

**T.C.  
ONDOKUZ MAYIS ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
AKILLI SİSTEMLER MÜHENDİSLİĞİ ANA BİLİM DALI**



## **GIDA GÜVENLİĞİNİN SAĞLANMASINDA GÖRÜNTÜ İŞLEME UYGULAMASI**

Yüksek Lisans Tezi

**Cansunur ÇOKOKUMUŞ**

Danışman

**Prof. Dr. Sermin ELEVLİ**

SAMSUN  
2024

## TEZ KABUL VE ONAYI

**Cansunur ÇOKOKUMUŞ** tarafından, **Prof. Dr. Sermin ELEVLİ** danışmanlığında hazırlanan “**GIDA GÜVENLİĞİNİN SAĞLANMASINDA GÖRÜNTÜ İŞLEME UYGULAMASI**” başlıklı bu çalışma, jürimiz tarafından 6.8.2024 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

|               | Unvanı Adı Soyadı<br>Üniversitesi<br>Ana Bilim/Ana Sanat Dalı                                                      | Sonuç                                                                     |
|---------------|--------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------|
| <b>Başkan</b> | Prof. Dr. Mehmet Serhat<br>ODABAŞ<br>Ondokuz Mayıs Üniversitesi<br>Akıllı Sistemler Mühendisliği Ana<br>Bilim Dalı | <input checked="" type="checkbox"/> Kabul<br><input type="checkbox"/> Ret |
| <b>Üye</b>    | Prof. Dr. Sermin ELEVLİ<br>Ondokuz Mayıs Üniversitesi<br>Akıllı Sistemler Mühendisliği Ana<br>Bilim Dalı           | <input checked="" type="checkbox"/> Kabul<br><input type="checkbox"/> Ret |
| <b>Üye</b>    | Dr. Öğr. Üyesi Aycan<br>PEKPAZAR<br>Samsun Üniversitesi<br>Endüstri Mühendisliği Ana Bilim<br>Dalı                 | <input checked="" type="checkbox"/> Kabul<br><input type="checkbox"/> Ret |

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

Prof. Dr. Ahmet TABAK  
Enstitü Müdürü

## BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Yüksek Lisans tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi ?

Evet ☐ (Gerekli ise ekler kısmına ekleyiniz)

Hayır ☒

06 / 08 / 2024

Cansunur ÇOKOKUMUŞ

## TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

**Tez Başlığı :** GIDA GÜVENLİĞİNİN SAĞLANMASINDA GÖRÜNTÜ İŞLEME UYGULAMASI

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 06.06.2024 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 8

Tek kaynak oranı : % 2 çıkmıştır.

06 / 08 / 2024

Prof. Dr. Sermin ELEVLİ

## ÖZET

### GIDA GÜVENLİĞİNİN SAĞLANMASINDA GÖRÜNTÜ İŞLEME UYGULAMASI

Cansunur ÇOKOKUMUŞ  
Ondokuz Mayıs Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Akıllı Sistemler Mühendisliği Ana Bilim Dalı  
Yüksek Lisans, Ağustos / 2024  
Danışman: Prof. Dr. Sermin ELEVLİ

Gıda güvenliği yönetiminin etkin bir şekilde sağlanmasının temelinde iyi hijyen uygulamaları bulunmaktadır. Gıda işletmecileri, iyi hijyen uygulamaları için kimyasal, biyolojik ve fiziksel nedenlerden kaynaklı her türlü bozulma ve bulaşmaya sebep olan etkenin farkında olmalı ve tüketicinin sağlığını korumak için gerekli önlemleri alarak gıda hijyenini sağlamalıdır. Gıda hijyeninin sağlanarak gıda kaynaklı sorunların önlenmesinde temizlik, sterilizasyon, atık yönetimi, ekipman bakımı ve kontrolü, personelin kişisel hijyeni gibi iyi hijyen uygulamaları yer almaktadır. Bu kapsamda personelin kişisel koruyucu ekipman (KKE) kullanımı gıda güvenliğini sağlama hususunda başvuru alan temel önleyici tedbirler arasında ele alınmaktadır. Yemek hazırlık ve servis alanlarında önlük, eldiven, şapka ve maske gibi KKE'lerin personel tarafından kullanımı süreklilik esasına dayandırılmalıdır. İnsanların çoğu kontrol edildiğini bildiğinde kurallara uyma konusunda daha fazla özen gösterdiğinden bu konuda personel takibi önem arz etmektedir. Ancak söz konusu takibin sürekliliği zor olup, kimi zaman ekstra iş yükü getirebilmektedir. Yapay zekanın gelişmesiyle birlikte görüntü işleme uygulamaları, otomatik ve süreklilik esasına dayalı kontrolün gerçekleştirilmesinde büyük fayda sağlamaktadır.

Tez çalışması kapsamında, restoran mutfaklarında gıdaların hazırlık ve pişirme aşamalarında gıda güvenliği ve hijyenini sağlamak için KKE kullanımı ile ilgili uygunsuzlukların görüntü işleme teknolojisi kullanılarak tespit edilmesi hedeflenmiştir. Bunun sağlanması için gerçek zamanlı, hızlı işlem gücüne ve yüksek doğruluk oranlarına sahip derin öğrenme tabanlı Yolo algoritması tercih edilmiştir. Çalışmada maske, üniforma, eldiven ve şapka gibi gıda sektöründe kullanılan KKE'ler farklı epoch sayılarında Yolov5, Yolov8 ve Yolov9 nesne tespit algoritmaları kullanılarak tespit edilmiştir. En iyi sonuçlar Yolov9 algoritması kullanılarak elde edilmiş olup %88,5 kesinlik, %90,9 duyarlılık, %92,7 mAP değerine ulaşılarak yüksek bir başarı sağlanmıştır.

**Anahtar Sözcükler:** KKE, Görüntü İşleme, Nesne Tespiti, Gıda Güvenliği, Yolo Algoritmaları.

# ABSTRACT

## IMAGE PROCESSING APPLICATION IN ENSURING FOOD SAFETY

Cansunur ÇOKOKUMUŞ  
Ondokuz Mayıs University  
Institute of Graduate Studies  
Department of Intelligent Systems Engineering  
Master, August / 2024  
Supervisor: Prof. Dr. Sermin ELEVLİ

Good hygiene practices are the basis for effective food safety management. For good hygiene practices, food business operators should be aware of all kinds of factors that cause spoilage and contamination due to chemical, biological and physical reasons, and ensure food hygiene by taking the necessary precautions to protect the health of the consumer. Good hygiene practices such as cleaning, sterilization, waste management, equipment maintenance and control, personnel personal hygiene are included in preventing foodborne problems by ensuring food hygiene. In this context, the use of personal protective equipment (PPE) by personnel is considered among the basic preventive measures used to ensure food safety. The use of PPE such as aprons, gloves, hats and masks by personnel in food preparation and service areas should be based on continuity. Personnel monitoring is important in this regard, as most people pay more attention to complying with the rules when they know they are being controlled. However, continuity of such follow-up is difficult and can sometimes bring extra workload. With the development of artificial intelligence, image processing applications provide great benefits in realizing automatic and continuous control.

Within the scope of the thesis study, it is aimed to detect non-conformities regarding the use of PPE by using image processing technology in order to ensure food safety and hygiene during the preparation and cooking stages of food in restaurant kitchens. To achieve this, the deep learning-based Yolo algorithm, which has real-time, fast processing power and high accuracy rates, was preferred. In the study, PPE used in the food industry such as masks, uniforms, gloves and hats were detected using Yolov5, Yolov8 and Yolov9 object detection algorithms at different epoch numbers. The best results were obtained using the Yolov9 algorithm, and a high success rate was achieved by reaching 88.5% precision, 90.9% recall and 92.7% mAP value.

**Keywords:** PPE, Image Processing, Object Detection, Food Safety, Yolo Algorithms.

## ÖN SÖZ VE TEŞEKKÜR

Bu tez çalışmasında, gıda güvenliğinin korunmasına katkı sağlamak için gıda sektöründe kullanılan zorunlu kişisel koruyucu ekipmanların kullanım durumlarının görüntü işleme ve nesne tespiti teknolojilerinden faydalanılarak tespit edilmesi hedeflenmiştir.

Tez konumu seçerken isteklerimi göz önünde bulundurup tez yazma sürecimde bilgi ve tecrübesiyle bana yardımcı olan danışman hocam Prof. Dr. Sermin Elevli'ye ve yüksek lisans eğitimim süresince emeği geçen tüm hocalarıma teşekkürlerimi sunarım.

Tüm eğitim hayatım boyunca maddi ve manevi her türlü desteği sağlayarak her zaman yanımda duran canım aileme teşekkür ederim.

Cansunur ÇOKOKUMUŞ

Samsun - 2024

# İÇİNDEKİLER

|                                                                            |     |
|----------------------------------------------------------------------------|-----|
| TEZ KABUL VE ONAYI .....                                                   | i   |
| BİLİMSEL ETİĞE UYGUNLUK BEYANI .....                                       | ii  |
| TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI .....                                 | ii  |
| ÖZET .....                                                                 | iii |
| ABSTRACT .....                                                             | iv  |
| ÖN SÖZ VE TEŞEKKÜR.....                                                    | v   |
| İÇİNDEKİLER .....                                                          | vi  |
| SİMGELER VE KISALTMALAR.....                                               | vii |
| ŞEKİLLER DİZİNİ .....                                                      | ix  |
| TABLolar DİZİNİ .....                                                      | xi  |
| 1. GİRİŞ .....                                                             | 1   |
| 2. LİTERATÜR TARAMASI .....                                                | 4   |
| 3. GIDA GÜVENLİĞİ VE HİJYEN.....                                           | 12  |
| 4. GÖRÜNTÜ İŞLEME VE NESNE TESPİTİ .....                                   | 15  |
| 4.1. Görüntü İşleme .....                                                  | 15  |
| 4.2. Nesne Tespiti .....                                                   | 18  |
| 4.3. Görüntü İşleme ve Nesne Tespitinde Kullanılan Bazı Parametreler ..... | 21  |
| 4.4. Yolo Algoritması.....                                                 | 23  |
| 4.4.1. Yolov5 Algoritması .....                                            | 26  |
| 4.4.2. Yolov8 Algoritması .....                                            | 26  |
| 4.4.3. Yolov9 Algoritması .....                                            | 27  |
| 4.5. Performans Değerlendirme Metrikleri.....                              | 27  |
| 5. UYGULAMA.....                                                           | 30  |
| 5.1. Kişisel Koruyucu Ekipman Tespitinde Görüntü İşleme Metodolojisi ..... | 30  |
| 5.2. Veri Seti .....                                                       | 32  |
| 5.3. Veri Etiketleme .....                                                 | 33  |
| 5.4. Verilerin Eğitimi .....                                               | 35  |
| 5.4.4. Yolov5 ile Eğitim .....                                             | 35  |
| 5.4.5. Yolov8 ile Eğitim .....                                             | 38  |
| 5.4.6. Yolov9 ile Eğitim .....                                             | 41  |
| 5.4.7. Tüm Algoritma Sonuçlarının Sınıflar Bazında Değerlendirilmesi ..... | 43  |
| 6. SONUÇLAR VE ÖNERİLER.....                                               | 59  |
| KAYNAKLAR.....                                                             | 61  |
| EKLER .....                                                                | 65  |
| ÖZ GEÇMİŞ.....                                                             | 67  |

## SİMGELER VE KISALTMALAR

|        |                                                   |
|--------|---------------------------------------------------|
| AP     | : Avereage Precision                              |
| CCM    | : Color Co-Occurrence Matrix                      |
| CDC    | : Centers for Disease Control and Prevention      |
| CNN    | : Convulational Neural Network                    |
| FN     | : False Negative                                  |
| FP     | : False Positive                                  |
| FPS    | : Frame Per Second                                |
| GAN    | : Generative Adversarial Networks                 |
| GAP    | : Good Agricultural Practices                     |
| GELAN  | : Generalized Efficient Layer Aggregation Network |
| GHP    | : Good Hygiene Practices                          |
| GLCM   | : Gray Level Co-Occurrence Matrix                 |
| GMP    | : Good Manufacturing Practices                    |
| GPU    | : Graphics Processing Unit                        |
| HACCP  | : Hazard Analysis and Critical Control Points     |
| HOG    | : Histogram of Oriented Gradients                 |
| IP     | : Image Processing                                |
| İSG    | : İş Sağlığı ve Güvenliği                         |
| KKE    | : Kişisel Koruyucu Ekipman                        |
| mAP    | : Mean Average Precision - mAP                    |
| OD     | : Object Detection                                |
| PCA    | : Principal Components Analysis                   |
| PPE    | : Personal Protective Equipment                   |
| PPED   | : Personal Protective Equipment Detection         |
| PGI    | : Programmable Gradient Information               |
| R-CNN  | : Region-based Convolutional Neural Networks      |
| ResNet | : Residual Network                                |
| RNN    | : Recurrent Neural Network                        |
| SIFT   | : Scale Invariant Feature Transform               |
| SSD    | : Single Shot Multibox Detector                   |
| SURF   | : Speeded-Up Robust Features                      |



TN : True Negative  
TP : True Positive  
v1 : Versiyon 1  
v2 : Verison 2  
YOLO : You Only Look Once  
WHO : World Health Organisation



