesaplamak için kullanılır. Bu şekilde, nesnelerin sınıflarını belirleyebilir ve onları doğru bir şekilde sınırlama kutuları içinde tespit edebiliriz.

Faster R-CNN, bölge öneri ağı ve nokta-kutu regresyon ağının birleşimiyle çalışır ve bu sayede görüntülerdeki nesnelerin tespitini gerçekleştirir. Algoritma, ağ üzerindeki ağırlıkların eğitimi için genellikle büyük ölçekli veri setleri kullanır. Eğitim süreci, ağın nesne tespiti görevini optimize etmek ve doğru sınıf tahminleri ile sınırlama kutuları iyileştirmek için gerçek ve tahminlenmiş değerler arasındaki farkı azaltmaya odaklanır.

Faster R-CNN, genellikle nesne algılama problemlerinde yüksek hassasiyet ve hızlı hesaplama performansı sağlaması nedeniyle diğer versiyonlarına göre daha çok tercih edilir.

### **2.3 Endüstriyel Mobil Robotlar ve Güvenlik**

Robotik sistemler günümüzde insanlığın eriştiği en son teknolojik gelişmelerden biridir. Tekrarlayan işleri daha hızlı ve hassas yapmak için tasarlanan robotlar günümüzde kafeslerinden kurtularak, özgürleşmiş birer işbirlikçi mobil (gezgin) robotlara dönüşmüştür. Sağlıktan savunma sanayisine, tehlikeli veya hassas işlerden eğlence, eğitim türü işlere kadar birçok çalışma alanında robotlar görevlendirilmektedir (Gillan, 2020). Diğer mekatronik sistemlerde olduğu gibi robotlarda mekanik, elektronik, yazılım ve kontrol sistemlerini içerir. Çevrelerini algılar ve hassas bir şekilde istenilen operasyonları gerçekleştirir (Özkan, 2010).

Günümüzde internet, nesnelerin interneti, uzaktan kontrol, yapay zeka, simülasyon, bulut bilişim sistemleri, büyük veri (big data), siber güvenlik, katmanlı ya da eklemeli üretim ile yeni bir endüstriyel devrim başlamış olup fabrikalar hızla değişmekte ve akıllı fabrikalar haline gelmektedir (Badri, Boudreau-Trudel & Souissi, 2018). Bu köklü değişim endüstri 4.0 olarak adlandırılır ve en önemli ayaklarından biri robotik

sistemlerdir. Çizelge 2.2’de endüstride gerçekleşen köklü değişimlerin karşılaştırmalı olarak kapsadığı unsurları gösterilmektedir.

**Çizelge 2.2:** Endüstriyel Devrimlerin Karşılaştırılması

İçerdiği Unsurlar	Endüstri 1.0	Endüstri 2.0	Endüstri 3.0	Endüstri 4.0
Makine	+	+	+	+
Elektrik	-	+	+	+
Seri üretime yönelik tekrara dayalı görevler	-	+	+	Tercihen
Elektronik	-	-	+	+
Kontrol/Otomasyon	-	-	+	+
Yazılım	-	-	+	+
Robot kullanımı	-	-	+	+
Uzaktan kontrol	-	-	Sınırlı	+
Eklemeli Üretim (3D Printer)	-	-	-	+
Nesnelerin İnterneti	-	-	-	+
Bulut, Big Data	-	-	-	+
Yapay Zeka (AI)	-	-	-	+
Bilgi Teknolojileri (IT), Siber Güvenlik	-	-	-	+

İş sağlığı ve güvenliği (İSG) endüstri 1.0 ile başlamış olsa da en büyük gelişimini endüstri 3.0 ile sağlamış ve en önemli çalışmalar endüstri 3.0 sürecinde gerçekleşmiştir. Endüstrideki köklü değişimler her defasında üretim şeklini değiştirmekle kalmamış, iş sağlığı ve güvenliği algısını da değiştirmiştir. Çizelge 2.3 incelendiğinde Endüstri 3.0 ile Endüstri 4.0 değişen üretim şekli ve buna bağlı farklılaşan iş sağlığı ve güvenliği riskleri görülmektedir.

**Çizelge 2.3:** Endüstri 3.0’den Endüstri 4.0’e Geçerken Değişen Üretim Modeli ve Risk Farklılıkları

Endüstri 3.0		Endüstri 4.0	
Uygulama	Risk Durumu	Uygulama	Risk Durumu
Endüstriyel makine ve robotların önceden yapılandırmaya bir operatör tarafından her kullanım ve değişiklikte ayarlanması gerekir.	Her çalışma öncesi riskler için kontrol formları doldurulmalıdır.	Endüstriyel robotlar ve makineler akıllı sistemlerden oluşur ve operatöre ihtiyaç duymaz.	Makine ve robotlar risk kontrollerini kendileri yapar.
Endüstriyel robotlar ve makineler diğer makinelerle etkileşim içinde olmadan bağımsız olarak çalışır.	Her bir robot ve makine için ayrı bir risk analizi ve değerlendirilmesi yapılır.	Sistemlerin entegrasyonu ile akıllı makineler birbirleriyle bağımlıdır ve hem kendi işlevlerinden hem de diğer makinelerin işlevlerinden sorumludur.	Riskler ayrıştırılmaz, kapsayıcı ve bütüncüdür.

**Çizelge 2.3:** (Devamı) Endüstri 3.0'den Endüstri 4.0'e Geçerken Değişen Üretim Modeli ve Risk Farklılıkları

Endüstri 3.0		Endüstri 4.0	
Uygulama	Risk Durumu	Uygulama	Risk Durumu
Üretim çıktıları standarttır. Ürünler müşteriye özel üretilmez.	Sık sık risk analizine gerek yoktur. Üretim ve koşullar aynı olduğu sürece riskler de aynıdır.	Akıllı makineler ve sistemler, üretim süreçlerini esneklik kazandırabilir ve müşteri taleplerine ve tercihlerine göre ürünleri özelleştirilebilir.	Gerçek zamanlı oluşturulan, simülasyon veya hesaplamalarla güncellenen risk analizleri kullanılır.
Üretimde robot ve makineler kullanılsa da üretim ağırlıklı olarak insan işgücü ile gerçekleşir. Robot ve makineler insan kontrolünde çalışır, bağımsız değildir.	Makine insan uyumsuzluğundan kaynaklanan ergonomik ve fiziksel risklere odaklanılır.	Makineler yapay zeka ve robot teknolojisiyle çalıştıklarından, insan işgücü üretim merkezli olmaktan çıkar	Ergonomik riskler yerine insan robot etkileşimine bağlı risklerin ön planda olur.
Fabrika işleyişi, üretim, planlama vb. karar yapıları insan odaklıdır.	Riskler öznel ve insan yargısına bağlı oluşturulur. İnsana bağlı hatalar ve gecikmeler sık rastlanır.	Yapay zeka karar verme süreçlerinde önemli roller aldığından, fabrika içinde daha hızlı karar, sürekli kontrol ve değerlendirme yapılır.	Derin öğrenmeye dayalı, gerçek zamanlı güncellenen risk analizlerinin kullanılması hedeflenir.
Ham madde ve girdi envanterinin değişimin kontrolü zor olduğundan girdi sürecinde, piyasa ihtiyaçlarına göre çıktı sürecinde stoklama yapılır.	İnsan merkezli taşıma, yerleştirme süreciyle ilgili ciddi riskler oluşur.	Akıllı fabrikalar, endüstriyel süreçlerin entegrasyonu ve yapay zeka destekli sistemler sayesinde üretim kaynaklarını daha verimli kullanır. Müşteri odaklı üretim ve siparişlerin doğrudan gönderimi sağlar.	Stoklama ve stoklamadan kaynaklı riskler daha az oluşur.
İstihdam çalışanların bilgi, yetenek ve niteliğinden daha fazla emek gücü ön planda tutularak sağlanır. Çalışanların İSG kültürüne uyum sağlaması için önleyici yaklaşıma dayalı sürekli eğitim verilir.	Önleyici ve sınırlayıcı yaklaşıma dayalı, standart, tek yönlü ve periyodik olarak aynı konuların tekrarlandığı İSG eğitimleri uygulanır.	İstihdam da nitelik, yetenek, bilgi ve uyuma odaklanılır. Kendini geliştiren, değişime uyum sağlayan, esneklik gösterme becerisi yüksek çalışanlar istihdam edilir.	Etkileşim ve katılımın sağlandığı, gelişim ve inovasyon odaklı, özelleştirilmiş İSG eğitimleri uygulanır.

Robotlar Endüstri 3.0 ile üretim sürecine girmiştir. Her işlem adımı önceden belirlenerek tek tek programlanan bu robotlar çevrelerindeki değişimi dikkate almadan tekrarlı şekilde işlem adımlarını sırasıyla yapardı. Bu nedenle günümüzle kıyaslandığında kontrol edilmesi oldukça kolay, insan etkileşimi sınırlıydı. Bu sınırlamayı sağlayan en önemli faktör, Şekil 2.4'te görüldüğü gibi kafes içine alınarak çalıştırılmasıydı (Lohse & Evers, 2014).



**Şekil 2.4:** Endüstriyel Robotların Kafes İçinde Çalışması

**Kaynak:** Url-1

Teknolojideki gelişmeler sayesinde günümüzde artık robotlar insanlarla birlikte çalışmakta ve insan robot etkileşimi gerçekleşmektedir. Bu makinelere endüstriyel mobil robot veya cobot (kolaboratif robot) olarak adlandırılmıştır. İnsan endüstriyel mobil robot etkileşimi Şekil 2.5'te gösterilmiştir. İdeal durumda endüstriyel mobil robotlar insanlara zarar vermeden ve verilen görevi zamanında ve en hassas şekilde gerçekleştirmesi hedeflenmektedir. Fakat kimi zaman istenmeyen durumlar yüzünden robotlar etkileşim içinde oldukları insanlara ciddi zararlar verebilmektedir. Günümüzde, sensör, gerçek zamanlı ölçüm ve hızlı tepki süresi sayesinde mobil robot ile insan arasında minimum mesafe sağlanabilmektedir. Mobil robot insanla arasına koymuş olduğu bu fiziksel mesafe sayesinde çarpışmadan kaçınmayı sağladığından insana zarar vermemektedir (Safeea & Neto, 2019). Ayrıca insanlar ve işbirlikçi mobil robotlar birlikte, belli güvenlik kurallarına uyarak montaj bandında çalışabilirler (Gualtieri ve diğerleri, 2020). İşbirlikçi mobil robotlar insanlarla fiziksel etkileşim içinde olduğu durumlarda ise güç ve kuvvet sınırlaması yaparak çarpışma ya da sıkışma olması durumunda ciddi seviyede zarar vermezler. (Aivaliotis, 2019).



**Şekil 2.5:** İnsan Robot Etkileşimi

**Kaynak:** Url-2

İşbirlikçi mobil robotlar yapay zeka sayesinde bir insanın yapabileceği bir çok görevi başarı ile yerine getirmektedir. Özellikle insanlar için riskli olan tehlikeli görevleri (işleri), örneğin nükleer endüstrideki yüksek risk oluşturan görevleri bu robotlar yapmaktadır. İnsanların psikososyal sağlıklarını bozan, sıkıcı veya tekrar eden işlerde de mobil robotlar görev alabilmektedir. Bu sayede çalışanları fiziksel, kimyasal, ergonomik ve psikososyal risklerden korumaktadır. Bu bazı devletlerin ve kurumların mobil robot kullanımlarını teşvik edilmesini sağlamıştır. Örneğin Fransa'da Mayıs 2012 tarihinde 2012-639 sayılı kararname ile asbeste maruziyet riskini azaltmak için robot teknolojisinin kullanılması teşvik edilmiştir. (Uguina & Ruiz, 2019). Yine TotalEnergies ve Fransız devletin kurumu olan The Agence Nationale de la Recherche firması ile petrol ve gaz sahalarında mobil robotların kullanılması için 2013'ten 2017 yılına kadar yarışmalarla desteklediği bir araştırma geliştirme süreci yürütmüştür. Geliştirilen mobil robotlar, petrol ve gaz sahalarında (deniz altı dahil) sızıntıları tespit etmeyi ve onarmayı başarmıştır.

### **2.3.1 Mobil robotlar için güvenlik standartları**

Robotların hayatımıza girmesiyle birlikte, insan robot etkileşiminde üzerine tartışılan önemli konulardan biri de güvenlik olmuştur (Belzile ve diğerleri, 2021). İnsan robot etkileşimi hakkında yayınlanan ilk güvenlik standartları; koruyucu önlemler ve uyarı işaretleri gibi temel güvenlik gereksinimlerini kapsıyordu. Almanya'da 2011 yılında düzenlenen Hannover Fuarı'nda "Endüstri 4.0" kavramının ortaya çıkması, endüstride akıllı otomasyon sistemlerinin, özellikle insanlarla birlikte çalışmak üzere tasarlanan cobotların (işbirlikçi robotların) yaygınlaşmasının habercisi oldu. İnsanlarla çok yakın çalışan cobotların yaygınlaşması güvenlik standartlarının güncellenmesini gerektirdi. Günümüzde mekatronik sistemler için uygulanan onlarca

standart arasında, özellikle robotlar için özelleşmiş olan en önemlileri Çizelge 2.4’de verilmiştir.