## ŞEKİLLER DİZİNİ

|                                                                                           |    |
|-------------------------------------------------------------------------------------------|----|
| Şekil 2.1. Scopus Veri Tabanına ait arama sonuçları .....                                 | 4  |
| Şekil 2.2. ScienceDirect Veri Tabanına ait arama sonuçları .....                          | 5  |
| Şekil 2.3. IEEE Xplore Veri Tabanına ait arama sonuçları .....                            | 5  |
| Şekil 2.4. Ulusal Tez Merkezi tarama sonuçları.....                                       | 6  |
| Şekil 2.5. Yıllara göre en çok atıf alan makaleler .....                                  | 6  |
| Şekil 4.1. Görüntü işleme adımları .....                                                  | 17 |
| Şekil 4.2. Tek aşamalı ve iki aşamalı nesne tespiti algoritmaları.....                    | 19 |
| Şekil 4.3. Bağlantı kutuları .....                                                        | 21 |
| Şekil 4.4. Batch ve Epoch sayısı .....                                                    | 22 |
| Şekil 4.5. Sınırlayıcı kutular .....                                                      | 22 |
| Şekil 4.6. Yolo algoritmasına ait bibliyometrik ağ görselleştirmesi .....                 | 24 |
| Şekil 5.1. KKE tespiti görüntü işleme metodolojisi.....                                   | 30 |
| Şekil 5.2. Verilerin etiketlenmesi .....                                                  | 34 |
| Şekil 5.3. Roboflow ile etiketlenmiş resim ve Yolo algoritması formatında etiketler ..... | 34 |
| Şekil 5.4. Yolov5 15 epoch eğitim sonuçları (v1).....                                     | 36 |
| Şekil 5.5. Yolov5 25 epoch eğitim sonuçları (v1).....                                     | 36 |
| Şekil 5.6. Yolov5 50 epoch eğitim sonuçları (v1).....                                     | 36 |
| Şekil 5.7. Yolov5 15 epoch eğitim sonuçları (v2).....                                     | 37 |
| Şekil 5.8. Yolov5 25 epoch eğitim sonuçları (v2).....                                     | 37 |
| Şekil 5.9. Yolov5 50 epoch eğitim sonuçları (v2).....                                     | 37 |
| Şekil 5.10. Yolov8 15 epoch eğitim sonuçları (v1).....                                    | 39 |
| Şekil 5.11. Yolov8 25 epoch eğitim sonuçları (v1) .....                                   | 39 |
| Şekil 5.12. Yolov8 50 epoch eğitim sonuçları (v1).....                                    | 39 |
| Şekil 5.13. Yolov8 15 epoch eğitim sonuçları (v2).....                                    | 40 |
| Şekil 5.14. Yolov8 25 epoch eğitim sonuçları (v2).....                                    | 40 |
| Şekil 5.15. Yolov8 50 epoch eğitim sonuçları (v2).....                                    | 40 |
| Şekil 5.16. Yolov9 15 epoch eğitim sonuçları (v1).....                                    | 42 |
| Şekil 5.17. Yolov9 25 epoch eğitim sonuçları (v1).....                                    | 42 |
| Şekil 5.18. Yolov9 50 epoch eğitim sonuçları (v1).....                                    | 42 |
| Şekil 5.19. Yolov9 15 epoch eğitim sonuçları (v2).....                                    | 43 |
| Şekil 5.20. Yolov9 25 epoch eğitim sonuçları (v2).....                                    | 43 |
| Şekil 5.21. Yolov9 50 epoch eğitim sonuçları (v2).....                                    | 43 |
| Şekil 5.22. Şef üniforması sınıfı mAP50 – süre grafiği .....                              | 52 |
| Şekil 5.23. Eldiven sınıfı mAP50 – süre grafiği .....                                     | 52 |
| Şekil 5.24. Şapka sınıfı mAP50 – süre grafiği .....                                       | 53 |
| Şekil 5.25. Maske sınıfı mAP50 – süre grafiği .....                                       | 53 |

|                                                               |    |
|---------------------------------------------------------------|----|
| Şekil 5.26. Eldivensiz sınıfı mAP50 – süre grafiği.....       | 54 |
| Şekil 5.27. Şapkasız sınıfı mAP50 – süre grafiği .....        | 54 |
| Şekil 5.28. Maske sınıfı mAP50 – süre grafiği.....            | 55 |
| Şekil 5.29. Üniformasız sınıfı mAP50 – süre grafiği.....      | 55 |
| Şekil 5.30. Sınıflar için en iyi tahmin algoritmaları.....    | 56 |
| Şekil 5.31. F1-Güven Eğrisi.....                              | 57 |
| Şekil 5.32. Kesinlik - Duyarlılık Eğrisi.....                 | 57 |
| Şekil 5.33. Test veri setindeki görsellerden örnekler .....   | 58 |
| Şekil 5.34. Veri setinde bulunmayan videolardan örnekler..... | 58 |



## TABLÖLAR DİZİNİ

|                                                                                                            |    |
|------------------------------------------------------------------------------------------------------------|----|
| Tablo 2.1. Literatür taraması sonuçları .....                                                              | 4  |
| Tablo 2.2. KKE tespitinde görüntü işleme uygulamalarının kullanıldığı çalışmalara ait literatür özeti..... | 10 |
| Tablo 4.1. Yolo algoritması versiyonları.....                                                              | 25 |
| Tablo 4.2. Karışıklık matrisi .....                                                                        | 28 |
| Tablo 4.3. Yolov5, Yolov8 ve Yolov9 algoritmalarının COCO veri setindeki performans karşılaştırması.....   | 29 |
| Tablo 5.1. Veri seti .....                                                                                 | 32 |
| Tablo 5.2. Veri etiketleri (v1) .....                                                                      | 33 |
| Tablo 5.3. Tüm Sınıflar için Yolov5 algoritması eğitim sonuçları.....                                      | 35 |
| Tablo 5.4. Tüm sınıflar için Yolov8 algoritması eğitim sonuçları.....                                      | 38 |
| Tablo 5.5. Tüm sınıflar için Yolov9 algoritması eğitim sonuçları.....                                      | 41 |
| Tablo 5.6. Şef üniforması sınıfı için eğitim sonuçlarının karşılaştırması.....                             | 44 |
| Tablo 5.7. Eldiven sınıfı için eğitim sonuçlarının karşılaştırması.....                                    | 45 |
| Tablo 5.8. Şapka sınıfı için eğitim sonuçlarının karşılaştırması .....                                     | 46 |
| Tablo 5.9. Maske sınıfı için eğitim sonuçlarının karşılaştırması.....                                      | 47 |
| Tablo 5.10. Eldivensiz sınıfı için eğitim sonuçlarının karşılaştırması .....                               | 48 |
| Tablo 5.11. Şapkasız sınıfı için eğitim sonuçlarının karşılaştırması .....                                 | 49 |
| Tablo 5.12. Maskesiz sınıfı için eğitim sonuçlarının karşılaştırması .....                                 | 50 |
| Tablo 5.13. Üniformasız sınıfı için eğitim sonuçlarının karşılaştırması .....                              | 51 |

# 1. GİRİŞ

Hijyen standartlarına uyum, gıda güvenliğinin sağlanmasında en etkili gerekliliklerden birisidir. Bu kapsamda çalışanların temizlik kurallarına uymaları, üniforma, eldiven, bone ve maske gibi kişisel koruyucu ekipmanları kullanmaları gerekmektedir. Bilindiği üzere insanların çoğu, kontrol edildiklerinde kurallara uyma konusunda daha fazla özen göstermektedir. Bu noktada sürekliliğin sağlanması adına personel takibi önem taşımaktadır. Fakat söz konusu takibin sürekliliği zor olup kimi zaman ekstra iş yükü getirebilmektedir. Yapay zekâ temelli görüntü işleme tekniklerinin gelişmesiyle birlikte personel takibinin ve uygunsuzlukların tespitinin süreklilik esasına dayalı, otomatik ve yüksek doğrulukla yapılması mümkün hale gelmiştir.

Yapay zekâ, insanların akıl yürütme, analiz etme ve karar verme gibi yeteneklerini taklit ederek karmaşık görevlerin yerine getirilebilmesi için gerekli nitelikleri bulunduran makineler ve sistemlerdir. Yapay zekâ terimi, ilk kez 1956 yılında Dartmouth Konferansı'nda John McCarty, Marvin Minsky ve Claude Shannon tarafından kullanılmıştır (Alpaydın, 2013). Yapay zekâ teknolojisi, sorunların çözümü için makine öğrenmesi ve derin öğrenmeyi kullanmaktadır. Makine öğrenmesi, makinelerin belirli bir bilgiyi öğrendikten sonra o bilgiyi kullanarak tahmin çıkarımları yapmasını sağlamaktadır (Tekyaygil, 2020). Derin öğrenme ise makine öğrenmesinin bir alt sınıfı olup çok daha karmaşık problemlerin çözümü için geliştirilmiştir. Derin öğrenme, çok katmanlı yapay sinir ağlarını kullanarak makineler tarafından verilerin işlenmesini ve analiz edilmesini sağlamaktadır. Derin öğrenme metodlarının, görüntü işleme, nesne tespiti, robotik ve otomasyon, doğal dil işleme, ses işleme vb. birçok alanda kullanılmasıyla başarılı sonuçlara ulaşılmaktadır.

Günümüzde kullanımı giderek yaygınlaşan bu teknolojilerden görüntü işleme, kameralar veya sensörler aracılığıyla alınan görüntüleri analiz eden ve elde ettiği bu analiz sonuçlarına dayalı bilgi üretme yeteneğiyle dikkat çeken bir bilgisayar teknolojisidir. Bu teknoloji, nesne tespiti konusundaki yetenekleriyle sağlık alanında hastalık teşhisinde, askeri güvenlikte tehdit algılama sistemlerinde, trafik yönetiminde güvenlik önlemlerinde, endüstride kalite kontrolünde, tarımda verimlilik artışında, astronomide uzay keşiflerinde ve çevre güvenliğinde doğal felaketlerin izlenmesinde önemli bir rol oynamaktadır.

Görüntü işleme ve derin öğrenme teknikleriyle başarılı sonuçlara ulaşan nesne tespiti dijital görüntülerde ve videolarda belirli bir sınıfa ait nesneleri algılayan, nesnelerin koordinatlarını ve türünü belirlemeyi sağlayan bir yapay zekâ teknolojisidir. Nesne tespiti uygulamaları güvenlik denetimi, tıbbi görüntüleme, endüstriyel denetim alanları, otomotiv sektörü, KKE tespiti, mağaza stok düzeylerinin ve satışların izlenmesi, kargo izleme, paket sınıflandırma ve teslimat yönetimi gibi lojistik işlemlerde, günlük yaşantımızda kullandığımız akıllı ev cihazları vb. birçok alanda kullanılmaktadır.

KKE'lerin sürekli, otomatik ve doğru bir şekilde belirlenmesinde nesne tespiti önemli bir rol oynamaktadır. Güvenliği ve hijyeni sağlamak için kullanılan KKE'ler kullanım alanlarına bağlı farklılık göstermekte ve kullanımı önem arz etmektedir. Fabrikalarda, atölyelerde, inşaat alanlarında, yapı işlerinde ve diğer endüstriyel tesislerde çalışanlar iş eldiveni, iş gözlüğü, kulak koruyucuları, emniyet kaskları vb. KKE'ler kullanmaktadır. Kimyasal tesislerde, laboratuvarlarda ve tehlikeli madde işleme tesislerinde çalışan işçiler ile sağlık personellerinin kullandığı KKE'ler arasında cerrahi maske, eldiven, önlük vb. bulunmaktadır. Gıda üretim tesislerinde çalışanlar ise temizlik ve hijyen kuralları gereği maske, üniforma, şapka/bone, eldiven vb. KKE'ler kullanmaktadır. Literatürde KKE için farklı sektörlere yönelik nesne tespiti ile ilgili yapılan birçok çalışmaya rastlanılmaktadır. Fakat konuyla ilgili gıda alanında yapılmış çalışmaların eksikliği dikkat çekmektedir.

Tez çalışması kapsamında gıda alanında güvenliğin ve hijyenin sağlanması için personelin KKE kullanımı ile ilgili uygunsuzlukların tespit edilmesi hedeflenmiştir. Bunun sağlanması için gerçek zamanlı, hızlı ve yüksek doğruluk değerlerine sahip yöntemlere ihtiyaç duyulmaktadır. Son yıllarda yapılan çalışmalar incelendiğinde, gelişen teknolojiyle birlikte nesne tespitinde geleneksel yöntemlere kıyasla derin öğrenme algoritmalarının kullanımının ve öneminin arttığı ve yüksek başarı oranlarına ulaşıldığı anlaşılmaktadır. Çalışmada, yapay zekâ temelli derin öğrenme algoritmaları arasında yer alan gerçek zamanlı tespit, hızlı işlem gücü ve yüksek doğruluk değerlerine ulaşabilmesi nedeniyle Yolo algoritmaları kullanılmıştır. Yolo algoritmalarından Yolov5 hızlı olduğu için tercih edilirken son versiyonlardan Yolov8 (2023) ve Yolov9 (2024) ise yüksek doğruluk değerlerine ulaşabilmesi ve yeni yayınlanmaları nedeniyle tercih edilmiştir.

Bu alanda yapılan çalışmalarla karşılaştırıldığında çalışmanın öne çıkan özellikleri ve farkları aşağıda sıralanmıştır:

- Gıda sektöründe hijyen standartlarının sağlanması için kullanılması gereken KKE'lerin görüntü işleme ve nesne tespiti teknikleriyle yüksek doğruluk ve gerçek zamanlı belirlenmesine yönelik çalışmalara duyulan ihtiyacı karşılayacak özelliklere sahip olması
- Yeterli sayıda veri seti elde edilebilmesi için erişilebilir web kaynaklarından yararlanılması
- Nesne tespitinde Yolo ailesine 2024 yılında yeni katılan Yolov9 algoritmasının kullanılması

Çalışmanın sonraki kısımları şu şekilde organize edilmiştir. İkinci kısımda, konu ile ilgili literatür detaylı bir şekilde açıklanarak grafik destekli sunulmuştur. Üçüncü kısımda, gıda güvenliği, hijyen ve bunu sağlamak adına kullanılması gereken KKE'lerden bahsedilmiştir. Dördüncü kısımda, görüntü işleme ve nesne tespiti ile ilgili detaylı bilgilendirme yapılarak çalışmada kullanılan algoritmalar anlatılmıştır. Beşinci kısımda, araştırmada kullanılan veri setinin özelliklerinden ve uygulanan yöntemlerden bahsedilmiş sonrasında ise çalışmadan elde edilen sonuçlar hakkında bilgi verilerek önerilerde bulunulmuştur.


## 2. LİTERATÜR TARAMASI

Scopus, IEEE Xplore ve ScienceDirect veri tabanlarında başlık, özet ve anahtar kelimelerde olmak üzere “Kişisel Koruyucu Ekipman Tespiti (Personal Protective Equipment Detection - PPED)”, “Görüntü İşleme (Image Processing - IP)” ve “Nesne Tespiti (Object Detection - OD)” kelimeleri seçilerek literatür taraması yapılmıştır. Tablo 2.1. de sayısal sonuçlar görülmektedir.

Tablo 2.1. Literatür taraması sonuçları


| Veri Tabanı   | Makale Başlığı, Özet, Anahtar Kelime |           |            |            |
|---------------|--------------------------------------|-----------|------------|------------|
|               | PPED                                 | PPED+IP   | PPED+OD    | PPED+IP+OD |
| Scopus        | 747                                  | 29        | 109        | 17         |
| ScienceDirect | 125                                  | 4         | 16         | 4          |
| IEEE Xplore   | 55                                   | 4         | 27         | 4          |
| <b>Toplam</b> | <b>927</b>                           | <b>37</b> | <b>152</b> | <b>25</b>  |

KKE tespiti için güncel ve ilgi çeken bir konu olduğu Şekil 2.1., Şekil 2.2. ve Şekil 2.3. teki farklı veri tabanlarının yıllara göre arama sonuçlarından anlaşılmaktadır. Özellikle yapay zekâ teknolojilerinin gelişmesiyle birlikte KKE tespitinde görüntü işleme ve nesne tespiti kullanımı son yıllarda ciddi oranda artış göstermiştir.




Şekil 2.1. Scopus Veri Tabanına ait arama sonuçları






Şekil 2.2. ScienceDirect Veri Tabanına ait arama sonuçları



Şekil 2.3. IEEE Xplore Veri Tabanına ait arama sonuçları


Yıllara göre arama sonuçlarına bakıldığında, KKE tespiti ile ilgili yapılan çalışmaların sayısının görüntü işleme ve nesne tespiti kullanılarak KKE tespiti yapılan çalışmalara kıyasla daha fazla olduğu dikkat çekmektedir. 2017 ve sonrasında yapılan çalışmalarda görüntü işleme ve nesne tespiti uygulamalarının sayısında artış yaşandığı gözlemlenmektedir.