**Çizelge 2.4: Robotlarda Güvenlik Standartları**

Standart No	Standart Adı	İçeriği
ISO 10218:2011	Robotlar ve robotik cihazlar - Endüstriyel robotlar için güvenlik gereksinimleri	Endüstriyel robotlar için geliştirilmiş bir dizi uluslararası güvenlik standardı olup robot risk değerlendirmesi, koruyucu önlemler ve kontrol sistemleri gibi güvenlikle ilgili hususlar da dahil olmak üzere endüstriyel robotların tasarımı, kurulumu ve işletimi için gereklilikleri belirtir. Amerika Birleşik Devletleri'ndeki Robotik Endüstriler Birliği (RIA) tarafından yayınlanan eşdeğer standart adı ANSI/RIA R15.06-2012'dir.
ISO 13482:2014	Robotlar ve robotik cihazlar - Kişisel bakım robotları için güvenlik gereklilikleri	Kişisel bakım robotları için güvenlik gereksinimleri, tasarım ilkeleri ve risk değerlendirmeleri gibi konuları kapsar.
ISO/TS 15066 :2016	Robotlar ve robotik cihazlar - İşbirlikçi robotlar	Cobot olarak da bilinen işbirlikçi robotlar için teknik bir standarttır. Cobotların insanlarla birlikte çalıştıkları ortamlarda güvenli kullanımına yönelik kılavuz ilkeler sunmaktadır. Bunlar içinde robot hızı ve kuvvet sınırlama gibi konular da vardır. ISO 10218-1 ve ISO 10218-2'de verilen işbirlikçi endüstriyel robot çalışmasıyla ilgili gereksinimleri ve kılavuzu tamamlar. Standart, ISO 10218-1 ve ISO 10218-2'de açıklandığı gibi endüstriyel robot sistemleri için geçerlidir.
ISO 18646-1:2017	Robotik - Servis robotları için performans kriterleri ve ilgili test yöntemleri	Hizmet robotları için geliştirilmiş ve güvenlik için yönergeler sağlayan bir standarttır. Standart, kamusal alan, sağlık hizmetleri ve ev tipi robotlar dahil her türlü hizmet robotlarının tasarımı, kurulumu ve bakımına yönelik gereklilikleri belirtir.
ANSI/RIA R15.08-2020	Endüstriyel mobil robotlar - Güvenlik Gereklilikleri	Bölüm 1; endüstriyel mobil robot üreticileri için güvenlik gereksinimleri, tehlikeleri, riskleri ve gerekli önlemleri tanımlar. Bölüm 2; tesislerde güvenli bir mobil robot sisteminin tasarımı, kurulumu ve entegrasyonu tanımlar. Endüstriyel mobil robotlar etkileşime giren çalışanların eğitimi de bu kapsam içindedir. Bölüm 3; endüstriyel mobil robotların güvenli kullanımı ve bakımı hakkında temel bilgiler yer alır.
ISO 8373:2021	Robotik ve robotik cihazlar – Teknik Kelimeler Sözlüğü	Endüstriyel ve endüstriyel olmayan robotlarla ilgili terimler ve tanımlar içeren uluslararası standarttır.

**Kaynak:** Belzile & St-Onge, (2022)

### 3. MATERYAL ve YÖNTEM

#### 3.1 Güvenlik Önlem Boyutunu Belirleyen Kriterler

Bir mobil robotun güvenlik önleminin kriter doğrultusunda derecelendirilmesi için çalışma ortamında bulunan kişinin koruyucu ekipman kullanımı ve koruyucu ekipmanın yetkisine uygun olması amaçlanmış ve koruyucu ekipman kullanımı da dikkate alınarak derin öğrenme ile tespit edilmesi istenilen dört farklı kriter belirlenmiştir. Bu kriterler ve bu kriterlerle uygulanabilecek senaryolar Çizelge 3.1 ve Çizelge 3.2’de sunulmuştur. Böylece bir mobil robot için Çizelge 3.1’de belirtilen Senaryo 1, Çizelge 3.2’te belirtilen Senaryo 2 veya bunların dışında daha karmaşık ve farklı güvenlik önlemi alma senaryoları tercih edebilir.

**Çizelge 3.1:** Senaryo 1 Güvenlik Önlemi Almak İçin Kriterler

Sınıf	Koruyucu ekipman kullanımı/rengi	Güvenlik durum	Güvenlik önlemi	Belirlenen kriter	
3	Kullanılıyor/mavi	Güvenli durum, sürekli iş birliği	Takip	Çalışan Korunaklı	1. Derece Yetkili
2	Kullanılıyor/sarı	Dikkatli durum, geçici iş birliği	Güç/Kuvvet Sınırlama		2. Derece Yetkili
1	Kullanılıyor/beyaz	Belirsiz durum, İş birliğinden kaçınma	Geri çekilme		Misafir
0	Kullanılmıyor	Güvensiz durum	Görevi Durdurma	Çalışan Korunaksız	

**Çizelge 3.2:** Senaryo 2 Güvenlik Önlemi Almak İçin Kriterler

Sınıf	Koruyucu ekipman kullanımı/rengi	Güvenlik durum	Güvenlik önlemi	Belirlenen kriter
3	Kullanılıyor Yetkili	Güvenli durum Sürekli iş birliği	Yakın çalışma (en yakın 1 m.)	Çalışan yetkili ve yakın çalışmaya uygun
2	Kullanılıyor Yetkili olmayan	Dikkatli durum Geçici iş birliği	Dikkatli çalışma (en yakın 3 m.)	Çalışan yetkili değil
1	Kullanılmıyor Yetkili	Belirsiz durum İş birliğinden kaçınma	Uzak çalışma (en yakın 5 m.)	Çalışan yetkili ancak korunaksız
0	Kullanılmıyor Yetkili olmayan	Güvensiz durum Görevi bekletmeye alma	Görevi Durdurma	Çalışan yetkili değil ve korunaksız

#### 3.2 Model Oluşturma

Derin öğrenmede, nesne algılama mimarileri genellikle KSA kullanılarak oluşturulur. En yaygın kullanılan nesne algılama mimarileri arasında R-CNN, SSD

ve YOLO bulunmaktadır (Girshick ve diğerleri, 2015), (Redmon ve diğerleri, 2015), (Liu ve diğerleri, 2016). Bu algoritmaların doğruluk ve hız konusunda daha gelişmiş olan 3 versiyonun karşılaştırılması Çizelge 3.3’de verilmiştir. Doğruluk ve hız konusunda en iyi denge YOLOv5 versiyonunda görülmektedir. Bu çalışmada hem hız hem de doğruluk açısından iyi performans gösteren YOLOv5 ve hala araştırma aşamasında olan ve YOLO ailesinin son sürümü olan YOLOv8 kullanılmış ve karşılaştırılmıştır.

**Çizelge 3.3:** Nesne Tespitinde Kullanılan En Yaygın Algoritma Versiyonlarının Karşılaştırması

Algoritma	Yapısı	Özellikleri
SSD MobileNetv2	Tek bir ağ yapısında durum ve nesne algılama ve sınıflandırma yapabilen bir algoritmadır.	En hızlı çıkarım gerçekleştirme süresine sahip (Neftali ve diğerleri, 2022).
YOLOv5	Durum ve nesne algılama ve sınıflandırma işlemini tek seferde gerçekleştirir.	Doğruluk ve hız konusunda en iyi denge (Neftali ve diğerleri, 2022). (Mahendrakar ve diğerleri, 2022).
Faster R-CNN	İki aşamalı bir ağ yapısına sahiptir. Önceden tanımlanmış referans (bağlantı) noktaları (anchors) kullanarak ilgi bölgeleri (region of interest) oluşturulmak için RPN kullanır.	Doğruluk performansı en yüksek (Mahendrakar ve diğerleri, 2022).

### 3.2.1 Veri seti hazırlama ve ayırma

Çalışanın KKD bilgisi baret tespiti ile yetki seviyesi ise iki farklı yöntemle tespit edilmek istendiğinden Model A ve Model B eğitim veri setleri olmak üzere iki ayrı veri seti oluşturulmuştur. Çalışanın yetkisini belirleyen iki unsur tespit edilmesi hedeflenmiştir. Bu unsurlardan biri baret rengi diğeri ise iş yeleşti türüdür.

Model A’da 3 ayrı baret rengi tespiti ile yetki seviyesi belirlenmek istenmiştir. Mavi, sarı ve beyaz renkler hedeflenmiştir.

Model B’de iş yeleşti türü ile yetki seviyesi belirlenmek istenmiştir. Genellikle yönetici, mühendis ve teknikerlerin giydiği omuzdan reflektörlü ikaz yeleşti yetkili olarak kabul edilmiş ve sadece bu tip yeleştinin tespit edilmesi hedeflenmiştir.

Veri setinin sınıflandırılmasına genel bir bakış Model A için Şekil 3.1’de, Model B için Şekil 3.2’de ve istatistiksel bilgiler Model A için Çizelge 3.4’te, Model B için Çizelge 3.5’te verilmiştir. Model A ve Model B veri setleri 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 temsiliyet sağlaması hedeflenmiş ve aynı zamanda aşırı uyum (aşırı öğrenme) sorununun önüne geçilmiştir.



Şekil 3.1: Model A Veri Setinde Yer Alan Görüntü Örnekleri

Çizelge 3.4: Model A Veri Seti İstatistikleri

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



**Şekil 3.2:** Model B Veri Setinde Yer Alan Görüntü Örnekleri

**Çizelge 3.5:** Model B Veri Seti İstatistikleri

Sınıf	Sınıf tanımı	Eğitim veri seti	Doğrulama veri seti	Test veri seti	Toplam veri adeti
3	KKD kullanan yetkili	315	135	50	500
2	KKD kullanan yetkili olmayan	315	135	50	500
1	KKD kullanmayan yetkili	315	135	50	500
0	KKD kullanmayan yetkili olmayan	315	135	50	500
Toplam		1260	540	200	2000

### 3.2.1.1 Eğitim veri seti

Eğitim veri kümesi olarak da adlandırılır. Modelin öğrenme sürecinde doğrudan kullanılan ve eğitim performansını artırmak için parametreleri ayarları güncellenerek yeniden değerlendirilen verilerdir.

### 3.2.1.2 Doğrulama veri seti

Doğrulama veri kümesi olarak da adlandırılır. Modelin hiper-parametrelerini ayarlarken eğitim veri kümesi üzerinde elde edilen bir modelin tarafsız bir değerlendirmesini yapmak için kullanılan veri örneğidir. Doğrulama veri setleri eğitimi sağlayan yığınlar içinde kullanılmaz. Bu veri seti, modelin genellemesini

ölçmek ve aşırı uyumu (overfitting) tespit etmek amacıyla, eğitim süresince eğitimden bağımsız olarak kullanılır. Örneğin, doğrulama veri kümesi eğitim çıktılarında yakınsılaşma yaparsa eğitim aşırı doyuma gidiyordur anlamına gelir ve eğitim sonlandırılarak veri setleri, hiper-parametreler tekrar gözden geçilir.

### **3.2.1.3 Test veri seti**

Test veri kümesi olarak da adlandırılır. Eğitim aşamasında eğitim ve doğrulama kullanılmamış ve eğitim tamamlandıktan sonra eğitilmiş modelin ilk defa karışılacağı veriler üzerinden model performansının değerlendirilmesi amacıyla ayrılan veri setidir.


### **3.2.2 Görüntü ölçekleme**

Verilerin belirlenen bir piksel boyutu ile standartlaştırılarak, etiketleme, eğitim ve işleme uygun hale getirilmesidir. YOLO için görüntü ölçeklendirmede kullanılan standart bir piksel boyutu yoktur; bunun yerine, piksel boyutu nesnenin türüne ve çalışmanın içeriğine göre belirlenir. En uygun seçim, modelin farklı boyutlarda eğitilmesinin sonuçlarına göre belirlenebilir (Balmik, Barik, & Nandy, 2023). Eğitim modeli bittikten sonra çıkarım için kullanılacak görüntü ölçütü çıkarım süresini belirler. Bu çalışmada, Model A ve Model B’de yer alan bütün veriler 416x416 piksel boyutuna yeniden boyutlandırılarak hem hızlı çıkarım elde edilmesi hem de doğru tahminler yapılırken veri kaybının önlenmesi sağlanmıştır.

### **3.2.3 Etiketleme**

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 (Khalid ve diğerleri, 2023). 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.

Şekil 3.3'te modelde kullanılacak mavi renkli koruyucu ekipman sınıfı üzerinden etiketleme, Şekil 3.4'te ise KKD kullanan ve yetkili sınıfı üzerindeki etiketleme için gerekli olan sınırlama kutusunun belirlenmesi ve böylece herhangi bir etiketleme programı yardımı ile sınıf bilgisinin ve koordinatlarının txt uzantılı dosyaya kaydedilmesi görülmektedir.



(a)

3 0.5132211538461539 0.3557692307692308 0.4074519230769231 0.42788461538461536

(b)

**Şekil 3.3:** Model A a: Sınırlama Kutusunun Belirlenmesi, b: Sınıf ve Koordinat Bilgisinin Txt Uzantılı Dosyaya Kaydedilme Biçimi



(a)

Dosya	Düzenle	Görünüm
0	0.5276442307692307	0.48677884615384615 0.7115384615384616 0.9350961538461539

(b)

**Şekil 3.4:** Model B a: Sınırlama Kutusunun Belirlenmesi, b: Sınıf ve Koordinat Bilgisinin Txt Uzantılı Dosyaya Kaydedilme Biçimi

### 3.2.4 Hiper-parametreler

Bir görüntüdeki nesnelere ilişkin sınırlama kutusu koordinatlarını veya diğer sürekli öznitelikleri tahmin etmeye regresyon denir. Regresyon kayıp fonksiyonlarının geri bildirim ile güncellenen ve iyileşen bir süreçtir. Kayıp fonksiyonları, tahmin edilen değerler ile gerçek değerler arasındaki hatayı ölçmek için kullanılır. Regresyon modeli daha sonra hatayı azaltmak için güncellenir. Bu işlem hata minimize edilene kadar tekrarlanır. Kayıp fonksiyon türleri modele göre değişir. Genel anlamda kayıp fonksiyonları şunlardır.

Sınıf kaybı: Model tarafından tahmin edilen sınıf etiketleri ile gerçek sınıf etiketleri arasındaki hatayı ölçmek için kullanılır.

Sınırlama kutusu kaybı: Model tarafından tahmin edilen sınırlama kutusu koordinatları ile gerçek sınıf etiketinde bulunan sınırlama kutusu koordinatları arasındaki hatayı ölçmek için kullanılır.

Odak kaybı: Sınıfların veya örneklerin dağılımı asimetrik (birtakım görsellerin ve sınıfların diğerlerine göre daha sık kullanılması durumu) olduğunda derin öğrenme modellerinde dengesizlik ortaya çıkabilir. Dengesizliğin giderilmesi ve ayarlamaların yapılabilmesi için gerekli olan asimetrik dağılımdan kaynaklı hata ölçümüdür.

Her kayıp değeri ölçüldükten sonra eğitimin güncellemesine yenileme (iteration) denir. Yenileme için eğitim verilerinin tümü kullanılmasına gerek yoktur. Yığın veya paket (batch) adı verilen bir miktarının kullanılması yenileme için yeterlidir. Eğitim verileri üzerinden tam bir geçişin sağlandığı durum devir (epoch) olarak adlandırılır.

Bir modeli eğitmek için gereken devir sayısı, eğitim verilerinin boyutuna, modelin karmaşıklığına ve istenen doğruluk düzeyine bağlıdır. Genel olarak, daha fazla devir daha doğru bir modele yol açar, mutlak doğru bir önerme değildir. Daha fazla devir eğitim süresini uzatacağı gibi sınırlı eğitim verileri üzerinden gereğinden fazla eğitim yapılmasına neden olacağından modelin sadece eğitim verilerini çok iyi şekilde ezberlemesini de sağlayabilir. Bu nedenle, diğer düzenleme tekniklerini veya model değerlendirme yöntemlerini dikkate almadan sadece devir sayısını artırmak genelleştirmenin iyileştirilmesini garanti etmez ve potansiyel olarak aşırı uyuma yol açabilir. Bu nedenle eğitim sırasında iki ayrı veri kullanılır; eğitim verisi (training dataset) ve doğrulama verisi (validation dataset). Bunlar dışında eğitim tamamlandıktan sonra istenirse eğitilmiş modül eğitim sürecinden tamamen bağımsız

yeni bir deęerlendirmeye alınabilir. Bunun için ise test veri seti (test dataset) kullanılır.

Hiper-parametreler, eğitim süreci başlamadan önce belirlenen ayarlar veya konfigürasyonlardır. Bunlar, eğitim sırasında güncellenen model parametrelerinden farklıdır. Hiper-parametreler modelin davranışını ve performansını kontrol eder ve genellikle araştırmacı veya bir makine öğrenimi mühendisi tarafından ayarlanır. Model mimarisi, optimizasyon algoritması, öğrenme oranı, yığın boyutu vb. hiper-parametreler olup eğitim sürecinin çeşitli yönlerini etkilerler. Nesne algılama algoritmalarında kullanılan başlıca hiper-parametreler şunlardır.

Model mimarisi: Model mimarisi, nesnelere tespit etmek için kullanılan sinir ağının yapısını ifade eder. Nesne tespiti için kullanılacak birçok farklı model mimarisi vardır ve mimari seçimi modelin performansı üzerinde önemli bir etkiye sahip olabilir.

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 algılama modelinin performansını optimize etmek için ayarlanabilen önemli bir hiper-parametredir. Bir devir, tüm eğitim verilerinin tam bir geçişidir. Bir devir birden fazla iterasyondan oluşur.

Yığın (Batch): Tüm veri setini oluşturan alt veri kümelerini ifade eder. Eğitim sırasında model ağırlıklarının her bir işlenen veriden sonra güncellenmesi yerine, ağırlıkların kümelenen 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.

Önceden Eğitilmiş Model Kullanımı (Pretrained): Bir eğitim modelini sıfırdan eğitmek yerine önceden eğitilmiş bir model üzerinden eğitmek için kullanılan yöntemdir (Bozinovski & Fulgosi, 1976). YOLO'nun 80 nesne için önceden eğitilmiş hazır modelleri bulunur. Veya araştırmacı daha önce eğittiği bir modeli geliştirmek için yeni bir eğitim başlattığında sıfırdan başlamamak 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 ağları ağırlıkların oluşturulması için kullanılan algoritma türüdür. Bir optimize sağlayıcısının temel amacı çıkışın girişe bağlı oluşturduğu kayıp fonksiyonunu ölçmek ve en aza indirmektir. Stokastik gradyan inişi, Adam, AdamW ve RMSprop gibi birçok farklı optimizasyon algoritması vardır. Her sağlayıcı, modelin performansını artırmak için ayarlanabilen hiper-parametre seti sunar.

**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 başarılı olmamasına neden olabilir. Daha küçük öğrenme oranı daha istikrarlı bir yakınsama sağlar ancak eğitim süresi oldukça uzar, lokal minimum aşılabilir (Dong, Wang, Abbas., 2021). 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.

Tüm bu bilgiler doğrultusunda eğitim için önemli olan hiper-parametreler ve eğitim için kullanılan değerler Çizelge 3.6'da verilmiştir.

**Çizelge 3.6:** Model A ve Model B Eğitimde Kullanılan Hiper-parametre Değerleri

Hiperparametre	Türkçe Karşılığı	Eğitim Modeli için Kullanılan Değer
Epoch	Epok ya da Çevrim	213
Batch	Yığın	32
Pretrained	Ön Eğitilmiş Kullanım	True
Optimizer	Optimize Sağlayıcı	Adam
Initial Learning Rate	İlk Öğrenme Oranı	0.01
Final Learning Rate	Son Öğrenme Oranı	0.001

### 3.3 Model Performans Ölçüm Kriterleri

Bir model eğitim aşamasında ve eğitim tamamlandıktan sonra olmak üzere iki aşamada değerlendirilir. Eğitim aşamasındaki değerlendirme kayıp fonksiyonları, model performansı ve çıkarım süresi hesaplanırken, eğitilmiş modelin değerlendirilmesinde daha çok model performansına odaklanılır.

Modelin kayıp fonksiyonları eğitimin başarısı hakkında fikir verirken, eğitim performans metrikleri doğrudan eğitimin performansı hakkında bilgi verir. Eğitim

kayıpları bir önceki konuda işlenmişti. Bu bölümde model performansının ölçüm kriterleri incelenecektir. Eğitim aşamasında olan veya eğitilmiş bir modelde ilk ölçülen parametreler karmaşıklık matrisidir. Karmaşıklık matrisi her sınıf için 4 kategoriye ayrılır. Bunlar, doğru pozitif (DP), yanlış pozitif (YP), yanlış negatif (YN) ve doğru negatif (DN) şeklinde isimlendirilir ve Çizelge 3.7’de her test edilecek görsel için nasıl kategori edileceği açıklanmaktadır. Karmaşıklık matrisinin daha net anlaşılması için bir sınıf üzerinden oluşturulan örnek Çizelge 3.8’de gösterilmiştir.


**Çizelge 3.7:** Karmaşıklık Matris Şablonu

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

**Çizelge 3.8:** Örnek: Beyaz Renk Koruyucu Ekipman Kullanımının Test Edilmesi

Etiketdeki Durumu	Eğitim modelinin çıktısı	Sonuç	Test Sonucu
Pozitif (Beyaz renk koruyucu ekipman kullanımı var)	Pozitif (Algılandı)	Nesne var doğru algılandı (Doğru çıkarım)	Doğru Pozitif
Pozitif (Beyaz renk koruyucu ekipman kullanımı var)	Negatif (Algılanmadı)	Var olan nesne algılanmadı (Hata)	Yanlış Negatif
Negatif (Beyaz renk koruyucu ekipman kullanımı yok)	Pozitif (Algılandı)	Nesne yok varmış gibi algılandı (Hata)	Yanlış Pozitif
Negatif (Beyaz renk koruyucu ekipman kullanımı yok)	Negatif (Algılanmadı)	Nesne yok ve algılanmadı (Doğru çıkarım)	Doğru Negatif

Şekil 3.5’te örnek bir ölçme gösterilmektedir. Şekil 3.5 incelendiğinde, a görselinde baret kullanan yetkili tespiti doğru tespit edildiğinden doğru pozitif (TP), b görselinde baret kullanan yetkili, baret kullanan yetkisiz olarak tespit edildiğinden yanlış negatif (FN) ve c görselinde ise baret kullanmayan yetkili, baret kullanan yetkili şeklinde tespit edildiğinden yanlış pozitif (FP) olarak ölçülür.



**Şekil 3.5:** Model B sınıfı için a: Doğru Pozitif (TP), b: Yanlış Negatif (FN), c: Yanlış Pozitif (FP)

Karmaşıklık matrisi oluşturulduktan sonra denklem 3.1, 3.2, 3.3, 3.4 ve 3.5’de karmaşık matris değerlerine göre performans değerlendirmesi için türetilmiş duyarlılık, kesinlik, F1 skoru, ortalama hassasiyet (AP) ve genel ortalama hassasiyet (mAP) metriklerine ait eşitlikler yer alır. Bu metrikler literatürde en çok kullanılan ölçütlerdir (Atilla, 2023)

$$\text{Kesinlik } (p) = \frac{\text{Tahmin edilen toplam doğru pozitif sayısı}}{\text{Toplam pozitif tahmin sayısı}} = \frac{TP}{TP+FP} \quad (3.1)$$

$$\text{Duyarlılık } (r) = \frac{\text{Tahmin edilen toplam doğru pozitif sayısı}}{\text{Etiketlenen toplam pozitif doğru sayısı}} = \frac{TP}{TP+FN} \quad (3.2)$$

$$\text{F1 Skoru} = 2 * \frac{(\text{Kesinlik} * \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} = 2 * \frac{(p*r)}{(p+r)} \quad (3.3)$$

$$\text{Ortalama Hassasiyet (AP)} = \int_0^1 p(r)dr \cong \sum_{k=1}^n p(k) \cdot \Delta r(k) \quad (3.4)$$

$$\text{Genel Ortalama Hassasiyet (mAP)} = \frac{\sum AP}{\text{Sınıf sayısı}} \quad (3.5)$$

Keskinlik, 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 bu ortalama hassasiyetlerin toplanarak sınıf sayısına bölünmesi ile elde edilen ortalamadır.

Çalışmada son olarak GPU kullanılarak modelin tespit hızına bakılacaktır. Gpu, görüntüye dayalı görevleri yerine getirmek için geliştirilmiş özel bir işlemcidir. GPU'lar çoklu sinir ağlarının paralel işlenmesine olanak sağlamaktadır. Bu da çok büyük veri kümelerinin daha hızlı işlenmesini sağlar. Bu nedenle bilgisayarlarda yaygın kullanılan CPU (Central Processing Unit - Merkezi İşlem Birimi) ile karşılaştırıldığında çok daha hızlıdır. CPU'lar genel amaçlı kullanımlar için tercih edilirken GPU'lar grafik oluşturma, modelleme, makine öğrenimi ve video işleme gibi görevler için kullanılır. GPU'ların maliyeti CPU'lara göre biraz daha maliyetlidir, CPU'lardan daha fazla ek güç tüketimi de vardır. Bu nedenlerden dolayı kişisel bilgisayarlarda pek tercih edilmemektedir. GPU'ların maliyeti ve güç tüketimi düştükçe CPU'larla birlikte bilgisayarlarda yer alması düşünülmektedir. Çizelge 3.9'da CPU ile GPU karşılaştırması yer almaktadır.

**Çizelge 3.9:** CPU ile GPU Karşılaştırması

Özellik	CPU	GPU
Kullanım	Genel amaçlı kullanım	Yoğun grafik işlemleri için özel kullanım
Görevler	Programları çalıştırmak, verileri işlemek, cihazları kontrol etmek, diğer bilgisayarlarla iletişim kurmak	Grafik ve video işleme, makine öğrenimi
Mimarlık	Tek çekirdekli veya çok çekirdekli	Çok çekirdekli
Çalışma hızı	Tipik olarak 2-4 GHz	Tipik olarak 1-2 GHz
Paralellik	Komut düzeyinde paralellik	İş parçacığı düzeyinde paralellik
Kullanıcıları	Bilgisayar kullanıcıları, yazılım geliştiriciler, donanım mühendisleri, BT uzmanları	Grafik uzmanları, oyun geliştiricileri, makine öğrenim mühendisleri

Bu çalışma için Nvidia RTX A4000 16GB GPU modülü kullanılmıştır. Kartın görseli Şekil 3.6'da ve kartın kullanıldığı bilgisayara ait teknik özellikler Çizelge 3.10'da yer almaktadır.



**Şekil 3.6:** Nvidia RTX A4000 16GB Modül

**Çizelge 3.10:** Uygulamada Kullanılacak Bilgisayarın Teknik Özellikleri

<b>Teknik Özellik</b>	<b>Açıklama/Detay</b>
GPU	Nvidia RTX A4000 16 GB
RAM	32GB DDR5
İşlemci	AMD Ryzen 5 7600X
İşletim Sistemi	Windows 11 Pro



## 4. ARAŞTIRMA SONUÇLARI

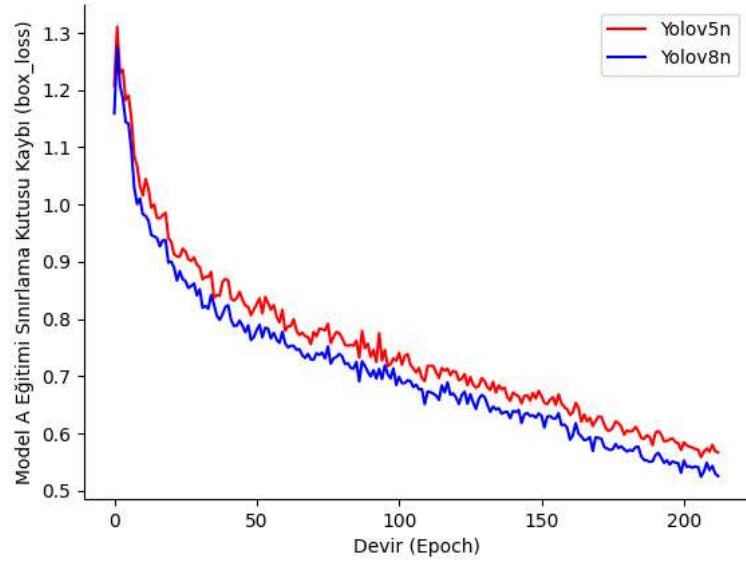
### 4.1 Eğitim Sürecinde Modeli Değerlendirme

Çalışmada Model A ve Model B için 2000 adetten toplam 4000 adet etiketleme gerçekleştirilmiştir. İki model içinde 2000 adet etiketin 1800 adedi eğitimi gerçekleştirmek ve eğitim sürecini doğrulamak, 200 adedi, tüm veri setinin %10'u, ise tamamlanmış eğitim modelini eğitim sonrası değerlendirmek için kullanılmıştır.