Konu ile ilgili Ulusal Tez Merkezinde, 2024 yılı Mayıs ayı itibarıyla KKE tespiti ile ilgili yapılmış bir çalışma bulunamadığından “Görüntü İşleme” ve “Nesne Tespiti” kelimeleri seçilerek tarama yapılmıştır. Taramada “Görüntü İşleme” kelimesi seçildiğinde 1.918, “Nesne Tespiti” kelimesi seçildiğinde 240 ve bu anahtar kelimeler birlikte seçildiğinde toplamda 72 adet çalışma tespit edilmiştir. Çalışmaların yıllara göre sayısal sonuçları Şekil 2.4. te görülmektedir.



Şekil 2.4. Ulusal Tez Merkezi tarama sonuçları

Sayısal sonuçlara bakıldığında görüntü işleme ve nesne tespiti alanında yapılan çalışmaların popülerliğini koruduğu dikkat çekmektedir. Google Scholar veri tabanında yapılan taramada, yıllara göre en çok atıf alan ve tez konusu ile en çok ilgisi bulunan makaleler Şekil 2.5. te sıralanmış ve çalışmaların sonuçları incelenmiştir.



Şekil 2.5. Yıllara göre en çok atıf alan makaleler

- ❖ Zhou vd. (2021), çalışmalarında emniyet kaskı tespiti için Yolov5 (s,m,l,x) algoritmasını kullanmışlardır. Algoritmaların eğitim öncesi ağırlıkları kullanılarak Yolov5s için %93,6 mAP, Yolov5m için %94,3 mAP, Yolov5l için %94,4 mAP ve Yolov5x için %94,7 mAP değerleri bulunmuştur. En iyi değere en yüksek mAP değerine sahip Yolov5x algoritmasıyla ulaşılmıştır.
- ❖ Nath vd. (2020), çalışmalarında Yolov3 algoritmasını kullanmışlardır. Üç yaklaşım belirleyerek işçi, şapka ve yelek tespiti ile KKE uyumluluğunu doğrulamışlardır. Birinci yaklaşımda %63,1 mAP, ikincide %72,3 mAP ve üçüncüde %67,9 mAP değeri elde edilmiştir. Tespit hızları birinci yaklaşımda 13 FPS (Frame Per Second), ikincide 11 FPS ve üçüncüde 3 FPS bulunmuştur. Çalışmada en hızlı yaklaşım birinci, en iyi performans ikinci yaklaşım seçilmiştir.
- ❖ Huang vd. (2021), çalışmalarında emniyet kaskı tespiti için SSD, Yolov3, geliştirilmiş Yolov3 ve Faster R-CNN algoritmalarını kullanarak sonuçları karşılaştırmışlardır. En iyi performans %94,3 mAP değeri ile Faster R-CNN'de sonrasında ise %93,1 mAP değeri ile geliştirilmiş Yolov3 algoritmasında elde edilmiştir. İşlem hızına bakıldığında ise Faster R-CNN 4 FPS, geliştirilmiş Yolov3 65 FPS değerlerine ulaşmıştır. Faster R-CNN gerçek zamanlı uygulamalar için çok yavaş kaldığından geliştirilmiş Yolov3 algoritmasının daha iyi uyum sağlayabileceği tespit edilmiştir.
- ❖ Wang vd. (2021), çalışmalarında kişi, baret (kırmızı, beyaz, mavi, sarı) ve yelek tespiti için Yolov3, Yolov4 ve Yolov5 algoritmalarını kullanmışlardır. Yolov5x %86,55 mAP değeri ile en iyi sonuçlara, Yolov5s ise 52 FPS ile en yüksek hıza sahip model seçilmiştir.
- ❖ Hayat ve Dias (2022), çalışmalarında baret ve kafa tespiti için Yolov3, Yolov4 ve Yolov5 algoritmalarını kullanarak sırasıyla %85,78 mAP, %90,64 mAP ve %92,44 mAP değerlerine ulaşmışlardır. En başarılı sonuçlar Yolov5 algoritmasıyla elde edilmiştir.
- ❖ Zeng vd. (2023), baret tespiti için geliştirdikleri Yolov4 algoritmasını kullanmışlardır. Orjinal Yolov4'e kıyasla daha başarılı sonuçlara ulaşan geliştirilmiş Yolov4 algoritmasıyla %93,74 mAP değeri elde edilmiştir.

- ❖ Tang vd. (2020), Faster R-CNN algoritmasını kullanarak farklı sınıflara ait nesneleri ve işçileri tespit etmişlerdir. Tüm sınıflar için ortalama mAP değeri %52,9 elde edilirken işçi sınıfı için %89,4 mAP değerine ulaşılmıştır. Sonrasında ise insan-obje etkileşimini sağlamak için geliştirilen modelde, baret kontrolü için %79,78 kesinlik, %77,64 duyarlılık; güvenlik renklendirme kontrolü için %79,11 kesinlik, %75,29 duyarlılık; el koruması kontrolü için %66,2 kesinlik ve %64,2 duyarlılık değerleri elde edilmiştir.
- ❖ Chen vd. (2023), baret tespiti için geliştirilmiş Yolov4 algoritmasını kullanmışlardır. Orjinal Yolov4 algoritmasına kıyasla model boyutu daha küçük, daha hızlı ve daha yüksek doğrulukta çalışan bir model elde edilmiştir. Geliştirilmiş Yolov4 algoritması ile %92,78 kesinlik, %86,35 duyarlılık ve %92,98 mAP değerlerine ulaşılmıştır.
- ❖ Tomas vd. (2021), çalışmalarında yüz maskesi tespiti için transfer öğrenme ve CNN kullanmışlardır. Kullanılan modellerden VGG-16 ile maskesiz kişilerin tespitinde %100'e ulaşılırken burnu dışarıda kalarak maske takanlar için ise %93 kesinlik değeriyle en iyi sonuçlara ulaşılmıştır.
- ❖ Son ve Kim (2021), çalışmalarında inşaat işçisi tespiti ve takibi için bir model (Yolov4 ve Siyam Ağları) önermişlerdir. Sabah 9-12 aralığında yapılan tespitte %96,34 doğruluk, kişinin tamamının görüldüğü tespitlerde ise %97,14 doğruluk elde ederek en başarılı sonuçlara ulaşmışlardır.
- ❖ Delhi ve Thomas (2020), çalışmalarında 4 sınıfa (baretsiz, yeleksiz, güvenli değil, güvenli) ait nesne tespiti için geliştirilmiş Yolov3 algoritmasını kullanmışlardır. Kullanılan model, %96 F1 puanı ve %96,92 doğruluk değerlerine ulaşmıştır.
- ❖ Nath ve Behzadan (2020), çalışmalarında bina, işçi ve ekipman tespiti için Yolov2 algoritmasını ve Yolov3 algoritmasını kullanmışlardır. Farklı veri kombinasyonlarında test edilen modellerden en başarılı sonuca ulaşan Yolov3, kalabalık kaynaklı veriler üzerinde test edildiğinde %78,2 mAP değerine ulaşmıştır.

- ❖ Yung vd. (2022), derin öğrenme tabanlı nesne tespit algoritmalarından Yolov5, Yolov6 ve Yolov7'yi kullanarak personel güvenliğinin sağlanması için kask tespiti yapmışlardır. Yolov5, Yolov6 ve Yolov7 için en yüksek mAP değerleri sırasıyla %83,7, %83,5 ve %89,6 bulunmuştur. Güvenlik kasklarının tespitinde en iyi performans Yolov7 ile elde edilmiştir.
- ❖ Alateeq vd. (2023), çalışmalarında işçi, baret, yelek ve ağır ekipman sınıfına ait nesneleri Yolov5 algoritması ile tespit etmişlerdir. İşçi, baret, yelek için %83 mAP, ağır ekipman sınıfı için %93 mAP değeri elde edilmiştir. Hız 141 FPS değerine ulaşmıştır.
- ❖ Farooq vd. (2023), kask ve kafa tespiti için Yolov5 (s, m, l, x) algoritmasını kullanmışlardır. Yolov5x %95,8 mAP değeri, %91,2 duyarlılık, %93,9 kesinlik ve %92,5 F1 puanı ile en başarılı sonuçlara ulaşırken Yolov5n ise görsellerde 62,5 FPS, videolarda 70,4 FPS ve gerçek zamanlı videolarda 65,3 FPS değeri ile en yüksek işlem hızına ulaşmıştır.

Yıllara göre en çok atıf alan makaleler incelendiğinde, çalışmaların daha çok inşaat alanında gerçekleştirildiği ve çalışmaların büyük çoğunluğunda Yolo algoritmasının farklı versiyonlarının kullanıldığı tespit edilmiştir. Elde edilen verilerin performans değerlendirme metrikleri ile değerlendirilmesi sonucunda yüksek doğruluk değerlerine ulaşıldığı dikkat çekmektedir.

KKE tespiti ile ilgili son yıllarda yapılan çalışmaların yer aldığı Scopus, IEEE Xplore ve ScienceDirect veri tabanlarındaki tarama sonucunda elde edilen Tablo 2.2. deki literatür özeti incelendiğinde ise; KKE tespitinin yine en çok inşaat ve sağlık alanlarında yapıldığı ve çalışmalarda Yolo algoritmasının diğer algoritmalarla oranla daha çok kullanıldığı dikkat çekmektedir. Yüksek doğruluk değerlerine ulaşabilmesi, gerçek zamanlı ve hızlı işlem gücüne sahip olması, bu algoritmanın tercih edilmesinde ön plana çıkmaktadır. Öte yandan gıda sektöründe KKE kullanımının tespitine yönelik bir çalışmaya rastlanmaması, bu alana yönelik çalışmalara ihtiyaç duyulduğunu belirtmektedir. Bu nedenle bu tez çalışması kapsamında, literatürdeki boşluğu doldurmak ve gıda sektöründe hijyen koşullarını sağlamak için görüntü işleme teknikleri ile KKE tespiti ele alınmıştır.

Tablo 2.2. KKE tespitinde görüntü işleme uygulamalarının kullanıldığı çalışmalara ait literatür özeti

| YAZAR                            | UYGULAMA ALANI | ÖRNEKLEM SAYISI | YÖNTEMLER                                  | SONUÇLAR                                                     |
|----------------------------------|----------------|-----------------|--------------------------------------------|--------------------------------------------------------------|
| <b>Tang vd. (2020)</b>           | İnşaat         | 4.565           | Faster R-CNN                               | Baret AP = %93,6<br>Güvenlik rengi AP = %82,8<br>mAP = %52,9 |
| <b>Casuat vd. (2020)</b>         | İnşaat         | —               | Yolov3                                     | mAP = %79,24<br>Doğruluk = %86,89                            |
| <b>Nath vd. (2020)</b>           | İnşaat         | 3.309           | VGG-16 ve PRID                             | Doğruluk, KKE = %90<br>Renk = %77                            |
| <b>Udatewar vd. (2021)</b>       | Sağlık         | 1.488           | MobileNet SSD, Yolov5                      | mAP = %40,9                                                  |
| <b>Khan vd. (2021)</b>           | Sağlık         | 1.500           | CNN (Adam, RMSprop optimizer)              | Doğruluk, RMSprop = %92,3<br>Adam = %85,1                    |
| <b>Wang vd. (2021)</b>           | İnşaat         | 1.330           | Yolov3, Yolov4, Yolov5 (s,m,l,x)           | Yolov5x<br>mAP = %86,55<br>Yolov5s FPS = 52                  |
| <b>Bhing ve Sebastian (2021)</b> | Sağlık         | 1.300           | Yolov5                                     | mAP = %84,5                                                  |
| <b>Ruparelia vd. (2021)</b>      | Sağlık         | 3.350           | Yolov5                                     | mAP = 92,49                                                  |
| <b>Cheng ve Lu (2022)</b>        | Elektrik       | 9.273           | Yolov5s                                    | En yüksek mAP = %90,9                                        |
| <b>Shah vd. (2022)</b>           | Sağlık         | 1.378 – 2.853   | MobileNetV2, DenseNet, Inceptionv3, Yolov4 | Doğruluk = %99,57                                            |
| <b>Durga vd. (2022)</b>          | Sağlık         | 3.860           | MobileNet V2                               | Doğruluk = %95,85                                            |
| <b>Zhang vd. (2022)</b>          | Sağlık         | 5.233           | MSPPE-Yolov4                               | Doğruluk = %84,14<br>F1 = %90,75                             |
| <b>Yung vd. (2022)</b>           | İnşaat         | 5.000           | Yolov5, Yolov6, Yolov7                     | mAP,<br>Yolov5 = %83,7<br>Yolov6 = %83,5<br>Yolov7 = %89,6   |

Tablo 2.2. (Devam)

| YAZAR                   | PROBLEM TANIMI | ÖRNEKLEM SAYISI | YÖNTEMLER                         | SONUÇLAR                                                                          |
|-------------------------|----------------|-----------------|-----------------------------------|-----------------------------------------------------------------------------------|
| Wu vd. (2022)           | Sağlık         | 5.000           | ME-YOLO                           | mAP = %97,2<br>FPS = 53                                                           |
| Reyes vd. (2022)        | İnşaat         | 300             | Yolov3                            | mAP = %92,99                                                                      |
| Başaran ve Çağıl (2022) | İnşaat, sağlık | 800             | Yolov4                            | Doğruluk = %96,<br>mAP = %98,9                                                    |
| Korkmaz ve Ağdaş (2023) | İnşaat         | 16.867          | Yolov8                            | mAP = %96,9                                                                       |
| Wang vd. (2023)         | İnşaat         | 2.371           | Geliştirilmiş YOLOX               | Baret = %90,33<br>İnsan = %87,03<br>Yelek = %82,12<br>mAP = %86,49<br>FPS = 22,13 |
| Ahmed vd. (2023)        | İnşaat         | 1.699           | Faster R-CNN, Yolov5              | Faster R-CNN<br>mAP = %96<br>Yolov5<br>mAP = %63,9                                |
| Nugraha ve Rifai (2023) | Makine         | 11.579          | Yolov4, Yolov5                    | mAP,<br>Yolov4 = %84, 4<br>Yolov5 = %88.6                                         |
| Azizan ve Zaini (2023)  | Sağlık         | 6.248           | MobileNetv2, Yolov3               | Maske<br>doğruluk = %81<br>Laboratuvar önlüğü<br>doğruluk = %92                   |
| Mathur ve Jain (2023)   | İnşaat         | 1.138           | Mask-RCNN (ResNet-101, ResNet-50) | ResNet-101<br>mAP = %73,01                                                        |
| Ji vd. (2023)           | İnşaat         | 10.000          | Yolov4 tabanlı RFA-Yolo           | Doğruluk = %93,1<br>FPS = 13                                                      |
| Lee vd. (2023)          | İnşaat         | 1.289           | YOLACT                            | Doğruluk = %91,3                                                                  |
| Thakur vd. (2023)       | İnşaat         | 700             | Yolov8s                           | mAP = %99,5                                                                       |

### 3. GIDA GÜVENLİĞİ VE HİJYEN

Sağlıklı beslenmenin en önemli kuralı temiz ve güvenli besinlerin tüketilmesidir. Bunun için gıdaların insan sağlığını etkilemeyecek ve çevre sorunları yaratmayacak ortamlarda besin değerlerini koruyarak elde edilmesi, işlenmesi ve saklanması gerekmektedir (Göral, 2021). Gıda güvenliği; gıda üretiminden başlayarak, gıda işleme, ambalajlama, depolama ve nakliye süreçlerini kapsamaktadır.