Eğitimin değerlendirmesinde kullanılan metrikler; kayıp fonksiyonları ve model metriklerin değerlendirilmesi şeklinde iki kısımdan oluşmaktadır. Kayıp fonksiyonlarında; sınırlama kutusu kaybına (box\_loss), sınıflandırma kaybına (cls\_loss) ve dağılım odak kaybına (dfl\_loss); model metriklerin değerlendirilmesinde ise, duyarlılık (recall), kesinlik (precision), F1 skoru, genel ortalama hassasiyetine (mAP) ve ayrıca algılama çıkarım süresine bakılmıştır. YOLOv5n ve YOLOv8n versiyonların ölçümlerinin aynı grafik üzerinden karşılaştırması için farklı renklerle aynı grafik üzerinden gösterilmiştir.

#### 4.1.1 Kayıp fonksiyonları değerlendirme

Sınırlama Kutusu Kaybı (Bounding Box Loss - box\_loss), tahmin edilen sınırlama kutusunun gerçek (önceden etiketlenen) sınırlama kutusunu referans aldığı anda oluşan hata miktarıdır (Zhang ve diğerleri, 2022). Bu değer 0 (sıfır) ise tahmin edilen sınırlama kutusuyla gerçek sınırlama kutusu arasında hiçbir hata olmadığı ve tamamen örtüştükleri anlamına gelir. Eğitim süreci ilerledikçe, sınırlama kutusu kaybı genellikle azalır. Şekil 4.1'de Model A ve Şekil 4.2'de ise Model B için sınırlama kutusu kayıpları görülmektedir. 213 devirden sonra, Model A için YOLOv5n versiyonu en düşük sınırlama kutusu kaybı 0.56698, YOLOv8n versiyonu 0.5244 olarak; Model B için YOLOv5n 0.69685, YOLOv8n ise 0,63997 olarak ölçülmüştür.




**Şekil 4.1:** Model A Eğitimi Sınırlama Kutusu Kaybı/Devir Eğrisi Grafığı




**Şekil 4.2:** Model B Eğitimi Sınırlama Kutusu Kaybı/Devir Eğrisi Grafığı

Sınıflandırma Kaybı (Classification Loss - cls\_loss), modelin doğru sınıflandırma yapma yeteneğini gösterir (Zhang ve diğerleri, 2022). Şekil 4.3 incelendiğinde Model A için YOLOv5n versiyonunun en düşük sınıflandırma kaybı 0.40516 YOLOv8n versiyonunun 0.3683 olarak; Şekil 4.4 incelendiğinde Model B için ise YOLOv5n versiyonunun en düşük sınıflandırma kaybı 0.62308 YOLOv8n versiyonunun 0,57943 olarak görülmüştür.




**Şekil 4.3:** Model A Eğitimi Sınıflandırma Kaybı/Devir Eğrisi Grafiği




**Şekil 4.4:** Model B Eğitimi Sınıflandırma Kaybı/Devir Eğrisi Grafiği

Dağılım Odak Kaybı (Distribution Focus Loss -dfl\_loss) da değerlendirmeye alınan kayıplardan biridir. Nesne algılamada sınırlama kutusunun konumu genel bir dağılım gösterir. Dağılım odak kaybı, ağırların rastgele (öngörülemez) ve esnek dağılımları ile oluşan sınırlama kutusunun sürekli konumları etrafındaki değerlerin olasılıklarını öğrenmeye hızlı bir şekilde odaklanması için ölçülen bir hata miktarıdır. (Li ve diğerleri, 2020), (Dong ve diğerleri, 2022), (Lou ve diğerleri, 2023), (Liu & Zhou, 2023). Şekil 4.5’de Model A , Şekil 4.6’da Model B için dağılım odak kaybı görülmektedir. Eğitim sonunda Model A, YOLOv5n versiyonu için 0.94251,

YOLOv8n versiyonu için 0.93787; Model B ise YOLOv5n modeli için 1.0312, YOLOv8n modeli için 1.0181 en düşük değerlerini almıştır.



Şekil 4.5: Model A Eğitimi Dağılım Odak Kaybı/Devir Eğrisi Grafiği




Şekil 4.6: Model B Eğitimi Dağılım Odak Kaybı/Devir Eğrisi Grafiği


#### 4.1.2 Model metriklerini değerlendirilme

Eğitim sırasında eğitim performansını belirleyen önemli metrikler; duyarlılık (recall), kesinlik (precision), F1 skoru ve genel ortalama hassasiyet (mAP) değerleridir. Bu metrik değerlerin 1 (bir)'e yaklaşması eğitim başarı oranının da arttığını gösterir (He ve diğerleri, 2022). Bu metriklerin hesaplanması için ise öncelikle doğru pozitif (TP),


yanlış pozitif (FP), doğru negatif (TN) ve yanlış negatif (FN) içeren karmaşıklık matrisinin bulunması gerekir (Zhu, Zhang & Jia, 2022). Model A için Şekil 4.7’de YOLOv5n’in, Şekil 4.8’de YOLOv8n’in Model B için ise Şekil 4.9’de YOLOv5n’in, Şekil 4.10’da YOLOv8n’in eğitim modeli karmaşıklık matrisi yer almaktadır. Tablo görselleri eğitim için kullanılan ‘ultralytics’ kütüphanesinin orijinal çıkışı olduğu için bire bir konulmuştur.




Şekil 4.7: Model A YOLOv5n Versiyonununun Eğitimi Karışıklık Matrisi



Şekil 4.8: Model A YOLOv8n Versiyonunun Eğitimi Karışıklık Matrisi

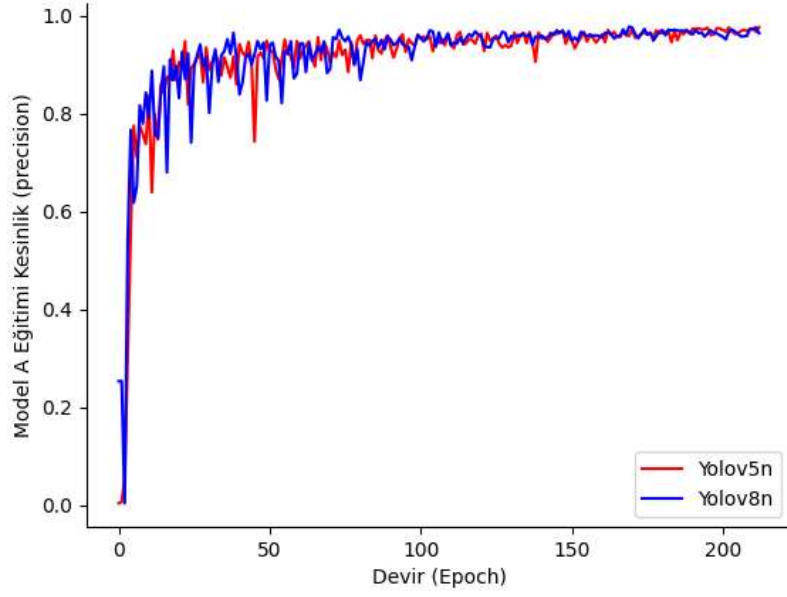


Şekil 4.9: Model B YOLOv5n Versiyonunun Eğitimi Karışıklık Matrisi

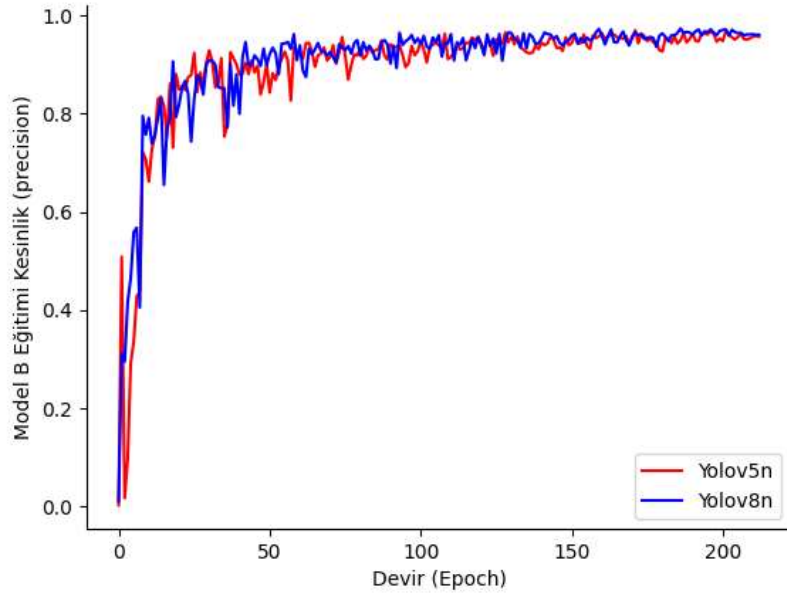


**Şekil 4.10:** Model B YOLOv8n Versiyonunun Eğitimi Karışıklık Matrisi

Modellerin eğitim süresince ölçülen kesinlik metrik değerleri, Model A için Şekil 4.11’de, Model B için ise Şekil 4.12’de verilmiştir. İki model ve versiyonlarına bakıldığında sonuçların birbirine çok yakın olduğu görülmüştür. Kesinlik ile modellerin yapmış olduğu tespitlerin doğruluk oranı ölçülür. İki modelin de tespit yeteneklerinin başarılı olduğu görülmüştür.




**Şekil 4.11:** Model A Eğitimi Kesinlik – Devir Eğrisi Grafiği




**Şekil 4.12:** Model B Eğitimi Kesinlik – Devir Eğrisi Grafiği

Duyarlılık metrik değer eğrisi Model A için Şekil 4.13’te, Model B için Şekil 4.14’te verilmiştir. Her iki modelden de yakın sonuçlar elde edilmiştir. Duyarlılık bir sınıf için etiketlenen örneklerinden ne kadarını doğru şekilde tespit edildiğinin ölçümüdür. İki modelin de başarılı şekilde sınıflandırma yaptığı görülmüştür.

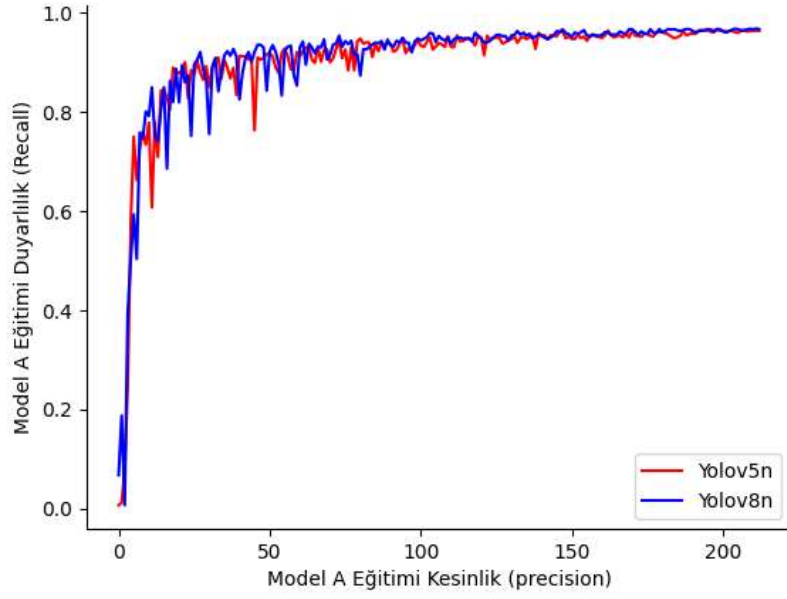


**Şekil 4.13:** Model A Eğitimi Duyarlılık – Devir Eğrisi Grafiği

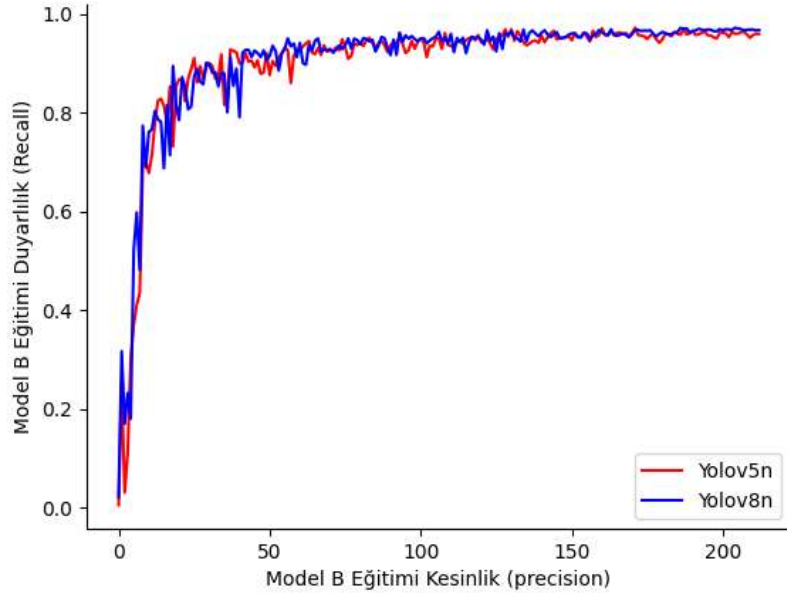


**Şekil 4.14:** Model B Eğitimi Duyarlılık – Devir Eğrisi Grafiği

Duyarlılık kesinlik eğrisi her devir (epoch) ile tekrar hesaplanan duyarlılık/kesinlik oranıdır. Şekil 4.15'te Model A, Şekil 4.16'da Model B'ye ait metrik değerler görülmektedir. Eğitimin devir sayısı ile değişen başarı oranını gösterir.




**Şekil 4.15:** Model A Eğitimi Duyarlılık - Kesinlik Eğrisi Grafiği




**Şekil 4.16:** Model B Eğitimi Duyarlılık - Kesinlik Eğrisi Grafiği

Güven eşiğine bağlı genel ortalama hassasiyet (mAP) eğitimin geneli için hesaplanan en önemli değerlendirme sonuçtur. Eğitim modelinin performansı genellikle bu ölçümle ifade edilir. Bu metriğin ortaya çıkabilmesi için güven eşiği de dikkate alınır. Bu nedenle her model için, 0.5 ve 0.5 – 0.95 güven eşiğinde olmak üzere iki ayrı grafik oluşturulmuştur. 0.5 güven eşiğinde mAP – devir sayısı grafiği Model A eğitimi için Şekil 4.17’de, Model B eğitimi için ise Şekil 4.18’de, 0.5 – 0.95 güven


eşğinde mAP – devir sayısı grafiği Model A eğitimi için Şekil 4.19’da, Model B eğitimi için ise Şekil 4.20’de verilmiştir.




Şekil 4.17: Model A Eğitimi 0.5 Güven Eşiğinde Map – Devir Eğrisi Grafiği



Şekil 4.18: Model B Eğitimi 0.5 Güven Eşiğinde Map – Devir Eğrisi Grafiği



**Şekil 4.19:** Model A Eğitimi 0.5 – 0.95 Güven Eşiğinde Map – Devir Eğrisi Grafiği



**Şekil 4.20:** Model B Eğitimi 0.5 – 0.95 Güven Eşiğinde Map – Devir Eğrisi Grafiği

FPS (Saniyedeki Kare Sayısı) metriği, modelin çalışma hızı hakkında bilgi verir. İşlem biriminin türü FPS değerini etkiler. CPU ve GPU kullanımında farklı sonuçlar elde edilir. CPU için 22.6 ile 29.2 milisaniye, GPU ise bir sonraki bölümde detaylı işlenmiş olup çıkarım süresi 2 milisaniyeden daha azdır. Bu da CPU için 44,25 ile 33,9'luk bir FPS değerine eş gelirken, GPU için ise 500 FPS'den daha fazla olduğu görülür.

Çizelge 4.1’de Eş.6 eşitliği uygulanarak Model A ve Model B eğitim modelinin sonuçları YOLOv5n ve YOLOv8n için karşılaştırmalı olarak verilmiştir. Çizelge 4.1 incelendiğinde kayıp fonksiyonlar, performans metriklerinde YOLOv5n ve YOLOv8n örtüştüğü görülür. Fakat CPU ile yapılan test çalışmasında hız konusunda YOLOv5n’nin YOLOv8n’ye göre %29.2 daha hızlı olduğu görülmüştür.

$$Performans = \text{yüzde fark} = \frac{\text{Yüksek Metrik Değeri} - \text{Düşük Metrik Değeri}}{\text{Düşük Metrik Değeri}} * 100 \quad (4.1)$$

**Çizelge 4.1: Eğitim Modellerinin Sonuçları ve Karşılaştırması**

Metrik adı	Model A		Model B		Versiyon Değerlendirmesi	Performans
	YOLOv5n	YOLOv8n	YOLOv5n	YOLOv8n		
Keskinlik	0,97705	<b>0,9783</b>	0,96995	0,9734	Model A: % <b>0,128 (YOLOv8n)</b> Model B: %0,355 (YOLOv8n)	
Duyarlılık	0,9641	<b>0,97314</b>	0,98097	0,98039	Model A: % <b>0,938 (YOLOv8n)</b> Model B: %0,059 (YOLOv5n)	
F1 Skoru	0,967511	0,968086	0,971501	<b>0,971816</b>	Model A: %0,059 (YOLOv8n) Model B: % <b>0,032 (YOLOv8n)</b>	
0.5 güven eşiğinde mAP	0,98555	<b>0,98794</b>	0,98606	0,98696	Model A: % <b>0,243 (YOLOv8n)</b> Model B: %0,091 (YOLOv8n)	
0.5-0.95 güven eşiğinde mAP	0,86924	<b>0,87643</b>	0,75334	0,76503	Model A: % <b>0,827 (YOLOv8n)</b> Model B: %1,55 (YOLOv8n)	
Çıkarım süresi (ms) (cpu)	<b>22,6</b>	29,2	27,9	29,5	Model A: % <b>29,2 (YOLOv5n)</b> Model B: %5.4 (YOLOv5n)	
Çıkarım süresi (ms) (gpu)	< 2 mili saniye					
FPS değeri (cpu)	<b>44,25</b>	34,25	35,84	33,9		
Çıkarım süresi (ms) (gpu)	> 500					

## 4.2 Eğitilmiş Modeli Değerlendirme

Eğitim aşamasında aşırı uyum ve benzer durumlar ortaya çıkmış ve yanıltıcı performans değerlerine yol açmış olabilir. Eğitim sonrası modülün, eğitim aşamasında kullanılmamış taze ve yeni veriler ile değerlendirilmesi gerekir.

Bu çalışmada da eğitim aşamasında kullanılmamış 200 adet taze ve yeni test veri seti ile eğitim sonrası modül değerlendirilmiştir. Değerlendirme sonucunda 0.5 güven eşik değerinde Model A YOLOv5n’in 95,68, Model A YOLOv8n’in 96,43, Model B YOLOv5n’in 95,74 ve Model B YOLOv8n’in 96,44 F1 skoru ortalaması elde ettiği görülmüştür. Bu sonuçlar hem eğitim performansı ile elde edilen değere yakındır ve modelin yeni verilere iyi genelleme yapabildiğini, hem de modellerin birbirine yakın performansa sahip olduklarını gösterilmiştir. Model A YOLOv5n ve YOLOv8n ile Model B YOLOv5n ve YOLOv8n versiyonlarının karışıklık matrisleri sırayla Şekil 4.21, Şekil 4.23, Şekil 4.25 ve Şekil 4.27’de, ayrıca eğitilmiş modellerin TP, FP, FN, keskinlik, duyarlılık ve F1 skor metrik sonuçları ise Şekil 4.22, Şekil 4.24, Şekil 4.26 ve Şekil 4.28’de verilmiştir.

Model A Yolov5n Confusion Matrix:

Gerçek\Algılanan	K(-)	K(B)	K(S)	K(M)	Arka plan
K(-)	48	0	0	0	2
K(B)	1	47	0	0	2
K(S)	0	4	45	0	1
K(M)	0	0	0	48	2
Arka plan	0	0	0	0	0

Şekil 4.21: Eğitilmiş Model A YOLOv5n Versiyonun Karışıklık Matrisi

Model A Yolov5n Metrics:

Sınıf	TP	FP	FN	Keskinlik	Duyarlılık	F1 Skoru
K(-)	48	1	2	0.979592	0.96	0.969697
K(B)	47	4	3	0.921569	0.94	0.930693
K(S)	45	0	5	1	0.9	0.947368
K(M)	48	0	2	1	0.96	0.979592
Arka plan	0	7	0	0	nan	nan

Şekil 4.22: Eğitilmiş Model A YOLOv5n Versiyonun Değerlendirmesi

Model A Yolov8n Confusion Matrix:

Gerçek\Algılanan	K(-)	K(B)	K(S)	K(M)	Arka plan
K(-)	48	0	0	0	2
K(B)	1	48	0	0	1
K(S)	0	3	45	0	2
K(M)	0	0	0	49	1
Arka plan	0	0	0	0	0

Şekil 4.23: Eğitilmiş Model A YOLOv8n Versiyonun Karışıklık Matrisi

Model A Yolov8n Metrics:

Sınıf	TP	FP	FN	Keskinlik	Duyarlılık	F1 Skoru
K(-)	48	1	2	0.979592	0.96	0.969697
K(B)	48	3	2	0.941176	0.96	0.950495
K(S)	45	0	5	1	0.9	0.947368
K(M)	49	0	1	1	0.98	0.989899
Arka plan	0	6	0	0	nan	nan

Şekil 4.24: Eğitilmiş Model A YOLOv8n Versiyonun Değerlendirmesi

Model B Yolov5n Confusion Matrix:

Gerçek\Algılanan	K(-)/Y(-)	K(+)/Y(-)	K(-)/Y(+)	K(+)/Y(+)	Arka plan
K(-)/Y(-)	46	2	1	0	1
K(+)/Y(-)	1	48	0	0	1
K(-)/Y(+)	0	0	47	0	3
K(+)/Y(+)	0	0	0	50	0
Arka plan	0	0	0	0	0

Şekil 4.25: Eğitilmiş Model B YOLOv5n Versiyonun Karışıklık Matrisi

Model B Yolov5n Metrics:

Sınıf	TP	FP	FN	Keskinlik	Duyarlılık	F1 Skoru
K(-)/Y(-)	46	3	4	0.938776	0.92	0.929293
K(+)/Y(-)	48	2	4	0.96	0.923077	0.941176
K(-)/Y(+)	47	1	3	0.979167	0.94	0.959184
K(+)/Y(+)	50	0	0	1	1	1
Arka plan	0	5	0	0	nan	nan

Şekil 4.26: Eğitilmiş Model B YOLOv5n Versiyonun Değerlendirmesi

Model B Yolov8n Confusion Matrix:

Gerçek\Algılanan	K(-)/Y(-)	K(+)/Y(-)	K(-)/Y(+)	K(+)/Y(+)	Arka plan
K(-)/Y(-)	48	1	0	0	1
K(+)/Y(-)	1	47	0	0	2
K(-)/Y(+)	0	0	47	0	3
K(+)/Y(+)	0	1	0	49	0
Arka plan	0	0	0	0	0

Şekil 4.27: Eğitilmiş Model B YOLOv8n Versiyonun Karışıklık Matrisi

Model A Yolov8n Metrics:

Sınıf	TP	FP	FN	Keskinlik	Duyarlılık	F1 Skoru
K(-)	48	1	2	0.979592	0.96	0.969697
K(B)	48	3	2	0.941176	0.96	0.950495
K(S)	45	0	5	1	0.9	0.947368
K(M)	49	0	1	1	0.98	0.989899
Arka plan	0	6	0	0	nan	nan

Şekil 4.28: Eğitilmiş Model B YOLOv8n Versiyonun Değerlendirmesi

### 4.3 GPU Üzerinden Değerlendirme

Eğitilmiş modeller, Nvidia RTX A4000 16GB GPU üzerinden uygulanmış ve değerlendirilmiştir. Uygulama sırasında, rastgele anlarda tespit sürelerinin ekran görüntüleri kaydedilmiştir. Her model ve her modelin sınıfı için birbirini takip eden 25 adet tespitin ortalaması alınarak tespit süresi hesaplanmış ve 2 milisaniyeden daha az olduğu görülmüştür. Model A YOLOv5n için Şekil 4.29, Model A YOLOv8n için Şekil 4.30, Model B YOLOv5n için Şekil 4.31 ve Model B YOLOv8n için Şekil 4.32'de bu kayıtlar gösterilmiştir.









0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 2.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 6.1ms  
0: 320x416 (no detections), 3.5ms  
0: 320x416 (no detections), 0.0ms  
0: 320x416 (no detections), 5.5ms  
0: 320x416 (no detections), 0.0ms  
0: 320x416 (no detections), 5.4ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 5.5ms  
0: 320x416 1 Beyaz Baret Kullanan, 5.8ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 6.8ms  
0: 320x416 1 Beyaz Baret Kullanan, 3.3ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms  
0: 320x416 1 Beyaz Baret Kullanan, 0.0ms

Şekil 4.33: Hareketlerde Kriterin Anlık Tespit Edilememesi



Şekil 4.34: Hareketli Durumda Tespit Edilemeyen Karelerden Bir Örnek

Uygulamada hareket edildiğinde genelde görüntüler net oluşmadı, buna rağmen tespitlerin büyük bir kısmı doğru olarak yapılmıştır. Şekil 4.35'te bu tespitlerden birkaç örnek bulunmaktadır.



**Şekil 4.35:** Hareketlilik Durumunda Doğru Tespit Yapılan Örnekler

## 5. TARTIŞMA

Bu bölümde iki ana başlık ele alınacaktır. İlk olarak, hatalı kriter algılamanın iş sağlığı ve güvenliği açısından etkisi, ikinci olarak ise mobil robotlarda güvenlik önlemleri için derin öğrenme kullanımı tartışılacaktır.

### 5.1 Hatalı Kriter Algılamanın İş Sağlığı ve Güvenliği Açısından Etkisi

Çalışmanın sonuçlarına göre, mAP değerine göre yaklaşık %2 ile %3, F1 skoruna göre de yaklaşık %4 ile %5 arasında hata oranı veya yanlış çıkarım durumu tespit edilmiştir. İş sağlığı ve güvenliğinde amaç sıfır hata olduğundan, bu hatalı kriter algılamanın özellikle değerlendirilmesi gerekir. İş sağlığı ve güvenliğinin uygulandığı alanlarda güvenlik önlemleri ve tehlike algılaması açısından doğru tespitlerin yapılması kritik bir rol oynadığından yanlış çıkarımlar, iş kazaları veya işyerindeki potansiyel tehlikelerin gözden kaçmasına neden olabilir. Bu da çalışanların güvenliği ve sağlığı açısından risk oluşturabilir.

Henri Fayol'a göre insan faktöründen, teknik hatalardan ve insanın doğanın karşısında zayıf oluşundan dolayı az bir miktarda olsa hataların oluşması mümkündür ve bundan kaçınılamaz. Günümüzde bu yaklaşım kabul edilmemekte ve iş sağlığı ve güvenliği yönetim sistemlerin kurulması, risklerin değerlendirilmesi, önlemlerin alınması ve sürekli iyileştirme ile sıfır kaza hedeflenmektedir. Bu çerçevede, bu çalışmada oluşturulan modelin yüksek doğrulama performansı sağlaması olumlu bir durumdur. Ancak doğrulama hatalarının daha da azaltılması, mümkünse sıfıra indirilmesi, incelenmesi ve değerlendirilmesi gereken bir konudur.