Sağlıklı yaşam için tüketilen, her türlü bozulma ve bulaşmaya sebep olan etkenden arındırılmış ve insan sağlığına zarar vermeyecek şekilde belirli standartlar çerçevesinde üretim, işleme, hazırlık ve dağıtım aşamalarından geçerek tüketime uygun hale getirilmiş gıdalar güvenilir gıdadır (Göral, 2021). Tüketicilerin sağlığının korunması için gıda güvenliği, gıda kaynaklı zehirlenmeler ve salgınlar nedeniyle tüm dünyada kontrol altına alınması gereken önemli bir sorun haline gelmiştir.

Gıda kaynaklı hastalıklar, özellikle bağışıklık sistemi zayıf insanların sağlığı açısından ciddi bir tehdit oluşturmaktadır. Dünyada her yıl, büyük çoğunluğunu çocukların oluşturduğu yaklaşık 600 milyon kişi gıda kaynaklı hastalık yaşamakta ve bunların 420.000'i hastalıklara yenik düşmektedir (WHO, 2022). Hastalık Kontrol ve Önleme Merkezine (Centers for Disease Control and Prevention - CDC) göre ise ABD'de her yıl yaklaşık 76 milyon gıda kaynaklı hastalık vakası meydana gelmekte ve bu kişilerden yaklaşık 325.000'i hastanelerde tedavi görmektedir (CDC, 2018). Bunun yanı sıra, gelişmiş ülkelerde her yıl nüfusun yaklaşık %30'unun gıda kaynaklı hastalıklara yakalandığı rapor edilmektedir (Göral, 2021). Dünya çapında ise tüm gıda kaynaklı hastalıkların yaklaşık %91'inin bakteriyel kontaminasyon kaynaklı gerçekleştiği tespit edilmiştir (Onbaşı ve Cinar, 2021). Bir yüzeyin veya maddenin bakterilerle temas etmesi veya enfekte olması durumunda meydana gelen bakteriyel kontaminasyonun nedenleri arasında insanlar, çevre (hava, su), hayvanlar, çiğ gıdalar ve tozlar bulunmaktadır.

Mikroorganizmaların gıdalara bulaşmasının en büyük nedeni insanlardır. İnsanların ellerinde, burunlarında, ağızlarında ve bağırsaklarında gıda zehirlenmesine sebep olan mikroorganizmalar barınmaktadır (Soyer, 2023). Gıdaların üretiminden tüketimine kadar geçen her aşamada gerekli özenin gösterilmesi ve hijyen standartlarına uygun hareket edilmesi gıda kaynaklı zehirlenme ve kontaminasyonun önüne geçilerek gıda güvenilirliğinin sağlanmasında önemli bir rol oynamaktadır.



Bu alanda, gıda kaynaklı hastalıkları azaltmak ve önlemek için gıda hazırlık ve pişirme aşamalarında hijyen standartlarına uygun hareket edilmeli, çalışanların gıda sektörüne uygun KKE kullanımına özen gösterilmeli ve süreklilik arz etmesi adına takibinin yapılması gerekmektedir. Ayrıca gıda ile doğrudan temas mümkün olduğunca önlenmeli ve bu konuda gerekli standartlar çerçevesinde denetimler yapılmalıdır. Gıda sektöründe önemli rol oynayan eldiven, bone/şapka, üniforma, önlük ve maske gibi personel KKE'leri gıda hijyeninin sağlanması için mutlaka kullanılmalıdır.

Güvenli gıda tüketebilmek için güvenli gıda üretimi sağlanmalıdır. Bunun için gıda güvenliği ve kalitesini artıracak yeni yaklaşımlar ve yöntemlerin uygulanması gerekmektedir. Bu yöntemler şunlardır:

- İyi tarım uygulamaları (Good Agricultural Practices - GAP), doğal kaynakların etkin bir şekilde kullanılarak tarım faaliyetlerinin sürdürülmesini sağlayan bir yaklaşımdır. Çevrenin korunması, işçi sağlığı ve güvenliğinin sağlanması ve gıda güvenliğini artırılmasını hedefleyen uluslararası kabul görmüş bir uygulamadır.
- İyi üretim uygulamaları (Good Manufacturing Practices - GMP), sağlık, gıda, kozmetik, tıbbi cihaz ve ilaç endüstrilerinde insan sağlığını doğrudan etkileyecek ürünlerin hijyenik koşullarda ve sağlıklı bir şekilde üretilmesi için kalite kontrolü sağlayan temel bir yaklaşımdır.
- İyi hijyen uygulamaları (Good Hygiene Practices - GHP), gıda güvenliğini sağlamak için gıda üretiminde ve gıda işletmelerinde uyulması gereken kuralları ve üretimden tüketime tüm süreçleri kapsayan, temizlik ve sanitasyon standartlarını, personel hijyenini, ekipman ve araç gereçlerin temizliğini ve gıdaların saklama koşullarını belirleyen hijyen standartlarıdır.
- Tehlike analizleri ve kritik kontrol noktaları (Hazard Analysis and Critical Control Points - HACCP), gıda güvenliği için gıda üretim sürecinde biyolojik, kimyasal ve fiziksel tehlikeleri tanımlayan ve bu tehlikeleri kontrol altına almak için kritik kontrol noktalarını belirleyen, değerlendiren ve kontrol eden bir sistemdir.

Tüm dünyada, gıda güvenliğinin sağlanması ve tüketicilerin korunması için çeşitli kuruluşlar aracılığıyla gerekli önlemler alınarak ve denetimler yapılarak sağlıklı gıdaya ulaşmak hedeflenmektedir.

Türkiye’de 13.06.2010 tarihli ve 27610 sayılı Resmî Gazetede yayınlanan “5996 Sayılı Veteriner Hizmetleri, Bitki Sağlığı, Gıda ve Yem Kanunu”nun amacı, Madde 1’de “*Gıda ve yem güvenilirliğini, halk sağlığı, bitki ve hayvan sağlığı ile hayvan ıslahı ve refahını, tüketici menfaatleri ile çevrenin korunması da dikkate alınarak korumak ve sağlamaktır*” şeklinde belirtilmiştir. Bu kanun, Tarım ve Orman Bakanlığı’nın kontrolünde gıda ve yeme ilişkin ürünlerin üretim aşamasından tüketiciye sunulmasına kadar geçen tüm süreci ve bu konulara ilişkin resmî kontrolleri ve yaptırımları kapsamaktadır (Resmî Gazete, 2010).

17.12.2011 tarihli ve 28145 sayılı Resmî Gazetede yayınlanan “Gıda Hijyeni Yönetmeliği”nin Personel Hijyeni başlıklı 17 (1) Maddesi’nde “*Gıdanın muameleye tabi tutulduğu alanlarda çalışan bütün personelin, kişisel temizliğini sürdürmeye azami itina göstermesi, temiz ve gerekli durumlarda uygun koruyucu kıyafet giymesi gerekir*” ifadesi bulunmaktadır (Mevzuat, 2011).

Bunun yanı sıra 2009 yılında “Güvenilir Gıda Sağlıklı Yaşam” kampanyası kapsamında 14 Şubat 2009 tarihinde “Alo174 Gıda Hattı” faaliyete geçirilmiştir. Tüketicinin gıda güvenirliliği ile ilgili her türlü ihbar ve şikâyetle ilgililere kolayca ulaşabilmesi, tüketiciye en kısa zamanda dönüş yapılabilmesi ve sonucun takibinin sağlanması hedeflenmiştir. 22.01.2024 tarihine kadar gerçekleştirilen 3.025.008 arama neticesinde gıda kapsamındaki 1.016.475 adedi kaydedilerek 1.010.632 adedi sonuçlandırılmıştır (Tarımorman, 2024).

Netice itibarıyla gıda güvenliğinin sağlanması için gıda sektöründe, malzeme tedarikinden başlayarak pişirme ve servisine kadar geçen bu süreçte, hijyen, kalite kontrolü ve müşteri memnuniyeti gibi faktörler önemlidir. Bu noktada tezde, gıdaların hazırlık ve pişirme aşamalarında hijyen ve temizlik kurallarına uyulmasını sağlamak ve güvenli gıda üretimini gerçekleştirmek adına personellerin kullanması gereken KKE takibi görüntü işleme yöntemleri ile ele alınmıştır.

## 4. GÖRÜNTÜ İŞLEME VE NESNE TESPİTİ

Bu kısımda görüntü işleme ve temel adımlarından, nesne tespiti ve kullanılan algoritmalarından ve performans değerlendirme metriklerinden bahsedilmiştir.

### 4.1. Görüntü İşleme

Görüntü işleme, çeşitli algoritmalar ve teknikler kullanarak dijital görüntülerden belirli amaçlara yönelik bilgi üreten ve elde ettiği bilgileri analiz eden bir teknolojidir. Fiziksel bir görüntünün dijital formata dönüştürülmesini ve ardından bu dijital görüntünün bilgisayar algoritmaları ve teknikleri kullanılarak işlenmesi sürecini ifade etmektedir. Bu işlem, görüntülerin kalitesini artırmak, özelliklerini çıkarmak, nesneleri tanımlamak veya belirli görevleri gerçekleştirmek amacıyla yapılmaktadır. Görüntü işlemede; geleneksel yöntemler (histogram eşitleme, kenar tespiti, öznitelik çıkarma, filtreleme, renk dönüşümleri) ve modern teknikler (derin öğrenme tabanlı) kullanılarak birçok işlem gerçekleştirilebilmektedir. Bu işlemler görüntülerin iyileştirilmesi, analizi, öznitelik çıkarma, renk dönüşümleri, filtreleme (Gaussian, Median, Mean Filtresi vb.), nesne tanıma, segmentasyon, işleme, değiştirme vb. uygulamalardır.

Geleneksel görüntü işleme yöntemleri, derin öğrenme tekniklerinden önce yaygın olarak kullanılan ve elde edilen özelliklerin belirli algoritmalar kullanılarak analiz edildiği yöntemlerdir. Geleneksel görüntü işleme algoritmalarının uygulanması için kullanılan bazı öznitelik çıkarma teknikleri şunlardır (Çilek, 2020):

- HOG (Histogram of Oriented Gradients): Bir görüntünün gradyan bilgisini kullanarak nesnelerin kenarlarını ve doku desenlerini tanımlayan bir özellik çıkarma tekniğidir.
- GLCM (Gray Level Co-Occurrence Matrix): Gri seviye görüntülerde pikseller arasındaki ilişkilerin analizi ve görüntünün dokusal özelliklerini tanımlamak için kullanılmaktadır.
- CCM (Color Co-Occurrence Matrix): Renkli görüntülerde pikseller arasındaki renk ilişkilerinin analizinde kullanılmakta ve görüntünün renk dokusunu temsil etmektedir.
- PCA (Principal Components Analysis): Temel Bileşen Analizi, yüksek boyutlu bir veri setinin boyutunu azaltmak ve değişkenlik miktarını en iyi şekilde korumak için kullanılarak önemli özelliklerin belirlenmesine yardım etmektedir.


- SIFT (Scale Invariant Feature Transform): Bir görüntüdeki belirgin noktaları (benzersiz ve tekrar edilebilir desenler) tespit eden bir algoritmadır. SIFT, bu noktaların tespitinde Gauss filtrelerini kullanmaktadır.
- SURF (Speeded-Up Robust Features): SIFT algoritmasının hızlandırılmış şeklidir. SURF, bu noktaların tespitinde Hessian determinant kullanmaktadır.

Derin öğrenme tabanlı görüntü işleme yöntemleri, görüntü verilerini işlemek ve belirli görevleri gerçekleştirmek için derin öğrenme mimarilerini kullanmaktadır. Bu mimarilerden bazıları aşağıda belirtilmiştir:

- Evrişimli Sinir Ağları (Convolutional Neural Networks - CNNs): Görüntü verilerini işlemek için tasarlanmış CNN'ler, görüntülerin özelliklerini çıkararak nesne tanıma, nesne tespiti, görüntü sınıflandırma ve diğer birçok görevde başarıyla kullanılmaktadır. Özellikle, ImageNet gibi büyük veri setleri üzerinde eğitilmiş derin CNN modelleri, görüntü işleme görevlerinde etkilidir.
- Üretken Çekişmeli Ağlar (Generative Adversarial Networks - GANs): Gerçekçi görüntüler oluşturmak için kullanılan ve bir üretici ile bir ayırt edici ağdan oluşan bu yapıda, üretici ağ yeni veriler üretirken ayırt edici ağ sahte ve gerçek verilerin belirlenmesine yardım etmektedir. GAN'lar, görüntü sentezi, görüntü iyileştirme ve veri artırma gibi alanlarda kullanılmaktadır.
- Siyam Ağları (Siamese Networks): Benzerlik ölçümü veya çiftler arasındaki ilişkileri belirleme gibi görevler için özellikle, yüz tanıma, nesne takibi ve görüntü eşleştirme gibi alanlarda kullanılmaktadır.
- Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNNs): Zaman serileri gibi ardışık veriler ile görüntü dizilerini veya zamanla değişen görüntüleri işlemek için kullanılmaktadır. Özellikle, video analizi ve hareket tahmini gibi görevlerde tercih edilmektedir.
- Dönüştürücü Ağları (Transformer Networks): Başlangıçta dil işleme görevleri için tasarlanmıştır fakat görüntü işleme alanında da kullanılabilir. Görüntü sınıflandırma, nesne tanıma ve görüntü segmentasyonu gibi görevlerde etkilidirler.

Teknolojinin gelişmesiyle kullanımı artan derin öğrenme tabanlı yöntemler ile başarı oranları yüksek sonuçlar elde edilebilmektedir.

Görüntü işlemedeki temel adımlar Çilek (2020)'den revize edildiği haliyle Şekil 4.1. de belirtilmiştir.



Şekil 4.1. Görüntü işleme adımları

- Görüntü alma: Görüntü işleme sürecinin ilk adımıdır ve çeşitli kaynaklardan optik veya elektronik cihazlar aracılığıyla elde edilen görüntüleri ifade etmektedir.
- Ön işleme: Elde edilen görüntülerin kalitesini artırmak ve işleme uygun hale getirmek için uygulanan adımlardır. Gürültü azaltma, kontrast ayarlama, boyutlandırma ve normalizasyon, kenar tespiti veya iyileştirme, renk uzayı dönüşümleri ön işleme adımları arasında bulunmaktadır. Bu adımlar görüntüdeki istenmeyen bileşenleri azaltarak sonraki işlem adımlarının daha etkin olmasını ve önemli bilgilerin korunmasını sağlamaktadır.
- Segmentasyon: Bir görüntüdeki belirli nesneleri ve bölgeleri tanımlamak için kullanılmaktadır. Segmentasyon genellikle eşikleme, bölütleme, kenar tespiti ve bölgesel büyütme gibi yöntemlerle gerçekleştirilir. Bu yöntemler, elde edilen bilgilerin daha anlamlı ve işlenebilir hale getirilmesini sağlamaktadır.
- Özellik çıkarma: Görüntüde bulunan nesnelerin, desenlerin veya diğer önemli bilgilerin tanımlanmasını sağlamaktadır. Kenar belirleme, köşe veya nokta belirleme, renk özellikleri, yapısal özellikler ve histogramlar gibi adımları içerebilir. Verilerden anlamlı bilgiler çıkarılmasına yardım etmektedir.
- Nesne tanıma ve sınıflandırma: Bir görüntüdeki nesneleri belirlemek ve tanımak için görüntüye çeşitli algoritmaların uygulanmasıdır.

- Görüntü yorumlama ve uygulama: Elde edilen sonuçların anlamlı hale getirildiği, analiz edilerek bilgiye dönüştürüldüğü ve çeşitli uygulamalarda kullanıldığı aşamadır.
- Saklama: Elde edilen görüntü ve analiz sonuçlarının ileride başvurmak veya kullanmak üzere kaydedilmesidir.


Görüntü işleme ve derin öğrenme tabanlı algoritmalar kullanılarak yapılan nesne tanıma ve tespiti, görüntü sınıflandırma ve segmentasyon gibi işlemler gün geçtikçe artan geniş uygulama alanlarına sahiptir.

#### **4.2. Nesne Tespiti**

Nesne tespiti, bir görüntüdeki nesnelerin ve konumlarının tespitinde kullanılan bir yapay zekâ teknolojisidir. Nesne tespiti, otonom sürüş teknolojilerinde araçların çevrelerindeki araç, yaya, trafik işareti vb. algılayarak güvenli bir şekilde hareket etmesinde, endüstriyel sistemlerin izlenmesinde ve envanter yönetiminde, kamu alanlarında, mağazalarda, binalarda vb. birçok yerde hırsızlık tespiti, yasa ihlallerinin takibi, kayıp kişilerin bulunması gibi güvenlik denetimlerinde ve tehlikeli durumların önlenmesinde, tarım endüstrisinde tarlada otomatik bitki sulama veya ilaçlama gibi görevlerde, sağlık alanında tedavide, üretim hatlarında robotların montaj işlemlerini gerçekleştirmesinde ve kalite kontrol işlemlerinde vb. birçok alanda KKE tespitinde kullanılmaktadır.

Nesne tespiti uygulamaları ile çalışanların güvenliğini ve sağlığını korumak veya gıda kontaminasyonunu önleyerek gıda hijyenini sağlamak için uygun ve doğru şekilde KKE kullanımının teşvik edilmesi sağlanabilmektedir. Bu teknoloji, istenmeyen durumlar için kameralar, sensörler veya özel yazılımlar kullanılarak uyarılarda bulunan sistemlerin geliştirilmesinde etkin bir role sahiptir. Böylece gıda güvenliğinin korunması, iş sağlığı ve güvenliği (İSG) standartlarına uyum ve iş kazalarının önlenmesine katkı sağlayabilmektedir.

Nesne tespitinde çoğunlukla derin öğrenme tabanlı Evrişimli Sinir Ağı (Convolutional Neural Network - CNN) algoritmaları kullanılmaktadır. CNN, görüntü tanıma ve işleme için geliştirilen bir derin öğrenme ağ çeşididir. CNN tabanlı nesne tespit algoritmaları tek aşamalı ve iki aşamalı modellerden meydana gelmektedir. Şekil 4.2. de nesne tespit ve takibinde kullanılan CNN tabanlı algoritmaların sınıflandırması Kundu (2023)'ten revize edildiği haliyle görülmektedir.



Şekil 4.2. Tek aşamalı ve iki aşamalı nesne tespiti algoritmaları

Tek aşamalı nesne tespit algoritmaları, görüntülerdeki nesnelerin varlığı ve konumu hakkında tahminlerde bulunmak için tüm görüntüyü tek seferde işleyerek nesne tanıma işlemini gerçekleştirir. Bu tür algoritmalar, nesneleri gerçek zamanlı ve hızlı bir şekilde tespit etmek için kullanılmaktadır.

İki aşamalı nesne tespit algoritmalarında ise, nesneleri tespit etmek için ilk aşamada, görüntüde nesne bulunan bölgeler belirlenerek potansiyel nesne bölgesi önerilerinde bulunulur. İkinci aşamada, her bir bölge önerisi bir nesne tespiti modeline veya sınıflandırıcıya iletilir. Bu şekilde nesnenin konumu ve sınıfı tespit edilebilir. İki aşamalı algoritmalar, özellikle karmaşık ve özelleştirilmiş nesnelerin tespiti ve sınıflandırma görevlerinde kullanılmaktadır (Temür, 2024).

Nesne tespit algoritmaları aşağıdaki gibi özetlenebilir.

- R-CNN: Nesne tespiti için CNN kullanılan bölge tabanlı bir derin öğrenme modelidir. Görüntülerdeki objelere ait sınıfları ve bu objelere ait sınırlayıcı kutuları (bounding box) tespit etmek için kullanılan R-CNN, 2014 yılında Ross Girshick vd. tarafından önerilmiştir. R-CNN’de, görüntü yaklaşık 2000 bölge teklifine bölünerek her bölgeye sırasıyla CNN uygulanmaktadır. Bölgelerin boyutu belirlenerek ve yapay sinir ağına, doğru bölge yerleştirilerek nesneler tanımlanmaktadır. Her bölge için ayrı bir CNN uyguladığından, eğitim süresi yaklaşık 84 saat ve tahmin süresi yaklaşık 47 saniyedir. R-CNN algoritmasının olumsuz yönleri; eğitim süresinin çok zaman alması, maliyetinin yüksek olması ve çok fazla disk alanı gerektirmesidir (Saraç, 2020).

- Fast R-CNN: Nesne tespiti için CNN kullanılan bölge tabanlı bir derin öğrenme modeli olan Fast R-CNN, bölgelerden öznitelikleri çıkaran, bunları farklı sınıflara ayıran ve tanımlanan sınıflar için sınır kutularını tahmin eden tek bir model kullanmaktadır. Bu model, her bölge için sınıflandırma ve sınır kutusu regresyonunu aynı anda gerçekleştirmektedir. Fast R-CNN mimarisinin eğitim süresi yaklaşık 8,75 saat ve tahmin süresi yaklaşık 2,3 saniyedir. R-CNN'e kıyasla bölge önerilerini daha verimli işlediği için daha hızlı çalışabilen bir yapıya ve daha iyi bir mAP değerine sahiptir. R-CNN'e göre hızlıdır fakat bölgeleri bulmak için kullanılan seçici arama (selective search) Faster R-CNN'e göre zaman alıcıdır (Meşeci, 2021).
- Faster R-CNN: Nesne tespiti için CNN kullanılan ve bölge tekliflerini seçici arama yerine ayrı bir bölge öneri ağı (Region Proposal Network - RPN) kullanarak daha verimli bir şekilde üreten derin öğrenme modelidir. Faster R-CNN algoritmasının eğitim süresi yaklaşık 8,75 saat ve tahmin süresi yaklaşık 0,3 saniyedir. Faster R-CNN'e kıyasla tahmin süresinin daha da iyileştirilmesi ve RPN kullanılarak maliyetin azaltılması sağlanmıştır (Özkan, 2022).
- Mask R-CNN: Nesne tespitini ve piksel bazında nesne ana hatlarını tanımlayan örnek segmentasyon (instance segmentation) sağlayan derin öğrenme modelidir. İlk aşamada görüntüler taranarak bölge önerileri, ikinci aşamada ise öneriler sınıflandırılarak sınırlayıcı kutular ve maskeler oluşturulmaktadır. Görüntü ve videodaki farklı nesneleri ayırt etmede kullanılmaktadır (Saraç, 2020).
- YOLO (You Only Look Once): Nesne tespiti için kullanılan görüntüyü tek bir geçişte analiz ederek nesneleri tespit eden ve sınıflandıran, gerçek zamanlı uygulamalarda etkili performans sağlayan bir derin öğrenme modelidir.
- SSD (Single Shot Multibox Detector): Nesne tespitinde görüntüyü tek seferde işleyen ve farklı ölçeklerdeki nesneleri tespit etmek için çoklu ölçekli özellik haritalarını kullanan bir derin öğrenme modelidir.

Nesne tespiti için kullanılan R-CNN, Fast R-CNN, Faster R-CNN, Mask R-CNN vb. modeller, ilk Yolo algoritması 2015 yılında piyasaya sunulana kadar yaygın bir şekilde kullanılmış uygulamalardır. Diğer modellerle kıyaslandığında gerçek zamanlı nesne tespitinde çok hızlı işlem yapabilmesi ve başarılı sonuçlara ulaşabilmesi Yolo'nun en önemli özelliğini yansıtmaktadır.




Tez çalışması kapsamında; Yolo algoritmalarından Yolov5, Yolov8 ve Yolov9 kullanılarak KKE tespiti en başarılı algoritmanın seçilmesi ve gerçek zamanlı uygulamalarda kullanılmak üzere bir temel teşkil etmesi hedeflenmektedir.

#### 4.3. Görüntü İşleme ve Nesne Tespitinde Kullanılan Bazı Parametreler

Görüntü işleme ve nesne tespitinde verilerin eğitiminde ve eğitimden elde edilen sonuçların yorumlanmasında kullanılan bazı parametreler aşağıda anlatılmıştır.


- Bağlantı Kutuları (Anchor Boxes): Belirli yükseklik ve genişlik değerlerine sahip önceden tanımlanmış kutulardır (Can, 2022). Farklı boyut ve şekillerdeki nesneleri yakalayabilmek için algoritmanın algılamaya çalıştığı nesnelerin boyutlarına ve en boy oranlarına göre seçilmektedirler (Şekil 4.3.).



Şekil 4.3. Bağlantı kutuları


- Yığın sayısı (Batch Size): Modelin eğitimi sırasında aynı anda kaç adet verinin işleneceği anlamına gelen batch size 2'nin katları (2, 4, 8, 16, 32, 64 vb.) şeklinde seçilmektedir (Şekil 4.4.). Ağırlıklar her yığın sayısından sonra güncellendiği için yığın boyutu küçük seçildiğinde model ağırlıkları daha çok güncellenecek ve bu durum sınıfın genelleme eğilimini iyileştirecektir. Yığın boyutu büyük ise istikrarlı ağırlık güncellemelerinin gerçekleşmesi sağlanacak ve eğitim hızlanacaktır (Brownlee, 2022).
- İterasyon (yineleme): Her yığın sayısından sonra ağırlıklar güncellendiğinde gerçekleşen yineleme sayısıdır (Şekil 4.4.).
- Epoch sayısı: Kullanılan algoritmanın, tüm eğitim veri kümesi üzerinde yaptığı geçiş sayısı demektir (Şekil 4.4.). Elde edilen eğitim verilerine göre ağ parametreleri güncellenmektedir. Nesne tespit modelinin performansını optimize etmek için ayarlanabilen bir hiperparametredir (Brownlee, 2022).

Total Data = 2.500



Şekil 4.4. Batch ve Epoch sayısı

- F1 Puan Eğrisi (F1-curve): Bu grafik, kesinlik ve duyarlılık değerlerinin harmonik ortalamasını alan F1 puanını temsil etmektedir.
- Duyarlılık Eğrisi (R-curve): Bu grafik, geri çağırma değerlerinin farklı eşik değerlerinde nasıl değiştiğini göstermektedir.
- Kesinlik Eğrisi (P-curve): Bu grafik, eşik değeri değiştikçe hassasiyetteki değişimi anlatmaktadır.
- Maksimum Olmayan Bastırma (Non Max Suppression - NMS): Yinelenen algılamaları ortadan kaldırmak ve algılanan nesnelere karşılık gelen en ilgili sınırlayıcı kutuları seçmek için nesne algılamada kullanılan bir tekniktir.
- Görüntüler (images): Nesne sınıflarına ait görüntülerin sayısını belirtmektedir.
- Örnekler (instances): Bu metrik, sınıfların doğrulama veri setindeki tüm görüntülerde kaç kez görüntülendiğinin sayısını belirtmektedir.
- Sınırlayıcı kutu (Bounding Box): Nesnelerin sınırlarını belirlemek için etrafını çevreleyen sınırlayıcı kutular nesnenin merkez koordinatları (x, y), genişlik, yükseklik ve güven skoru ile tanımlanmaktadır (Şekil 4.5.).



Şekil 4.5. Sınırlayıcı kutular (Freepik)


#### 4.4. Yolo Algoritması

Yolo algoritması adını “You Only Look Once” kelimelerinin baş harflerinden almaktadır. Türkçesi “Sadece Bir Kez Bak” anlamına gelen Yolo, CNN tabanlı ve gerçek zamanlı bir nesne tespit algoritmasıdır. Gerçek zamanlı sonuçlara ihtiyaç duyulduğunda ve canlı bir video akışını analiz etmek gerektiğinde tercih edilen bu algoritma “açık kaynak” kullanıcıları tarafından aktif katkıda bulunulması ile ön plana çıkmaktadır. Yolo algoritması çalışma mantığı aşağıda sıralanmıştır.

- Algoritma, görseli  $S \times S$  boyutlarında hücrelere (3x3, 5x5, 19x19 vb.) ayırır ve her hücre için sınırlayıcı kutu ve sınıf olasılıklarını tahmin eder.
- Sınırlayıcı kutuların güven skoru ve sınıf olasılıkları çarpımıyla nesneler tahmin edilir. Güven skoru belirli bir eşik değerinin üzerindeki sınırlayıcı kutular kalır.
- Aynı nesneye ait çakışan sınırlayıcı kutulara NMS uygulanır ve en yüksek güven skoruna sahip, en uygun sınırlayıcı kutu ile algılanan nesne işaretlenir.

Yolo algoritması baş (head), boyun (neck) ve omurga (backbone) olmak üzere üç temel kısımdan oluşmaktadır. Backbone, görüntü üzerinde özellik çıkarımı yaparak önemli öznitelikleri belirlemektedir. Backbone ve head arasında bulunan neck, backbone katmanından gelen özellik haritalarını işleyerek nesne tespitine daha uygun bir formata getirmektedir. Sınırlayıcı kutuların bulunduğu head nesnenin konumunu ve sınıfını tahmin etmek için kullanılmaktadır. Çerçeve (framework) ise nesne tespitinde modelin geliştirilmesi, eğitimi ve uygulanması için kullanılan araçlar ve yapılarıdır. Başarılı sonuçlara ulaşan ve geniş bir kullanım alanı bulunan Yolo algoritması seçilerek Web of Science veri tabanında tarama yapılmıştır. Tarama sonucunda elde edilen verilerden, Yolo algoritması ile en çok kullanılan anahtar kelimeler seçilerek Vosviewer uygulamasında Şekil 4.6. da yer alan bibliyometrik ağ görselleştirmesi hazırlanmıştır.

Yolo algoritmasına ait analiz sonuçları incelendiğinde yapay zekâ, makine öğrenmesi, derin öğrenme, CNN, görüntü işleme, nesne tespiti, maske tespiti ve insan tespitinin ön plana çıktığı görülmektedir.