Bu nedenle hatalı kriter algılamaya yol açan faktörler özellikle incelenmelidir. Bu faktörler, eğitim ön hazırlık çalışmalarındaki eksiklikler, DSA mimarisine ait zayıflıklar ve gerçek hayatta karşılaşılan değişkenlikler ve karmaşık koşullar gelmektedir.

### **5.1.1 Eğitimin ön hazırlık çalışmalarındaki eksiklikler**

Modelin nesnelere hatalı algılanmasının eğitim ön hazırlığı ile ilgili sebepleri; veri setinin doğru ve yeterli hazırlanmaması, model konfigürasyon ayarlarının doğru belirlenmemesi şeklinde iki başlık altında toplanabilir. Veri setinin doğru ve yeterli hazırlanmaması, veri setinin yetersiz ve/veya dengesiz toplanmış olması anlamına gelir, bu durum da hedeflenen nesnenin tümüyle temsil edilme durumunun sağlanamamasına, hedeflenen sınıfın bir biçimi, boyutu veya rengi üzerine taraflı eğitim verilmesine neden olur. Bu durumda DSA yeni örneklerle doğru genelleme yapmakta zorlanır, yanlış pozitif veya yanlış negatif sonuçlara yol açabilir. Veri setinin doğru ve yeterli hazırlanmamasının bir şekilde az miktardaki verinin; belirli bir açıyla sağa ya da sola döndürülmesi, bulanıklaştırılması, kirletilmesi, boyutunun değiştirilmesi vb. yöntemlerle çoğaltma denilen teknik ile artırılması ve eğitime sokulması durumunda, aşırı uyuma neden olabilir. Bu da eğitimde kullanılan az veriyi eğitim aşamasında ezberlemesine, uygulamada ise hedeflenen nesnenin farklı bir biçimi, boyutu ve rengi ile karşılaştığında algılamakta zorlanmasına ve yine yanlış negatif veya yanlış pozitif olarak algılanmasına sebep olabilir. Eğitim ön hazırlığında kaynaklanan hataların bir diğer sebebi ise eğitim konfigürasyonunun yani hiper-parametrelerin doğru belirlenmemesinden kaynaklıdır. Örneğin eğitimde gereğinden fazla devir (epoch) kullanılırsa yine verilerin ezberlenmesi ve aşırı uyuma neden olabilir. Benzer şekilde yığın (batch), öğrenme oranı (learning rate), optimize sağlayıcı (optimizer) seçimi yanlış olursa eğitim performansı düşük kalabilir ve algılamaların yanlış olmasına yol açabilir.

### **5.1.2 DSA mimarisine ait zayıflıklar**

Model tarafından nesnelere hatalı algılanmasının ikinci nedeni ise DSA ile ilgilidir. DSA'nın doğru seçimi önemlidir. Hedeflenen nesnenin türüne, eğitim veri miktarına göre yapay sinir ağı derinliği ve mimarisi belirlenmelidir (Harrison ve diğerleri, 2021). Eğer nesne boyutu çok küçükse bazı algoritmalar algılamakta zorlanabilir. YOLO türü algoritmalar büyük ölçekli nesnelere iyiyken, R-CNN türü algoritmalar küçük boyutlu nesnelere daha iyidir. Yine eğitim veri seti miktarı algoritmanın seçiminde önemlidir. Yapay sinir ağı çok derinse ve veriler bu derin ağı besleyecek kadar büyük değilse, uygulamada yanlış pozitifler olabilir. Benzer şekilde, yapay

sinir ağı yeterli derinlikte değilse, yeterli öğrenme sağlanamadığında doğru genellemeler yapılamayabilir ve hatalı tespitlere neden olabilir.

### **5.1.3 Gerçek hayatta karşılaşılan değişkenlikler ve karmaşık koşullar**

Model tarafından hatalı algılamanın son nedeni modelin nesneyi algıladığı koşullarla ilgilidir. Algılama için kullanılan sensör (kamera) çözünürlüğü iyi değilse ve ışık algılaması zayıfsa, kamera hareket ettiğinde görüntü çok bulanıklaşıyorsa, algılamanın gerçekleştiği ortam yeterli aydınlıkta değilse, hedeflenen nesnenin önünde nesneyi örten başka nesnelere varsa, bu ve benzeri durumlar hatalı algılamaya yol açabilir.

Nesne algılama modülünün değerlendirilmesinde temsiliyeti sağlayacak geniş bir veri seti kullanılsa da modelin uygulanacağı çalışma ortamındaki koşullar değerlendirilmese kullanılan model hedeflenen nesneyi tespit etmekte zorlanabilir. Çalışma ortamından elde edilen değerlendirme, test ortamında elde edilen değerlendirmeden daha düşük bir performans gösterebilir. Doğru tespit yapabilmek için nesne algılama modülünün çalışma ortamının koşullarına uygun şekilde değerlendirilmesi önemlidir. Aynı model bir işyerinde ışık ortamına, ortamdaki değişikliklere, çalışma şekline ve çalışanlara yönelik daha fazla temsiliyet sağladığından daha güvenli sonuçlar verirken, başka bir işyerindeki ışık ortamına, koşullara, çalışma şekline ve çalışanlara yönelik temsiliyeti düşükse, hedeflenen nesnelere ya da durumları tespit etmekte de zorlanabilir, hatalı sonuçlar verebilir. Bu durum kamera sensörü özellikleri ve kalitesi ile bile değişebilir.

Bu nedenle, nesne algılama modülünün gerçek çalışma ortamında test edilmesi ve performansının bu koşullarda da değerlendirilmesi önemlidir. Böylece, modelin güvenilirliği ve uygulanabilirliği daha iyi anlaşılabilir ve gerektiğinde iyileştirmeler yapılabilir. Hatalı tespit fark edildiği anda, ilgili durumun değişik açıları ve boyutlardan görseli alınarak veri setine eklenebilir ve böylece elde edilecek yeni eğitilmiş modellerle robotun algılama performansı iyileştirilebilir.

Hatalı algılamaları azaltmanın bir diğer yöntemi ise modelin tespit için kullandığı güven eşik değerini yüksek belirlemektir. Böylece model kararsız kaldığı durumlarda kriter algılaması yapmayacaktır. Ancak bu yöntem, doğru tespitleri de azaltacaktır ve bu durumda kriter tespit edilmediğinden en yüksek boyutlu güvenlik önlemi devreye

girer. Bu yöntem mobil robotların operasyonel çalışmalarında bir miktar verim düşüklüğe neden olabilir. Yine de hassas durumlar için bu yöntem uygulanabilir.

Modelin nesneyi algıladığı koşullardan kaynaklanan hata sebeplerinden biri de, insanların/çalışanların mobil robotları bilinçli olarak manipüle etmesi ya da yanıltılmasıdır. Nguyen ve diğerleri (2015), Kurakin ve diğerleri (2017), Liu ve diğerleri (2018) ve Goswami (2020) tarafından yapılan çalışmalar, insanların hedef nesne ile arasındaki farkı kolaylıkla ayırt edebileceği bazı ilgisiz şekilleri yüksek doğrulukla eğitilmiş modellerin ayırt edemediği ve yüksek güven eşiği ile o şekilleri hedeflenen şekil olarak tespit ettikleri ile ilgilidir. Özellikle Nguyen ve diğerleri sürücüsüz arabalar için bu durumun tehlike oluşturduğunu, kötü niyetli yaklaşımların sürücüsüz araçları yanıltabileceğini ve potansiyel kazalara yol açabileceğini vurgulamıştır. Bu durum insan endüstriyel mobil robot etkileşimi için de risk oluşturabilir.

Hatalı çıkarımlara ve derin öğrenmenin bazı zayıflıklarına rağmen, iş sağlığı ve güvenliği alanı ile ilgili literatür incelendiğinde derin öğrenme ile ilgili çalışmaların arttığı görülmektedir. Derin öğrenmenin özellikle işyerlerinde gerçek zamanlı risk tespiti, analizi ve değerlendirmesinin yapılabilmesine olanak sağlaması İSG alanına getirmiş olduğu en önemli katkıdır.

Bazı alanlarda, örneğin büyük şantiyelerde KKD'nin kullanım durumunun tespit edilmesi için gereği oluşan iş, çalışan yoğunluğu, düzensizlik ve karmaşıklığından dolayı oldukça zor olabilmektedir. Ancak derin öğrenme teknolojisi sayesinde KKD'nin kullanım durumu gerçek zamanlı olarak denetlenebilir. Bu otomatik denetimin belli bir miktar hata oranı olmasına rağmen İSG açısından iş kazalarını azaltmaya yönelik önemli bir katkı sağlar.

Derin öğrenmenin İSG getirmiş olduğu bu önemli katkı, ayrıca derin öğrenme teknolojisinin gelişim aşamasında olmasından dolayı bu hata miktarı üzerine yeteri kadar tartışılmamaktadır. Ancak derin öğrenme İSG alanında daha da yaygınlaştıkça ve birçok işyeri tarafından kullanıldıkça nesne algılama hataları daha etkin ve fazla tartışılacaktır.

## 5.2 Mobil Robotlarda Güvenlik Önlemleri İçin Derin Öğrenme Kullanımı

Hata ve diğerleri (2019), yapay zeka veya derin öğrenmenin insan mobil robot etkileşimde güvenliği artırmak için kullanılabilir olduğunu belirtmiştir. Çalışmalarında, yapay zeka tekniklerinin çalışan davranışlarını tahmin etmek, sensör algısını geliştirmek ve robotların denetim sistemlerini daha güvenli hale getirmek için kullanılabileceğini önermişlerdir.

Genellikle tehlikeli insan davranışları, yetkisiz çalışanlar tarafından, bilgi eksikliği veya tecrübesizlik nedeniyle gerçekleşmektedir. Bu nedenle, tehlikeli davranışları belirlemek için yetkili ve yetkisiz çalışanların tespit edilmesi önemli bir yöntem olabilir. Ayrıca, bir çarpışma veya kaza durumunda çalışanların daha az zarar görmesi için kişisel koruyucu donanım kullanımının tespit edilmesi de önemlidir.

Çoğu araştırmacı insan robot etkileşimde güvenlik sorunu ele alarak derin öğrenmeyi daha çok robot becerisini geliştirmek için kullanmaktadır. Bu araştırmacılar insan-robot etkileşiminde robotların becerisinin artırılmasının güvenliği sağlayacağını ileri sürmektedir. Yüksek becerilere sahip robotların daha duyarlı ve yetenekli olmaları, iş güvenliği açısından olumsuz durumların azalmasına katkı sağlayabilir. Ancak bu durum insan robot etkileşiminde güvenliği sağlamak için tek başına yeterli değildir. Robotların yüksek kabiliyetleri olmasına rağmen, hatalar olabilir. Bu hatalar robot veya etkileşim içinde olduğu insan tarafından yapılabilir. İSG açısından, yüksek becerilere sahip robotların daha az hata yapmasını ya da hata yapmamasını sağlamak önemlidir ancak tek başına yeterli değildir. Bununla birlikte hataların oluşması durumunda kazaların gerçekleşmemesi için gerekli önlemlerin alınması da önemli ve gereklidir.

Yüksek becerilere sahip robotların kullanılması, olumsuz durumların ortaya çıkma olasılığını azaltabilir ancak yeterli ve geçerli bir önlem türü olarak düşünülmemelidir. Robot algı ve becerilerinin artırılmasının yanı sıra iş sağlığı ve güvenliği yönetimi süreçleri de etkin bir şekilde uygulanmalıdır. İş sağlığı ve güvenliği açısından hata olmamasını sağlamak kadar hata olması durumunda önleyici önlemlerin alınmasını sağlamak da önemlidir. Bu nedenle, robot becerisinin geliştirilmesine ek olarak, derin öğrenmeye dayalı farklı önlemler de alınabilir ve derin öğrenme güvenlik önlemlerini belirlemek için kullanılabilir. Özellikle insan robot etkileşiminde güvenliği sağlamak için, insanın yetkinlikleri, deneyimleri ve

eğitimleri göz önünde bulundurulmalıdır. Böylelikle, iş kazalarının önlenmesi ve çalışanların güvenliği sağlanabilir.

Mobil robotlarda güvenlik için doğrudan derin öğrenme kullanımıyla ilgili olarak literatüre çok fazla çalışma henüz girmemiştir. Bu durumun en önemli nedeni, nesne algılama teknolojisinin hızlı karar alınması gereken güvenlik durumlarında yeterince hızlı olamama endişesidir. Derin öğrenme modellerinin eğitimi ve çıkarım süreleri genellikle uzun sürmektedir ve anlık tepkilerin gerektiği güvenlik durumlarında yavaş kalabilmektedir. Bu nedenle derin öğrenmenin güvenlik amacıyla kullanılmasının kazaları engellemede yeterli olamayacağı kabul edilmiştir.

Günümüzde hem nesne algılama algoritmalarında hem de bu algoritmaların işleneceği işlemci kartlarındaki gelişmeler bu tür yaklaşımlar için ufuk açmaktadır.

Ancak, nesne tespit algoritmaları ve bu algoritmaların işleneceği işlemci modüllerindeki gelişmeler, çıkarım hızının anlık tepkilere cevap verme konusunda umut verici bir duruma gelmesini sağlamıştır. 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. Bu çalışmada görülmüştür ki, nesne algılama çıkarım hızı, lidar sensörünün 360 derecelik bir alanı taramasından daha hızlıdır. Bu çalışmada elde edilen sonuçlar göstermiştir ki nesne algılama teknolojisi de artık bir lidar sensörün hızına yakın cevaplar verebilmektedir. Elbette ki bir lidar sensörünün görevi, bir nesne algılama sisteminin göreviyle aynı değildir. Lidar sensörler, nesnenin ne olduğundan bağımsız olarak, çevresinin 2B veya 3B haritasını çıkararak mobil robotların engellerden kaçınmasını ve insanlarla çarpışmalar da dahil olmak üzere birçok kazadan korunmasını sağlar. Nesne algılama teknolojisi ise insanlar gibi belirli nesnelere tanımlamak ve bunlara yanıt vermek için geliştirilmiştir. Nesne algılama teknolojisi, mobil robotların etkileşim içinde olduğu insanlar hakkında bilgi toplayabilir ve bu kapsamda güvenlik derecesini belirleyebilir.