Şekil 4.6. Yolo algoritmasına ait bibliyometrik ağ görselleştirmesi

Tablo 4.1. Yolo algoritması versiyonları

| Versiyon   | Geliştiren                   | Tarih | Çerçeve (Framework) | Omurga (Backbone)   |
|------------|------------------------------|-------|---------------------|---------------------|
| YOLOv1     | Joseph Redmon vd.            | 2015  | Darknet             | Darknet-24          |
| YOLOv2     | Joseph Redmon vd.            | 2016  | Darknet             | Darknet-19          |
| YOLOv3     | Joseph Redmon ve Ali Farhadi | 2018  | Darknet             | Darknet-53          |
| YOLOv4     | Alexey Bochkovskiy vd.       | 2020  | Darknet             | CSPDarknet-53       |
| YOLOv5     | Glenn Jocher                 | 2020  | PyTorch             | CSPDarknet-53       |
| YOLOR      | Chien-Yao Wang vd.           | 2021  | PyTorch             | CSPdarknet          |
| YOLOX      | Zheng Ge vd.                 | 2021  | PyTorch             | Modified CSP v5     |
| YOLOv6     | Chuyi Li vd.                 | 2022  | PyTorch             | EfficientRep        |
| YOLOv7     | Chien-Yao Wang vd.           | 2022  | PyTorch             | RepConvN            |
| YOLOv8     | Ultralytics                  | 2023  | PyTorch             | CSPDarknet-53 + C2f |
| YOLO-NAS   | Deci AI                      | 2023  | PyTorch             | RepVGG              |
| YOLO-WORLD | Tencent's AI research lab.   | 2024  | PyTorch             | Yolo-v8             |
| YOLOv9     | Chien-Yao Wang vd.           | 2024  | PyTorch             | Gelan               |

Yolo ailesi içerisinde yer alan birçok Yolo versiyonu bulunmaktadır. Bu versiyonlara ait bilgiler Ragab vd., (2024)'ten revize edildiği haliyle Tablo 4.1. de belirtilmiştir. Tez çalışması için bu versiyonlardan Yolov5, Yolov8 ve Yolov9 seçilerek gıda alanında kullanılan KKE'ler tespit edilmiştir. Yolov5 algoritmasının tercih edilme nedeni çok hızlı ve kullanımı kolay bir PyTorch modeli olması ve geniş bir kullanıcı topluluğuna sahip bu modelin sürekli güncellenerek geliştirilmesidir. Son versiyonlardan Yolov8 (2023) ve Yolov9 (2024) algoritmalarının tercih edilmesinde ise yüksek mAP ve doğruluk değerlerine ulaşabilmesi aynı zamanda yeni yayınlanmaları etkilidir.

#### **4.4.1. Yolov5 Algoritması**

Yolov5 algoritması 2020 yılında Glenn Jocher tarafından geliştirilmiş fakat bu çalışmayla ilgili bir makale yayınlanmamıştır. Yolov5, önceki versiyonlardan farklı olarak Python tabanlı PyTorch kütüphanesini kullanmaktadır. Yolov5 modelinin backbone katmanında CSP-Darnet53, neck katmanında SPPF ve CSP-PANet, head katmanında ise YOLOv3 mimarileri kullanılmaktadır. YOLOv5 algoritmasının beş ana versiyonu bulunmaktadır. Bunlar; nano (n), küçük (s), orta (m), büyük (l) ve ekstra büyük (x)'tür. Versiyonlardan n, s ve m daha hızlı bir eğitim için kullanılırken l ve x daha yüksek doğruluk ve ayrıntı gerektiren uygulamalarda tercih edilmektedir. Model boyutu büyüdükçe eğitim süresi artmaktadır (Büyükburgaz, 2024).

#### **4.4.2. Yolov8 Algoritması**

Ultralytics tarafından 2023 yılı Ocak ayında geliştirilen Yolov8 algoritması, önceki Yolo sürümlerinin başarısını temel alarak performansı ve esnekliği daha da artırmak için yeni özellikler ve iyileştirmeler sunan bir modeldir. Yolov8'in Yolov8n, Yolov8s, Yolov8m, Yolov8l ve Yolov8x şeklinde 5 versiyonu bulunmaktadır. Yolov8n en küçüğü ve en hızlısı, Yolov8x ise daha yavaş fakat daha yüksek doğrulukta çalışan versiyonudur (Büyükburgaz, 2024).

Daha hızlı ve daha doğru bir nesne algılamının sağlanması için Yolov8 ağ mimarisinde önemli iyileştirmeler uygulanmış ve performansı optimize etmek için modüllerde değişiklikler yapılmıştır. Yolov8'de, sınırlayıcı kutuları otomatik tahmin eden çapasız algılama doğruluk ve hassasiyetin artmasını sağlamıştır. Nesne tespitinde birden fazla görüntüyü tek bir görüntüde birleştiren mozaik büyütme tekniği, eğitim

bitmeden durdurularak aşırı uyum önlenmiş ve yüksek doğruluğa ulaşılmıştır. Head'in tasarımındaki değişim, hesaplama karmaşıklığını azaltırken hızlı tespit sağlamıştır.

Bu gelişmeler, gerçek zamanlı nesne algılamada performansı, doğruluğu ve verimliliği artırarak büyük veri kümelerinin işlemesine imkân tanımaktadır.

#### **4.4.3. Yolov9 Algoritması**

2024 yılı Şubat ayında Chien-Yao Wang vd. tarafından geliştirilen Yolov9 algoritması, Programlanabilir Gradyan Bilgisi (Programmable Gradient Information - PGI) ve Genelleştirilmiş Etkin Katman Birleştirme Ağı (Generalized Efficient Layer Aggregation Network - GELAN) mimarilerini içermektedir (Büyükburgaz, 2024).

PGI, bilgi darboğazı sorunuyla mücadele etmek için geliştirilmiş bir kavramdır. Derin ağ katmanlarında temel verilerin korunmasını sağlamaktadır. Bu şekilde güvenilir gradyanların oluşturulmasını sağlamakta, doğru model güncellemelerini kolaylaştırmakta ve genel algılama performansını iyileştirmektedir (Ultralytics, 2024).

GELAN, parametrelerin etkin bir şekilde kullanımını sağlayarak hesaplama karmaşıklığının önlenmesi, doğruluğun ve çıkarım hızının optimize edilmesi için tasarlanmış bir mimaridir. Çeşitli hesaplama bloklarının esnek entegrasyonuna izin veren tasarımı Yolov9'a hız ve doğruluğun yanı sıra geniş bir uygulama alanı sağlamaktadır (Ultralytics, 2024).

Yolov9 algoritmasının Yolov9t, Yolov9s, Yolov9m, Yolov9c ve Yolov9e şeklinde beş versiyonu bulunmaktadır. Yolov9c ve Yolov9e en yüksek doğruluğa ulaşan versiyonlardır.

#### **4.5. Performans Değerlendirme Metrikleri**

Görüntü işleme teknolojisi kullanılarak nesne tespiti yapılan çalışmalarda model eğitim ve test aşamalarından geçtikten sonra elde edilen sonuçlar, model performansını değerlendirmek için kullanılmaktadır. Performans değerlendirmede kullanılan metrikler; karışıklık matrisi (confusion matrix), doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1 puanı, ortalama kesinlik (Average Precision - AP), genel ortalama kesinlik değeri (Mean Average Precision - mAP)'dir (Thakur, 2023).

- Karışıklık matrisi (Confussion matrix): Bir sınıflandırma probleminde gerçekleşen ve tahmin edilen değerleri göstermektedir. Her bir sınıf için gerçek

ve yanlış pozitif ve negatif etiket sayısını görüntüleyerek modelin etkinliğini özetleyen ve modelin değerlendirilmesi için kullanılan bir tablodur (Tablo 4.2.).

Tablo 4.2. Karışıklık matrisi

|                                 | Tahmin edilen (Predicted)<br>Pozitif    | Tahmin edilen (Predicted)<br>Negatif    |
|---------------------------------|-----------------------------------------|-----------------------------------------|
| Gerçekleşen (Actual)<br>Pozitif | Gerçek Pozitif<br>(True Positive - TP)  | Yanlış Negatif<br>(False Negative - FN) |
| Gerçekleşen (Actual)<br>Negatif | Yanlış Pozitif<br>(False Positive - FP) | Gerçek negatif<br>(True Negative - TN)  |

- Doğruluk (Accuracy): Modelde doğru tahmin edilen alanların tüm tahminlere oranı ile hesaplanmaktadır.

$$\text{Doğruluk} = (TP + TN) / (TP + FP + TN + FN) \quad (4.1)$$

- Kesinlik (Precision): Modelin pozitif algıladığı tahminlerin, gerçekte ne kadarının doğru tahmin edildiğini belirler.

$$\text{Kesinlik} = TP / (TP + FP) \quad (4.2)$$

- Duyarlılık (Recall): Tüm gerçek nesneler arasında pozitif olarak tahmin edilmesi gereken işlemlerin ne kadarının pozitif tahmin edildiğini belirler.

$$\text{Duyarlılık} = TP / (TP + FN) \quad (4.3)$$

- F1 puanı (F1 score) : Kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır ve 0 ile 1 arasında değerler alır.

$$\text{F1 puanı} = 2 * ((\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})) \quad (4.4)$$

- Ortalama Kesinlik (Average Precision - AP): Modelin kesinlik ve duyarlılık grafiğinde bulunan alan hesaplanarak AP değeri elde edilir.

- Genel Ortalama Kesinlik Değeri (Mean Average Precision - mAP): Nesne tespitinde kullanılan yaygın bir değerlendirme kriteridir ve her sınıf için ortalama hassasiyeti hesaplayarak tüm sınıflardaki sonuçların ortalamasını alır. Bu metrik değerlerinin 1'e yaklaşması daha başarılı sonuçlar elde edildiği anlamını taşımaktadır. Daha yüksek bir mAP daha iyi performans anlamına gelmektedir.

$$\text{Genel Ortalama Kesinlik} = \sum AP / \text{Sınıf Sayısı} \quad (4.5)$$



Model deęerlendirmesinde elde edilen bu sonulardan yararlanarak en yksek doęruluk oranı ve bařarıya ulařan model seilmektedir.

Tablo 4.3. te YOLOv5, YOLOv8 ve YOLOv9 algoritmalarına ait versiyonların 640\*640 boyutlarında COCO veri seti zerindeki performans karřılařtırmaları bulunmaktadır (Jocher, 2022). COCO veri seti, nesne algılama (YOLO, Faster R-CNN ve SSD vb.), rnek segmentasyonu (Mask R-CNN vb.) ve anahtar nokta algılama (OpenPose vb.) alanlarında derin ęrenme modellerini eęitmek ve deęerlendirmek iin kullanılan hazır bir veri setidir (Ultralytics, 2023). Algoritmaların COCO veri setinden elde edilen mAP50-95 deęerleri, farklı tespit zorluęu seviyelerindeki performanslarını ifade etmektedir.

Tablo 4.3. YOLOv5, YOLOv8 ve YOLOv9 algoritmalarının COCO veri setindeki performans karřılařtırması

| <b>Model</b>   | <b>mAP50-95 (%)</b> | <b>Model</b>   | <b>mAP50-95 (%)</b> | <b>Model</b>   | <b>mAP50-95 (%)</b> |
|----------------|---------------------|----------------|---------------------|----------------|---------------------|
| <b>YOLOv5n</b> | 28                  | <b>YOLOv8n</b> | 37,3                | <b>YOLOv9t</b> | 38,3                |
| <b>YOLOv5s</b> | 37,4                | <b>YOLOv8s</b> | 44,9                | <b>YOLOv9s</b> | 46,8                |
| <b>YOLOv5m</b> | 45,4                | <b>YOLOv8m</b> | 50,2                | <b>YOLOv9m</b> | 51,4                |
| <b>YOLOv5l</b> | 49                  | <b>YOLOv8l</b> | 52,9                | <b>YOLOv9c</b> | 53                  |
| <b>YOLOv5x</b> | 50,7                | <b>YOLOv8x</b> | 53,9                | <b>YOLOv9e</b> | 55,6                |


Performans deęerlendirme metriklerinden mAP50-95 deęerinden elde edilen sonular karřılařtırıldığında en yksek bařarı oranının YOLOv9 algoritmasından elde edildięi anlařılmaktadır. Dięer algoritmaların zmleyemedięi bilgi darboęazı sorununa zm getiren aynı zamanda PGI ve GELAN mimarilerini kullanarak doęruluk ve verimlilięi de artıran YOLOv9 algoritması, YOLOv5 ve YOLOv8'in de kullandığı PyTorch erevesini kullanarak PyTorch'taki arařtırma topluluęu sayesinde geliřtirilmekte ve iyileřtirilmektedir. YOLOv9 algoritması bařlangıcından bu yana tm bu geliřtirme ve iyileřtirmelerin sonucunda bařarılı bir nesne tespit algoritması haline gelmiřtir.

## 5. UYGULAMA

Bu bölümde KKE tespitinde uygulanan görüntü işleme metodolojisinden, eğitim için hazırlanan veri seti ve özelliklerinden, uygulamada kullanılan program ve yöntemlerden, KKE tespiti ile elde edilen sonuçların analizinden bahsedilmiştir.

### 5.1. Kişisel Koruyucu Ekipman Tespitinde Görüntü İşleme Metodolojisi

Görüntü işleme, dijital görüntülerden algoritmalar kullanılarak belirli amaçlar doğrultusunda yararlı bilgilerin elde edilmesi işlemidir. KKE tespitinde görüntü işlemeden yararlanmak ve yüksek doğrulukta sonuçlara ulaşabilmek için aydınlatma koşulları, kamera mesafesi ve çözünürlüğe bağlı çok sayıda kaliteli görüntüye ihtiyaç duyulmaktadır. Şekil 5.1. de KKE tespitinde takip edilen görüntü işleme metodolojisi belirtilmiştir.