Bu durumda nesne algılama sistemleri lidar sensörlerle uyumlu çalışabilir ve birlikte yer alacakları bir sistemde tek düze önlem almak yerine koşullara ve kriterlere göre önlem alabileceklerdir. Lidar ve nesne algılama algoritmasının birlikte kullanılması,

mobil robotlara güvenlik konusunda hızlı ve bilinçli kararlar verme yeteneđi kazandıracaktır.



## 6. SONUÇ VE ÖNERİLER

Bu çalışmada, iki ayrı veri seti ve YOLO algoritmasının YOLOv5n ve YOLOv8n olmak üzere iki farklı versiyonu kullanılmıştır ve toplam 4 adet modül oluşturulmuştur. Modüller veri setine göre Modül A ve Modül B olarak isimlendirilmiştir. Modül A, bir mobil robotun etkileşim içinde olduğu insanın yetkisi baretin rengi ile algılama hedeflemiştir. Bu algılama aynı zamanda çalışanın baret kullandığını da göstermektedir. Model B ise yelek tipinden yetki seviyesi, çalışanın baret kullanımını ise ayrı bir değerlendirme ile algılamaya hedeflenmiştir. Her veri seti için 2000 adet etiket oluşturulmuştur. 0,5 güven eşiği ile Model A YOLOv5n versiyonu 0,98555, YOLOv8n versiyonu 0,98794'lük bir doğruluk performansı göstermiştir. Model B'de ise YOLOv5n versiyonu 0,98606, YOLOv8n versiyonu 0,98696'lük bir doğruluk performansı göstermiştir. İki model için çıkarım süresi CPU için farklılık gösterse de GPU da ortalama 2 mili saniyeden daha az olmuştur. Bu modüllerin 500 FPS'den daha yüksek bir çıkarım hızına ulaştığını gösterilmiştir.

Bu çalışma, mobil robotların insan etkileşiminde güvenlik önlemi tercihi için derin öğrenmeye dayalı kriter tespiti hipotezi gerek doğruluk gerekse hız konusunda yakınlık sensörleriyle birlikte uygulanabilir olduğu gösterilmiştir. Böylece mobil robotlar için güvenlik önlemleri, günümüzde yaygın olduğu gibi koşullardan bağımsız, tekdüze olarak değil, kriter durumu dikkate alınarak verimliliklerini artıracak şekilde tasarlanabilir.

Çalışmada 16gb kapasitesinde GPU aygıtı kullanılmıştır. Aynı kapasitede Nvidia'nın mobil robotlar için uygulanabilir modülleri de mevcuttur. Bunlar da uygulamalar geliştirilerek mobil robotların kullanıma sunulabilir.

Mobil robotlar tarafından alınan güvenlik önlemleri için öne çıkan kriterler çalışanlarla veya çalışma ortamıyla ilgilidir. Çalışanlarla ilgili kriterler; çalışanın koruyucu ekipmana kullanımı, davranış niyeti ve yetki seviyesi gibi faktörleri, çalışma ortamıyla ilgili kriterler ise; çalışma ortamının düzeni, genişliği, zemini ve aydınlatması gibi unsurları içerebilir. Bir mobil robot tarafından nesne algılama

mimarisi ve yakınlık sensörleri kullanılarak, tüm bu kriterler algılanabilir ve uygulayacağı güvenlik önlemini bu kriterlere göre belirleyebilir. Bu anlamı ile çalışma genişletilebilir ve bu çalışmanın devamında insan mobil robot etkileşiminde güvenliği etkileyen tüm durumların algılanması sağlanarak daha kapsamlı güvenlik kriterleri oluşturulabilir.

Ayrıca bu çalışmanın devamında, mobil robotun tespit ettiği kriterleri, özellikle güvenlik boyutunu üst seviyeye almasını sağlayan kriterleri hafızasına alması, analiz etmesi ve raporlamasını da sağlanabilir. İşyerinde çalışanların ne derece güvenlik kurallarına uyduğu, yetkisiz çalışanların ne kadar mobil robottan kaçındığını, kişisel koruyucu donanımlarının ne sıklıkta kullanıldığı raporlayabilir. Bu raporlar eğitimlerin yenilenme periyodların belirlenmesinde etkili olacağı gibi işyerindeki güvenlik kültürü hakkında genel bir bilgi de sağlayabilir.

Yine bu çalışmanın devamında Derin Metrik Öğrenme yöntemi ile çalışanların mobil robotla olan mesafesi derin öğrenme ile ölçülebilir. Böylece lidar sensörler olmadan da haritalandırma ve mesafe ölçme yapılabilir.

Sonuç olarak, derin öğrenme teknolojisinin, mobil robotlar için güvenlik önlem boyutunu belirleyecek kriter tespitinde, doğruluk ve hız değerine ulaşmış olduğu görülmüştür. Derin öğrenme hata ve risk tespitini yüksek doğruluk ve gerçek zamanlı yapabilme yeteneği sayesinde, iş sağlığı ve güvenliği açısından kullanımın daha da artacağı ve önemli bir araç olacağı öngörülmektedir.

## KAYNAKLAR

- Aivaliotis, P., Aivaliotis, S., Gkournelos, C., Kokkalis, K., Michalos, G., & Makris, S.** (2019). Power and Force Limiting on Industrial Robots for Human-Robot Collaboration. *Robotics and Computer-Integrated Manufacturing*, 59, 346-360. ISSN 0736-5845. <https://doi.org/10.1016/j.rcim.2019.05.001>
- Aktürk, S., & Serbest, K.** (2022). Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi. *Journal of Smart Systems Research*, 3(2), 97-119.
- Alpaydın, E.** (2013). *Yapay öğrenme*. Boğaziçi Üniversitesi Yayınevi.
- Ashenden, S. K., Bartosik, A., Agapow, P. M., & Semenova, E.** (2021). Introduction to artificial intelligence and machine learning. *The era of artificial intelligence, machine learning, and data science in the pharmaceutical industry*, 15-26.
- Badri, A., Boudreau-Trudel, B., & Souissi, A. S.** (2018). Occupational Health and Safety in the Industry 4.0 Era: A Cause for Major Concern? *Safety Science*, 109, 403-411.
- Balasubramanian, K., Arunkumar, R., Jayachandran, J., Jayapal, V., Chundatt, B. A., & Freeman, J. D.** (2009, June). Object recognition and obstacle avoidance robot. In *2009 Chinese Control and Decision Conference* (pp. 3002-3006). IEEE.
- Balmik, A., Barik, S., & Nandy, A.** (2023, March). A Robust Object Recognition Using Modified YOLOv5 Neural Network. In *2023 10th International Conference on Signal Processing and Integrated Networks (SPIN)* (pp. 462-467). IEEE.
- Belzile, B., & St-Onge, D.** (2022). Safety first: On the safe deployment of robotic systems. In *Foundations of Robotics: A Multidisciplinary Approach with Python and ROS* (pp. 415-439). Singapore: Springer Nature Singapore.
- Belzile, B., Wanang-Siyapdjie, T., Karimi, S., Gomes Braga, R., Iordanova, I., & St-Onge, D.** (2021). From safety standards to safe operation with mobile robotic systems deployment.
- Bengio, Y.** (2013). *Deep Learning of Representations: Looking Forward*. In: Dedi, AH., Martín-Vide, C., Mitkov, R., Truthe, B. (eds) *Statistical Language and Speech Processing. SLSP 2013. Lecture Notes in Computer Science()*, vol 7978. Springer, Berlin, Heidelberg.
- Bengio, Y., Courville, A., & Vincent, P.** (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.

- Bishop, C. M., & Nasrabadi, N. M.** (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
- Bozinovski, S., & Fulgosi, A.** (1976). The influence of pattern similarity and transfer learning upon training of a base perceptron b2. In *Proceedings of Symposium Informatica* (Vol. 3, pp. 121-126).
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., & Zagoruyko, S.** (2020). End-to-end object detection with transformers. In *Computer Vision—ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part I 16* (pp. 213-229). Springer International Publishing.
- Casuat, C. D., Merencilla, N. E., Reyes, R. C., Sevilla, R. V., Pascion, C. G.** (2020). Deep-Hart: An Inference Deep Learning Approach of Hard Hat Detection for Work Safety and Surveillance.
- Cengil, E.** (2022) İki Boyutlu Sağlık, Tarım ve İş Güvenliği İmgeleri Üzerinde Sınıflandırma ve Nesne Tespiti. Doktora, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı.
- Chernousko, F. L.** (2017). Locomotion principles for mobile robotic systems. *Procedia Computer Science*, 103, 613-617.
- Chinniah, Y.** (2016). Robot safety: overview of risk assessment and reduction. *Advances in Robotics & Automation*, 5(01), 1-5.
- Chowdhury, T. T., Hossain, A., Fattah, S. A., & Shahnaz, C.** (2019, May). Seizure and non-seizure EEG signals detection using 1-D convolutional neural network architecture of deep learning algorithm. In 2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT) (pp. 1-4). IEEE.
- Çalışkan, D., & demir, Ö.** (2022). Derin Öğrenme Yöntemleri ile Şüpheli Davranış Tespiti. *International Periodical Of Recent Technologies In Applied Engineering*, 3(1), 28-43.
- Dalal, N., & Triggs, B.** (2005, June). Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)* (Vol. 1, pp. 886-893). Ieee.
- Devol, G.** (1956). A Programmable Manipulator. *Proceedings of the Eastern Joint Computer Conference*, 12, 104-110, 1956.
- Dhillon, B. S., Fashandi, A. R. M., & Liu, K. L.** (2002). Robot systems reliability and safety: A review. *Journal of quality in maintenance engineering*, 8(3), 170-212.
- Dong, H., Yang, J., Wang, J., & Li, S.** (2022). Surface Quality Automatic Inspection for Pharmaceutical Capsules Using Deep Learning. *Journal of Sensors*, 2022.
- Dong, S., Wang, P., & Abbas, K.** (2021). A survey on deep learning and its applications. *Computer Science Review*, 40, 100379.

- Duque-Suárez, N., Amaya-Mejía, L. M., Martínez, C., & Jaramillo-Ramirez, D.** (2022). Deep Learning for Safe Human-Robot Collaboration. In *Advances in Automation and Robotics Research: Proceedings of the 3rd Latin American Congress on Automation and Robotics, Monterrey, Mexico 2021* (pp. 239-251). Springer International Publishing.
- El-Shamouty, M., Wu, X., Yang, S., Albus, M., & Huber, M. F.** (2020, May). Towards safe human-robot collaboration using deep reinforcement learning. In *2020 IEEE international conference on robotics and automation (ICRA)* (pp. 4899-4905). IEEE.
- Erdoğan, P.** (2019). Deep Learning Performance on Medical Image, Data and Signals. *Sakarya University Journal of Computer and Information Sciences*, 2(1), 28-40.
- Fang, Q., Li, H., Luo, X., Ding, L., Luo, H., Rose, T. M., An, W.** (2018). Detecting non-hardhat-use by a deep learning method from far-field surveillance videos. *Automation in Construction*, 85, 1-9.
- Farooq, M. U., Bhutto, M. A., & Kazi, A. K.** (2023). Real-Time Safety Helmet Detection Using YOLOv5 at Construction Sites. *Intelligent Automation & Soft Computing*, 36(1).
- Filatov, N., Maltseva, N., Bakhshiev, A.** (2020). Development of Hard Hat Wearing Monitoring System Using Deep Neural Networks with High Inference Speed. In *2020 International Russian Automation Conference (RusAutoCon)* (pp. 459-463). IEEE.
- Fragapane, G., De Koster, R., Sgarbossa, F., & Strandhagen, J. O.** (2021). Planning and control of autonomous mobile robots for intralogistics: Literature review and research agenda. *European Journal of Operational Research*, 294(2), 405-426.
- Fryman, J.** (2014, June). Updating the industrial robot safety standard. In *ISR/Robotik 2014; 41st International Symposium on Robotics* (pp. 1-4). VDE.
- Gallo, G., Di Rienzo, F., Garzelli, F., Ducange, P., & Vallati, C.** (2022). A Smart System for Personal Protective Equipment Detection in Industrial Environments Based on Deep Learning at the Edge. *IEEE Access*, 10, 110862-110878.
- Gao, J., Gao, X., Zhu, W., Zhu, J., & Wei, B.** (2008, April). Coal Mine Detect and Rescue Robot Design and Research. In *ICNSC* (pp. 780-785).
- Ghojogh, B., Ghodsi, A., Karray, F., & Crowley, M.** (2021). Restricted boltzmann machine and deep belief network: Tutorial and survey. *arXiv preprint arXiv:2107.12521*.
- Ghorpade, D., Thakare, A. D., & Doiphode, S.** (2017, August). Obstacle detection and avoidance algorithm for autonomous mobile robot using 2D LiDAR. In *2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA)* (pp. 1-6). IEEE.
- Gillan, D.J.** (2020). Invited Essay: Usability Issues in Human-Robot Interaction. *Journal of Usability Studies*, 15, 179-183.