Şekil 5.1. KKE tespiti görüntü işleme metodolojisi

- Görüntü işlemede ilk aşama, görüntülerin elde edilmesidir. Görüntü, gözlerle algılanan ve zihinsel olarak oluşturulan şeylerin görsel temsidir. Görüntüler kameralar veya sensörler aracılığıyla elde edilmektedir. Çalışmada kullanılan görüntüler stok resim sitesi Freepik ve Google görsellerden restoran şefleri ile ilgili yapılan aramalar sonucunda temin edilmiştir.
- Veri setinde bulunan görüntüler etiketleme ve gerekli ön işlemlerden geçirilerek eğitime hazır hale getirilmektedir. Etiketleme işlemi için Labellmage, Makesense.ai ve Roboflow gibi programlar kullanılmaktadır. Çalışmada, veri setinin etiketleme işlemleri Roboflow ile yapılmıştır. Etiketleme işleminden sonra eğitim, doğrulama ve test için ayrılan veri seti 640\*640 boyutlarına getirilerek yeniden boyutlandırılmıştır. Ön işleme adımları içerisinde boyutlandırmanın yanı sıra veri çoğaltma işlemleri de yer almaktadır. Veri çoğaltma yöntemleri gri tonlama, bulanıklaştırma, gürültü ekleme, kırpma, çevirme, döndürme, parlaklık vb. işlemlerdir. Çalışmanın birinci versiyonunda veri çoğaltma işlemi uygulanmamış, ikinci versiyonunda ise sadece gri tonlama kullanılarak veri sayısı arttığında başarı oranındaki değişimler gözlemlenmiştir.
- Veri seti etiketlendikten sonra Yolo formatına uygun hale getirilmiştir. Görseller ile Yolo algoritmasının kullandığı .txt formatındaki etiketlerin bulunduğu eğitim, doğrulama ve test veri klasörleri hazırlanmıştır. Çalışmada Yolov5, Yolov8 ve Yolov9 algoritmaları kullanılmıştır.
- Görüntü işleme uygulamaları, yüksek Grafik İşlem Birimi (Graphics Processing Unit – GPU) gerektiren hızlı ve güçlü bilgisayarlarda çalıştığından ve Google Colaboratory (Colab) platformu NVIDİA Tesla T4 GPU özelliğiyle bunu ücretsiz bir şekilde sağladığından eğitim işlemi için Colab bulut hizmetinden yararlanılmıştır. Google Drive bağlantısıyla Colab’da eğitime başlanmıştır. Colab, derin öğrenme uygulamalarının geliştirilmesi, modellerin eğitilmesi, Tensorflow, Keras, OpenCV vb. kütüphanelerin kullanımı, Python programlama dilinin geliştirilmesi gibi birçok hizmet için kullanım sağlamaktadır.
- Veri seti eğitildikten sonra test edilerek elde edilen sonuçlar performans değerlendirme metrikleri ile değerlendirilmiştir.

Çalışmada uygulamayı etkileyen bazı kısıtlamalarla karşılaşmıştır. Bunlar aşağıda belirtilmiştir.

- Gıda sektöründeki firmalarda, gizlilik nedeniyle personele ait görüntülerin temin edilme güçlüğünden dolayı çalışmada kullanılan veri setinin ücretsiz stok resim sitelerinden elde edilmesi ve görsellerin, benzerlikten dolayı veri artırma teknikleriyle istenilen düzeyde çoğaltılamaması
- Verilerin eğitiminde kullanılan Colab'ın eğitim için sınırlı süre kullandırması nedeniyle en fazla 50 epoch sayısında eğitimin gerçekleştirilmesi

## 5.2. Veri Seti

Nesne tespiti için büyük bir öneme sahip olan veri seti çalışmanın başarılı sonuçlara ulaşmasında etkin bir rol oynamaktadır. Tablo 5.1. de belirtildiği gibi veri setinde Versiyon1 (v1) için 1.943, veri çoğaltma işlemi ile elde edilen Versiyon2 (v2) için 2.157 görsel kullanılmıştır. Veri çoğaltma işlemlerinden gri tonlama kullanılarak v2 için eğitim verilerinin sayısı artırılmıştır. Diğer çoğaltma yöntemleri kullanılarak yapılan versiyon denemelerinde ise görüntüler arasındaki benzerlikten dolayı veri sayısındaki artış, modelde aşırı uyuma (overfitting) neden olmuştur. Bu nedenle sadece bir çoğaltma yöntemi seçilerek veri sayısındaki artışın model başarısına etkisi gözlemlenmiştir. Uygulama, her iki versiyon için Yolov5, Yolov8 ve Yolov9 algoritmaları kullanılarak 15, 25 ve 50 epoch sayılarında gerçekleştirilmiştir.

Tablo 5.1. Veri seti

|               | <b>v1</b>    | <b>v2</b>    |
|---------------|--------------|--------------|
| Eğitim        | 1.455        | 1.627        |
| Doğrulama     | 293          | 315          |
| Test          | 195          | 215          |
| <b>Toplam</b> | <b>1.943</b> | <b>2.157</b> |

Veri seti %75 eğitim (train), %15 doğrulama (validation) ve %10 test verileri şeklinde dağıtılmıştır. Literatürde bulunan çalışmalarda eğitim veri seti %70-80 arasında değişirken, doğrulama ve test veri seti toplamda %20-30 arasında bir değer almaktadır. Veri setinde toplam 8 sınıf etiketi bulunmaktadır (Tablo 5.2.). Bu sınıflara ait etiketlerin eşit bir şekilde dağılımı sonuçların doğruluğu ve başarı oranının artması açısından önemlidir. Bu nedenle sınıf sayılarının birbirine yakın olması için gerekli sınıflara ait görüntüler veri setine eklenmiş ve sınıflar arasında bir uyum sağlanmıştır.


Tablo 5.2. Veri etiketleri (v1)

| Sınıf Etiketleri              | Etiket Sayısı |
|-------------------------------|---------------|
| Chef uniform (Şef üniforması) | 1.177         |
| Glove (Eldivenli)             | 878           |
| Hat (Şapka)                   | 1.108         |
| Mask (Maske)                  | 879           |
| No glove (Eldivensiz)         | 1.119         |
| No hat (Şapkasız)             | 943           |
| No mask (Maskesiz)            | 805           |
| No uniform (Üniformasız)      | 835           |
| <b>Toplam</b>                 | <b>7.744</b>  |


### 5.3. Veri Etiketleme

Verilerin etiketlenmesinde ve çoğaltılmasında Roboflow platformu kullanılmıştır. Roboflow; görüntü işlemede nesne tespiti, sınıflandırma ve segmentasyon uygulamalarında görsellerin etiketlenmesi, çoğaltılması ve eğitilmesi için kullanılan ücretsiz bir platformdur. Görsellerin yeniden boyutlandırılması, istenilen oranlarda dağılımı (eğitim, doğrulama, test) ve veri çoğaltma (gri tonlama, bulanıklaştırma, gürültü ekleme, kırpma, çevirme, döndürme, parlaklık vb.) işlemleriyle veri setini eğitime hazır hale getirmek için kullanılmaktadır.

Veri setinde sınırlayıcı kutular (bounding box) kullanılarak şef üniforması, şapka, eldiven, maske, üniformasız, şapkasız, eldivensiz ve maskesiz sınıfları tek tek etiketlenmiştir. Etiketleme işlemi sırasında nesne ve merkez noktası tamamen sınırlayıcı kutu içerisine alınarak etiketleme yapılmıştır. Etiketleme işleminin doğru bir şekilde yapılması veri setinin eğitimde başarılı sonuçlar elde etmesinde önemli bir rol oynamaktadır. Eğitim işleminin hızlı ve başarılı bir şekilde gerçekleşmesi için resimlerin aynı boyutta ve ideal oranlarda olması gerekmektedir. Bu nedenle etiketlenen resimler yeniden boyutlandırma işlemi ile 640\*640 boyutlarına getirilmiştir. Şekil 5.2. ve Şekil 5.3. te Roboflow kullanılarak etiketlenen veri setinden örnekler ve etiket formatı bulunmaktadır.



Şekil 5.2. Verilerin etiketlenmesi (Freepik)



|   |            |           |            |            |
|---|------------|-----------|------------|------------|
| 0 | 0.534375   | 0.5359375 | 0.359375   | 0.4328125  |
| 4 | 0.4015625  | 0.621875  | 0.078125   | 0.1046875  |
| 6 | 0.54140625 | 0.278125  | 0.09140625 | 0.12265625 |
| 2 | 0.540625   | 0.1140625 | 0.17421875 | 0.1609375  |

Şekil 5.3. Roboflow ile etiketlenmiş resim ve Yolo algoritması formatında etiketler (Freepik)

Etiketlemede ilk sütun sınıf türünü belirtirken diğer sütunlar sırasıyla x, y, w (genişlik), h (yükseklik) koordinatlarını belirtmektedir.

## 5.4. Verilerin Eğitimi

Eğitim, doğrulama ve test için ayrılan veri seti Google Colab platformuna aktarılmış ve Google Drive bağlantısıyla Colab üzerinden eğitim gerçekleştirilmiştir. Görüntü işleme uygulamalarında yüksek güce sahip bilgisayarlara ihtiyaç duyulması nedeniyle modelin hızlı bir şekilde eğitilmesi için GPU ve python kütüphanelerinin kullanımını ücretsiz sağlayan Google Colab kullanılmıştır. En iyi sonucu elde edebilmek için farklı epoch sayılarında eğitim gerçekleştirilmiştir. Colab eğitim için ücretsiz GPU sağlamakta fakat eğitim için kullanılan süreyi sınırlamaktadır. Bu nedenle epoch sayısı en yüksek 50 seçilmiştir. Gerçek zamanlı, hızlı ve yüksek doğruluk değerlerine ulaşma gibi avantajlar sağladığından modelin eğitimi için Yolo algoritması kullanılmıştır. Eğitim için Google Colab’da kullanılan bazı kodlar Ek 1’de belirtilmiştir.

### 5.4.4. Yolov5 ile Eğitim

Yolov5 algoritması ile v1 ve v2 örnek büyüklükleri için 15, 25 ve 50 epoch sayılarında gerçekleştirilen eğitim işleminde batch size 16 seçilirken eğitim işleminin hızlanması için görsel boyutu 416 seçilmiştir. Eğitim sonuçlarına bakıldığında v1 için sınıflara ait 293 görüntü ve bu sınıfların doğrulama veri setindeki görüntülerde toplam 1.192 örnek, v2 için 315 görüntü ve 1.251 örnek bulunmaktadır. Bu durum şef üniforması, maske, eldiven, şapka ve diğer 4 sınıfa ait görüntülerin doğrulama setinde toplamda v1 için 1.192 kere, v2 için 1.251 kere görüntülenmesi anlamına gelmektedir. Tablo 5.3. te belirtilen eğitim sonuçlarında performans değerlendirmesinde kullanılan metriklerden kesinlik (Precision - P), duyarlılık (Recall - R), mAP50 değeri ve eğitim süresi bulunmaktadır.

Tablo 5.3. Tüm Sınıflar için Yolov5 algoritması eğitim sonuçları

|    |          | Görüntüler | Örnekler | P     | R     | mAP50 | Süre (dakika) |
|----|----------|------------|----------|-------|-------|-------|---------------|
|    | 15 Epoch |            |          | 0,537 | 0,588 | 0,584 | 5,4           |
| v1 | 25 Epoch | 293        | 1.192    | 0,676 | 0,706 | 0,71  | 8,2           |
|    | 50 Epoch |            |          | 0,816 | 0,817 | 0,834 | 15,5          |
|    | 15 Epoch |            |          | 0,631 | 0,605 | 0,634 | 6,6           |
| v2 | 25 Epoch | 315        | 1.251    | 0,73  | 0,74  | 0,747 | 9,1           |
|    | 50 Epoch |            |          | 0,825 | 0,818 | 0,832 | 18,7          |



Şekil 5.4., Şekil 5.5. ve Şekil 5.6. da Yolov5 nesne tespit algoritması v1'e ait eğitim sonuçlarından örnekler bulunmaktadır. Tüm görsellerde (Freepik) sınıfın yanında bulunan sayılar nesnelerin tespit edilme oranlarını göstermektedir.



Şekil 5.4. Yolov5 - 15 epoch eğitim sonuçları (v1)



Şekil 5.5. Yolov5 - 25 epoch eğitim sonuçları (v1)



Şekil 5.6. Yolov5 - 50 epoch eğitim sonuçları (v1)

Şekil 5.7., Şekil 5.8. ve Şekil 5.9. da Yolov5 nesne tespit algoritması v2 için eğitim sonuçlarından örnekler bulunmaktadır.





Şekil 5.7. Yolov5 - 15 epoch eğitim sonuçları (v2)



Şekil 5.8. Yolov5 - 25 epoch eğitim sonuçları (v2)



Şekil 5.9. Yolov5 - 50 epoch eğitim sonuçları (v2)

Nesne tespit başarıları karşılaştırıldığında, Yolov5 algoritmasında epoch sayısı arttıkça eğitim süresi artarken performans değerlendirme metrikleri ve başarı oranındaki artış dikkat çekmektedir. Yolov5 için en başarılı sonuçlara en yüksek mAP değerlerinin bulunduğu 50 epoch sayılarında ulaşılmıştır. Versiyonlar arasında anlamlı bir artış gözlemlenmemiş fakat epoch sayısı arttıkça başarı oranı artmıştır.

#### 5.4.5. Yolov8 ile Eğitim

Yolov8 algoritması ile v1 ve v2 örnek büyüklükleri için 15, 25 ve 50 epoch sayılarında batch size 16, resim boyutu 416 seçilerek eğitim gerçekleştirilmiştir. Tablo 5.4. te eğitim sonuçlarına ilişkin kesinlik (P), duyarlılık (R), mAP50 değeri ve eğitim süresi değerleri bulunmaktadır.

Tablo 5.4. Tüm sınıflar için Yolov8 algoritması eğitim sonuçları

|    |          | Görüntüler | Örnekler | P     | R     | mAP50 | Süre (dakika) |
|----|----------|------------|----------|-------|-------|-------|---------------|
|    | 15 Epoch |            |          | 0,871 | 0,854 | 0,898 | 7,8           |
| v1 | 25 Epoch | 293        | 1.192    | 0,859 | 0,884 | 0,915 | 11            |
|    | 50 Epoch |            |          | 0,855 | 0,889 | 0,903 | 22,1          |
|    | 15 Epoch |            |          | 0,842 | 0,901 | 0,91  | 8,7           |
| v2 | 25 Epoch | 315        | 1.251    | 0,865 | 0,888 | 0,912 | 13,4          |
|    | 50 Epoch |            |          | 0,871 | 0,874 | 0,915 | 27            |

Eğitim süresi, veri sayısı ve epoch sayısı ile orantılı bir şekilde artarken kesinlik (P), duyarlılık (R) ve mAP50 değerlerindeki artış dikkat çekmektedir. Yukarıdaki tabloya bakıldığında Yolov8 için en başarılı sonuçlara en yüksek mAP değerinin bulunduğu v1'in 25 ve v2'nin 50 epoch sayılarında ulaşıldığı anlaşılmaktadır. 1. versiyonda epoch sayısı 25 iken 50 epoch sayısına kıyasla daha iyi bir mAP değerine ulaşılmasında veri setinin öğrenmeyi 50 epoch sayısından önce tamamlaması etkilerken v2'de en iyi mAP değerine 50 epoch sayısında ulaşılmasında veri sayısındaki artışın etkili olduğu düşünülmektedir. Çünkü veri sayısı arttıkça eğitim süresi uzamaktadır. Aynı mAP değerlerine sahip bu iki versiyondan eğitim süresi de dikkate alındığında v1 için 25 epoch sayısındaki modelin tercih edilmesi daha avantajlıdır.

Epoch sayısı arttıkça genel olarak modelin başarısı artmaktadır. Ancak eğitim sırasında, model veri setini öğrendikten sonra fazladan epoch sayısının ezberlemeye neden olmaması için eğitim en yüksek performans değerlerine ulaştıktan sonra durdurulmalıdır.

Şekil 5.10., Şekil 5.11. ve Şekil 5.12. de Yolov8 nesne tespit algoritması v1'e ait eğitim sonuçlarından örnekler bulunmaktadır.