- Girshick, R.** (2015). Fast R-CNN. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- Girshick, R., Donahue, J., Darrell, T., & Malik, J.** (2015). Region-based convolutional networks for accurate object detection and segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 38(1), 142-158.
- Goswami, S.** (2020). False detection (positives and negatives) in object detection. *arXiv preprint arXiv:2008.06986*.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T.** (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- Gualtieri, L., Rauch, E., Vidoni, R., & Matt, D. T.** (2020). Safety, Ergonomics and Efficiency in Human-Robot Collaborative Assembly: Design Guidelines and Requirements. *Procedia CIRP*, 91, 367-372. ISSN 2212-8271.
- Harrison Jr, J. H., Gilbertson, J. R., Hanna, M. G., Olson, N. H., Seheult, J. N., Sorace, J. M., & Stram, M. N.** (2021). Introduction to artificial intelligence and machine learning for pathology. *Archives of pathology & laboratory medicine*, 145(10), 1228-1254.
- Hata, A., Inam, R., Raizer, K., Wang, S., & Cao, E.** (2019, September). AI-based safety analysis for collaborative mobile robots. In *2019 24th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)* (pp. 1722-1729). IEEE.
- He, B., Zhuo, J., Zhuo, X., Peng, S., Li, T., & Wang, H.** (2022, September). Defect detection of printed circuit board based on improved YOLOv5. In *2022 International Conference on Artificial Intelligence and Computer Information Technology (AICIT)* (pp. 1-4). IEEE.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R.** (2017). Mask R-CNN. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).
- He, K., Zhang, X., Ren, S., & Sun, J.** (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE transactions on pattern analysis and machine intelligence*, 37(9), 1904-1916.
- He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Herath, D., & St-Onge, D.** (2022). *Foundations of Robotics: A Multidisciplinary Approach with Python and ROS*. Springer Nature Singapore.
- Hinton, G. E., Osindero, S., & Teh, Y. W.** (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R.** (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.

- Khalid, S., Oqaibi, H. M., Aqib, M., & Hafeez, Y.** (2023). Small Pests Detection in Field Crops Using Deep Learning Object Detection. *Sustainability*, 15(8), 6815.
- Kim, D., Kong, J., Lim, J., Sho, B.** (2020). 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.
- Kotu, V., & Deshpande, B.** (2019). *Deep Learning*. In V. Kotu & B. Deshpande (Eds.), *Data Science (Second Edition)*. Morgan Kaufmann. ISBN 9780128147610.
- Kurakin, A., Goodfellow, I., & Bengio, S.** (2016). Adversarial machine learning at scale. *arXiv preprint arXiv:1611.01236*.
- LeCun, Y., Bengio, Y., & Hinton, G.** (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Lee, M. C., & Lee, M.** (2022, October). Deep Learning-based Target Following and Obstacle Avoidance Methods in Mobile Robots. In *2022 IEEE International Conference on Consumer Electronics-Asia (ICCE-Asia)* (pp. 1-4). IEEE.
- Li, X., Wang, W., Wu, L., Chen, S., Hu, X., Li, J., ... & Yang, J.** (2020). Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection. *Advances in Neural Information Processing Systems*, 33, 21002-21012.
- Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollár, P.** (2017). Focal loss for dense object detection. In *Proceedings of the IEEE international conference on computer vision* (pp. 2980-2988).
- Liu, J., & Zhou, Y.** (2023, February). Marine debris detection model based on the improved YOLOv5. In *2023 3rd International Conference on Neural Networks, Information and Communication Engineering (NNICE)* (pp. 725-728). IEEE.
- Liu, J., Chang, H., Hsu, T. Y., & Ruan, X.** (2000). Prediction of the flow stress of high-speed steel during hot deformation using a BP artificial neural network. *Journal of materials processing technology*, 103(2), 200-205.
- Liu, Q., Liu, Z., Xiong, B., Xu, W., & Liu, Y.** (2021). Deep reinforcement learning-based safe interaction for industrial human-robot collaboration using intrinsic reward function. *Advanced Engineering Informatics*, 49, 101360.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C.** (2016). Ssd: Single shot multibox detector. In *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14* (pp. 21-37). Springer International Publishing.
- Liu, X., Cheng, M., Zhang, H., & Hsieh, C. J.** (2018). Towards robust neural networks via random self-ensemble. In *Proceedings of the European Conference on Computer Vision (ECCV)* (pp. 369-385).

- Lohse, M., & Evers, V.** (2014). Useful and Motivating Robots — The Influence of Task Structure on Human-Robot Teamwork. In 2014 9th ACM/IEEE International Conference on Human-Robot Interaction (HRI) (pp. 232-233). Bielefeld, Germany.
- Lou, H., Duan, X., Guo, J., Liu, H., Gu, J., Bi, L., & Chen, H.** (2023). DC-YOLOv8: Small-Size Object Detection Algorithm Based on Camera Sensor. *Electronics*, 12(10), 2323.
- Mahendrakar, T., Ekblad, A., Fischer, N., White, R., Wilde, M., Kish, B., & Silver, I.** (2022, March). Performance Study of YOLOv5 and Faster R-CNN for Autonomous Navigation around Non-Cooperative Targets. In 2022 IEEE Aerospace Conference (AERO) (pp. 1-12). IEEE.
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D.** (2021). Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 44(7), 3523-3542.
- Naftali, M. G., Sulistyawan, J. S., & Julian, K.** (2022). Comparison of Object Detection Algorithms for Street-level Objects. arXiv preprint arXiv:2208.11315
- Nguyen, A., Yosinski, J., & Clune, J.** (2015). Deep neural networks are easily fooled: High confidence predictions for unrecognizable images. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 427-436).
- Nilsson, N. J.** (Ed). (1984). Shakey The Robot, Technical Report, SRI International: Menlo Park, CA, USA.
- Özkan, B.** (2009). Mekatronik Sistemlerde Uygulanan Belli Başlı Kontrol Yöntemleri. *TÜBAV Bilim Dergisi*, 2(3), 302-316.
- Raj, R., & Kos, A.** (2022). A Comprehensive Study of Mobile Robot: History, Developments, Applications, and Future Research Perspectives. *Applied Sciences*, 12(14), 6951.
- Rajawat, A.S.; Bedi, P.; Goyal, S.B.; Shukla, P.K.; Zaguia, A.; Jain, A.; Khan, M.M.** (2021). Reformist framework for improving human security for mobile robots in industry 4.0. *Mobile Information Systems*, 2021, 1-10.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A.** (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788)
- Ren, S., He, K., Girshick, R., & Sun, J.** (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- Rezayati, M., Zanni, G., Zaoshi, Y., Scaramuzza, D., & van de Venn, H. W.** (2023). Improving safety in physical human-robot collaboration via deep metric learning. *arXiv preprint arXiv:2302.11933*.
- Ruppert, N., & George, K.** (2022, June). Robotic Arm with Obstacle Detection Designed for Assistive Applications. In 2022 IEEE World Conference on Applied Intelligence and Computing (AIC) (pp. 437-443). IEEE.

- Safeea, M., & Neto, P.** (2019). Minimum Distance Calculation Using Laser Scanner and Imus for Safe Human-Robot Interaction. *Robotics and Computer-Integrated Manufacturing*, 58, 33-42. ISSN 0736-5845. <https://doi.org/10.1016/j.rcim.2019.01.008>
- Saudi, M., Hakim, A., Ahmad, A., Saudi, M., Shakir, A.** (2020). Image Detection Model for Construction Worker Safety Conditions using Faster R-CNN. *International Journal of Advanced Computer Science and Applications*.
- Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R., & LeCun, Y.** (2013). Overfeat: Integrated recognition, localization and detection using convolutional networks. *arXiv preprint arXiv:1312.6229*.
- Shruti, P., & Rekha, R.** (2023, February). A Review of Convolutional Neural Networks, its Variants and Applications. In *2023 International Conference on Intelligent Systems for Communication, IoT and Security (ICISCoIS)* (pp. 31-36). IEEE.
- Sohn, I.** (2021). Deep belief network based intrusion detection techniques: A survey. *Expert Systems with Applications*, 167, 114170.
- Şimşek, E., Ozyer, G. T., & Ozyer, B.** (2015). Direction and Position Reconstruction on Mobile Robots. *Balkan Journal of Electrical and Computer Engineering*, 3, 196-201.
- Tan, M., Pang, R., & Le, Q. V.** (2020). Efficientdet: Scalable and efficient object detection. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 10781-10790).
- Topolsky, D., Topolskaya, I., Plaksina, I., Shaburov, P., Yumagulov, N., Fedorov, D., & Zvereva, E.** (2022). Development of a mobile robot for mine exploration. *Processes*, 10(5), 865.
- Toshev, A., & Szegedy, C.** (2014). Deeppose: Human pose estimation via deep neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1653-1660).
- Uguina, J. R. M., & Ruiz, A. B. M.** (2019). Robotics and Health and Safety at Work. *International Journal of Swarm and Evolutionary Computation*, 8, 176. DOI: 10.24105/2090-4908.2019.8.176
- Viola, P., & Jones, M.** (2001, December). Rapid object detection using a boosted cascade of simple features. In *Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001* (Vol. 1, pp. I-I). Ieee.
- Wang, L., Xie, L., Yang, P., Deng, Q., Du, S., Xu, L.** (2020). Hardhat-Wearing Detection Based on a Lightweight Convolutional Neural Network with Multi-Scale Features and a Top-Down Module. *Sensors*, 20(7), 1868.
- Wang, X., Niu, D., Luo, P., Zhu, C., Ding, L., Huang, K.** (2020). A Safety Helmet and Protective Clothing Detection Method based on Improved-YOLO V 3. In *2020 Chinese Automation Congress (CAC)* (pp. 5437-5441). IEEE.
- Wu, J., Cai, N., Chen, W., Wang, H., Wang, G.** (2019). Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset. *Automation in Construction*, 106, 102894.

- Xu, J., Zhang, Z., Friedman, T., Liang, Y., & Broeck, G.** (2018, July). A semantic loss function for deep learning with symbolic knowledge. In International conference on machine learning (pp. 5502-5511). *PMLR*.
- Yang, X., Xie, Y., Yang, S., Liang, P., He, Y., Yang, J., ... & He, Y.** (2023, May). Research on application of object detection based on yolov5 in construction site. In *2023 15th International Conference on Advanced Computational Intelligence (ICACI)* (pp. 1-6). IEEE.
- Youssef, A. A., El Khoreby, M. A., Issa, H. H., & Abdellatif, A.** (2022). Brief Survey on Industry 4.0 Warehouse Management Systems.
- Zhang, W., Yang, C.-f., Jiang, F., Gao, X.-z., & Zhang, X.** (2020). Safety Helmet Wearing Detection Based on Image Processing and Deep Learning. In 2020 International Conference on Communications, Information System and Computer Engineering (CISCE) (pp. 343-347). Kuala Lumpur, Malaysia. doi: 10.1109/ CISCE50729.2020.00076
- Zhang, Z., Deng, Z., Wu, Z., & Lai, G.** (2022, August). An Improved EIoU-YOLOv5 Algorithm for Blood Cell Detection and Counting. In *2022 5th International Conference on Pattern Recognition and Artificial Intelligence (PRAI)* (pp. 989-993). IEEE.
- Zhou, F., Zhao, H., Nie, Z.** (2021). Safety Helmet Detection Based on YOLOv5. In 2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA) (pp. 6-11). IEEE
- Zhou, X., Wang, D., & Krähenbühl, P.** (2019). Objects as points. *arXiv preprint arXiv:1904.07850*.
- Zhu, L., Zhang, J., & Jia, C.** (2022, November). An improved yolov5-based method for surface defect detection of steel plate. In *2022 China Automation Congress (CAC)* (pp. 2233-2238). IEEE.
- Zou, Z., Chen", K., Shi, Z., Guo, Y., & Ye, J.** (2023). Object detection in 20 years: A survey. *Proceedings of the IEEE*.

#### İnternet Kaynakları

**Mobile robot**, (2022) alındığı tarih: 01.02.2022, adres:

[https://en.wikipedia.org/wiki/Mobile\\_robot](https://en.wikipedia.org/wiki/Mobile_robot)

**Url-1**<[https://www.freepik.com/free-vector/warehouse-automation-banners-set\\_6147488.htm#query=factory%20machine&position=24&from\\_view=keyword&track=ais](https://www.freepik.com/free-vector/warehouse-automation-banners-set_6147488.htm#query=factory%20machine&position=24&from_view=keyword&track=ais)> alındığı tarih: 18.03.2023

**Url-1**<[https://www.freepik.com/free-vector/intelligent-automated-manufacturing-isometric-composition\\_6169445.htm](https://www.freepik.com/free-vector/intelligent-automated-manufacturing-isometric-composition_6169445.htm)> alındığı tarih: 18.03.2023

## ÖZGEÇMİŞ

### ÖĞRENİM DURUMU

- Lisans: 2004, Kocaeli Üniversitesi, Mühendislik Fakültesi  
Elektronik ve Haberleşme Mühendisliği
- Lisans: 2018, İstanbul Üniversitesi, Açık ve Uzaktan Eğitim Fakültesi  
Sosyoloji
- Lisans: 2022, İstanbul Üniversitesi, Açık ve Uzaktan Eğitim Fakültesi  
İş Sağlığı ve Güvenliği
- Yüksek Lisans: 2016, İstanbul Gedik Üniversitesi, Sosyal Bilimler Enstitüsü  
İş Sağlığı ve Güvenliği
- Yüksek Lisans: 2022, Marmara Üniversitesi, Fen Bilimleri Enstitüsü  
Mekatronik Mühendisliği

### TEZDEN TÜRETİLEN YAYINLAR

Aslan, T. & Yağımlı, M. (2023). İş Sağlığı ve Güvenliğinde Derin Öğrenme Tabanlı Risk Tespit ve Analizi . The Journal of International Scientific Researches , 8 (2) , 223-236 . Retrieved from <https://dergipark.org.tr/tr/pub/isrjournal/issue/78902/1288496>

### DİĞER YAYINLAR

Aslan, T., & Aküner, M. C. (2020). 3 Boyutlu Yazıcı Desteği ile Nüvesiz Tip Alternatör Tasarımı. Presented at the Yenilikçi Teknolojiler Sempozyumu (ISITES2020), Bursa. DOI:<https://dx.doi.org/10.33793/acperpro>

### AKADEMİK VE İDARİ GÖREVLER

Öğretim Görevlisi- İstanbul Okan Üniversitesi, MYO, Elektronik ve Otomasyon Bölümü (2016-2020) Program Başkanı, (2020-2021) Bölüm Başkanı

Öğretim Görevlisi – Karadeniz Teknik Üniversitesi, Rektörlük, İşyeri Sağlık ve Güvenlik Koordinatörü (2021-Devam Ediyor)