Şekil 5.10. Yolov8 - 15 epoch eğitim sonuçları (v1)



Şekil 5.11. Yolov8 - 25 epoch eğitim sonuçları (v1)



Şekil 5.12. Yolov8 - 50 epoch eğitim sonuçları (v1)

Şekil 5.13., Şekil 5.14. ve Şekil 5.15. de Yolov8 nesne tespit algoritması v2 için eğitim sonuçlarından örnekler bulunmaktadır.



Şekil 5.13. Yolov8 - 15 epoch eğitim sonuçları (v2)



Şekil 5.14. Yolov8 - 25 epoch eğitim sonuçları (v2)



Şekil 5.15. Yolov8 - 50 epoch eğitim sonuçları (v2)

#### 5.4.6. Yolov9 ile Eğitim

Yolov9 algoritması ile v1 ve v2 örnek büyüklükleri için 15, 25 ve 50 epoch sayılarında batch size 32, resim boyutu 416 seçilerek eğitim gerçekleştirilmiştir. Tablo 5.5. te belirtilen eğitim sonuçlarına göre kesinlik (P), duyarlılık (R), mAP50 değeri ve eğitim süresi bulunmaktadır.

Tablo 5.5. Tüm sınıflar için Yolov9 algoritması eğitim sonuçları

|    |          | Görüntüler | Örnekler | P     | R     | mAP50 | Süre (dakika) |
|----|----------|------------|----------|-------|-------|-------|---------------|
|    | 15 Epoch |            |          | 0,866 | 0,876 | 0,894 | 10,5          |
| v1 | 25 Epoch | 293        | 1.192    | 0,864 | 0,89  | 0,906 | 20,5          |
|    | 50 Epoch |            |          | 0,876 | 0,901 | 0,911 | 43,4          |
|    | 15 Epoch |            |          | 0,858 | 0,886 | 0,905 | 11,7          |
| v2 | 25 Epoch | 315        | 1.251    | 0,857 | 0,908 | 0,915 | 22,5          |
|    | 50 Epoch |            |          | 0,885 | 0,909 | 0,927 | 48,5          |

Yolov9 algoritmasının eğitim sonuçlarına bakıldığında epoch sayısına bağlı eğitim süresinin arttığı aynı zamanda bu durumun kesinlik (P), duyarlılık (R) ve mAP50 değerlerini de arttırdığı gözlemlenmektedir. En başarılı performansa v2'nin 50 epoch sayısında elde edilen değerler ile ulaşıldığı anlaşılmaktadır.

Performans metrikleri değerlendirildiğinde 0,885 kesinlik, 0,909 duyarlılık ve 0,927 mAP değerleri ile Yolov9 en başarılı algoritmadır. Eğitim süresi Yolov5 ve Yolov8 algoritmalarına kıyasla daha fazla olmasına rağmen Yolov9 algoritmasının performans başarısı ön plana çıkmaktadır.

Şekil 5.16., Şekil 5.17. ve Şekil 5.18. de Yolov9 nesne tespit algoritmasının v1 için eğitim sonuçları bulunmaktadır.





Şekil 5.16. Yolov9 - 15 epoch eğitim sonuçları (v1)



Şekil 5.17. Yolov9 - 25 epoch eğitim sonuçları (v1)



Şekil 5.18. Yolov9 - 50 epoch eğitim sonuçları (v1)

Şekil 5.19., Şekil 5.20. ve Şekil 5.21. de Yolov9 nesne tespit algoritmasının v2 için eğitim sonuçları bulunmaktadır.





Şekil 5.19. Yolov9 - 15 epoch eğitim sonuçları (v2)



Şekil 5.20. Yolov9 - 25 epoch eğitim sonuçları (v2)



Şekil 5.21. Yolov9 - 50 epoch eğitim sonuçları (v2)

#### 5.4.7. Tüm Algoritma Sonuçlarının Sınıflar Bazında Değerlendirilmesi

Tablo 5.6., Tablo 5.7., Tablo 5.8., Tablo 5.9., Tablo 5.10., Tablo 5.11., Tablo 5.12. ve Tablo 5.13. te sınıfların (şef üniforması, eldiven, şapka, maske, eldivensiz, şapkasız, maskesiz, üniformasız) eğitim sonuçlarının karşılaştırması sunulmaktadır.

Tablo 5.6. Şef üniforması sınıfı için eğitim sonuçlarının karşılaştırması

| Şef Üniforması |    |          | TP         | FP        | FN        | TN         | Precision    | Recall       | F1           | mAP          |
|----------------|----|----------|------------|-----------|-----------|------------|--------------|--------------|--------------|--------------|
| Yolov5         | v1 | 15 Epoch | 159        | 84        | 173       | 776        | 0,654        | 0,479        | 0,553        | 0,554        |
|                |    | 25 Epoch | 211        | 46        | 109       | 826        | 0,821        | 0,659        | 0,731        | 0,744        |
|                |    | 50 Epoch | 236        | 37        | 33        | 886        | 0,865        | 0,879        | 0,872        | 0,895        |
|                | v2 | 15 Epoch | 195        | 82        | 113       | 861        | 0,703        | 0,633        | 0,666        | 0,693        |
|                |    | 25 Epoch | 250        | 47        | 49        | 905        | 0,842        | 0,836        | 0,839        | 0,853        |
|                |    | 50 Epoch | 261        | 33        | 25        | 932        | 0,887        | 0,912        | 0,899        | 0,917        |
| Yolov8         | v1 | 15 Epoch | 247        | 26        | 16        | 903        | 0,905        | 0,938        | 0,921        | 0,957        |
|                |    | 25 Epoch | 237        | 13        | 25        | 917        | 0,947        | 0,903        | 0,924        | 0,977        |
|                |    | 50 Epoch | 242        | 29        | 15        | 906        | 0,893        | 0,94         | 0,916        | 0,973        |
|                | v2 | 15 Epoch | 266        | 34        | 10        | 941        | 0,888        | 0,964        | 0,924        | 0,959        |
|                |    | 25 Epoch | 256        | 19        | 19        | 957        | 0,932        | 0,931        | 0,931        | 0,975        |
|                |    | 50 Epoch | <b>264</b> | <b>12</b> | <b>18</b> | <b>957</b> | <b>0,955</b> | <b>0,936</b> | <b>0,945</b> | <b>0,982</b> |
| Yolov9         | v1 | 15 Epoch | 239        | 23        | 17        | 913        | 0,913        | 0,935        | 0,924        | 0,969        |
|                |    | 25 Epoch | 239        | 17        | 21        | 915        | 0,932        | 0,918        | 0,925        | 0,973        |
|                |    | 50 Epoch | 242        | 14        | 18        | 918        | 0,946        | 0,93         | 0,938        | 0,98         |
|                | v2 | 15 Epoch | 261        | 22        | 19        | 949        | 0,921        | 0,931        | 0,926        | 0,964        |
|                |    | 25 Epoch | 267        | 26        | 10        | 948        | 0,911        | 0,965        | 0,937        | 0,966        |
|                |    | 50 Epoch | 272        | 17        | 10        | 952        | 0,94         | 0,966        | 0,953        | 0,973        |



Tablo 5.7. Eldiven sınıfı için eğitim sonuçlarının karşılaştırması

| Eldiven |    |          | TP        | FP       | FN       | TN           | Precision    | Recall       | F1          | mAP          |
|---------|----|----------|-----------|----------|----------|--------------|--------------|--------------|-------------|--------------|
| Yolov5  | v1 | 15 Epoch | 12        | 20       | 24       | 1.136        | 0,378        | 0,333        | 0,354       | 0,287        |
|         |    | 25 Epoch | 15        | 24       | 17       | 1.136        | 0,387        | 0,467        | 0,423       | 0,355        |
|         |    | 50 Epoch | 20        | 4        | 15       | 1.153        | 0,834        | 0,567        | 0,675       | 0,72         |
|         | v2 | 15 Epoch | 9         | 6        | 32       | 1.204        | 0,597        | 0,22         | 0,322       | 0,238        |
|         |    | 25 Epoch | 25        | 36       | 29       | 1.161        | 0,41         | 0,463        | 0,435       | 0,391        |
|         |    | 50 Epoch | 25        | 4        | 20       | 1.202        | 0,867        | 0,561        | 0,681       | 0,662        |
| Yolov8  | v1 | 15 Epoch | 22        | 2        | 9        | 1.159        | 0,915        | 0,718        | 0,805       | 0,863        |
|         |    | 25 Epoch | 24        | 6        | 5        | 1.157        | 0,806        | 0,831        | 0,818       | 0,86         |
|         |    | 50 Epoch | 23        | 5        | 6        | 1.158        | 0,827        | 0,795        | 0,811       | 0,839        |
|         | v2 | 15 Epoch | 36        | 7        | 4        | 1.204        | 0,839        | 0,902        | 0,869       | 0,89         |
|         |    | 25 Epoch | 39        | 9        | 5        | 1.198        | 0,82         | 0,892        | 0,854       | 0,943        |
|         |    | 50 Epoch | 38        | 12       | 4        | 1.197        | 0,765        | 0,902        | 0,828       | 0,888        |
| Yolov9  | v1 | 15 Epoch | 23        | 2        | 7        | 1.160        | 0,92         | 0,764        | 0,835       | 0,849        |
|         |    | 25 Epoch | 24        | 3        | 6        | 1.159        | 0,877        | 0,8          | 0,837       | 0,893        |
|         |    | 50 Epoch | 26        | 6        | 5        | 1.155        | 0,808        | 0,841        | 0,824       | 0,865        |
|         | v2 | 15 Epoch | 37        | 6        | 5        | 1.203        | 0,857        | 0,875        | 0,866       | 0,906        |
|         |    | 25 Epoch | 37        | 9        | 5        | 1.200        | 0,812        | 0,878        | 0,844       | 0,931        |
|         |    | 50 Epoch | <b>38</b> | <b>4</b> | <b>4</b> | <b>1.205</b> | <b>0,899</b> | <b>0,902</b> | <b>0,90</b> | <b>0,951</b> |

Tablo 5.8. Şapka sınıfı için eğitim sonuçlarının karşılaştırması

| Şapka  |    |          | TP         | FP       | FN       | TN         | Precision    | Recall       | F1           | mAP          |
|--------|----|----------|------------|----------|----------|------------|--------------|--------------|--------------|--------------|
| Yolov5 | v1 | 15 Epoch | 177        | 84       | 78       | 853        | 0,678        | 0,695        | 0,686        | 0,71         |
|        |    | 25 Epoch | 212        | 20       | 24       | 936        | 0,915        | 0,897        | 0,906        | 0,939        |
|        |    | 50 Epoch | 228        | 16       | 11       | 937        | 0,934        | 0,953        | 0,943        | 0,979        |
|        | v2 | 15 Epoch | 218        | 49       | 47       | 937        | 0,816        | 0,824        | 0,820        | 0,866        |
|        |    | 25 Epoch | 252        | 22       | 15       | 962        | 0,919        | 0,944        | 0,931        | 0,968        |
|        |    | 50 Epoch | 260        | 11       | 3        | 977        | 0,961        | 0,989        | 0,975        | 0,989        |
| Yolov8 | v1 | 15 Epoch | 227        | 11       | 5        | 949        | 0,953        | 0,979        | 0,966        | 0,988        |
|        |    | 25 Epoch | 229        | 3        | 5        | 955        | 0,987        | 0,979        | 0,983        | 0,989        |
|        |    | 50 Epoch | 228        | 6        | 4        | 954        | 0,973        | 0,983        | 0,978        | 0,99         |
|        | v2 | 15 Epoch | 261        | 5        | 1        | 984        | 0,981        | 0,996        | 0,988        | 0,994        |
|        |    | 25 Epoch | 261        | 3        | 1        | 986        | 0,988        | 0,996        | 0,992        | 0,995        |
|        |    | 50 Epoch | 263        | 1        | 6        | 981        | 0,996        | 0,979        | 0,987        | 0,995        |
| Yolov9 | v1 | 15 Epoch | 233        | 7        | 1        | 951        | 0,969        | 0,996        | 0,982        | 0,99         |
|        |    | 25 Epoch | 231        | 6        | 2        | 953        | 0,974        | 0,991        | 0,982        | 0,992        |
|        |    | 50 Epoch | 231        | 8        | 2        | 951        | 0,966        | 0,991        | 0,978        | 0,991        |
|        | v2 | 15 Epoch | 258        | 3        | 9        | 981        | 0,987        | 0,966        | 0,976        | 0,993        |
|        |    | 25 Epoch | 263        | 3        | 2        | 983        | 0,99         | 0,992        | 0,991        | 0,995        |
|        |    | 50 Epoch | <b>263</b> | <b>3</b> | <b>1</b> | <b>984</b> | <b>0,989</b> | <b>0,996</b> | <b>0,992</b> | <b>0,995</b> |

Tablo 5.9. Maske sınıfı için eğitim sonuçlarının karşılaştırması

| Maske  |    |          | TP        | FP       | FN       | TN           | Precision    | Recall   | F1           | mAP          |
|--------|----|----------|-----------|----------|----------|--------------|--------------|----------|--------------|--------------|
| Yolov5 | v1 | 15 Epoch | 20        | 26       | 2        | 1.144        | 0,433        | 0,909    | 0,587        | 0,838        |
|        |    | 25 Epoch | 21        | 10       | 1        | 1.160        | 0,669        | 0,955    | 0,787        | 0,955        |
|        |    | 50 Epoch | 21        | 3        | 1        | 1.167        | 0,886        | 0,955    | 0,919        | 0,959        |
|        | v2 | 15 Epoch | 36        | 21       | 5        | 1.189        | 0,632        | 0,878    | 0,735        | 0,896        |
|        |    | 25 Epoch | 36        | 6        | 5        | 1.204        | 0,849        | 0,878    | 0,863        | 0,88         |
|        |    | 50 Epoch | 39        | 2        | 3        | 1.207        | 0,95         | 0,921    | 0,935        | 0,951        |
| Yolov8 | v1 | 15 Epoch | 21        | 1        | 1        | 1.169        | 0,965        | 0,955    | 0,960        | 0,99         |
|        |    | 25 Epoch | 21        | 2        | 1        | 1.168        | 0,916        | 0,955    | 0,935        | 0,99         |
|        |    | 50 Epoch | 22        | 2        | -        | 1.168        | 0,955        | 0,955    | 0,955        | 0,992        |
|        | v2 | 15 Epoch | 40        | 2        | 2        | 1.207        | 0,957        | 0,951    | 0,954        | 0,975        |
|        |    | 25 Epoch | 40        | 1        | 2        | 1.208        | 0,977        | 0,951    | 0,964        | 0,976        |
|        |    | 50 Epoch | 39        | -        | 2        | 1.210        | 0,993        | 0,951    | 0,972        | 0,976        |
| Yolov9 | v1 | 15 Epoch | 21        | 1        | 1        | 1.169        | 0,97         | 0,955    | 0,962        | 0,965        |
|        |    | 25 Epoch | 21        | 1        | 1        | 1.169        | 0,97         | 0,955    | 0,962        | 0,988        |
|        |    | 50 Epoch | <b>22</b> | <b>1</b> | <b>-</b> | <b>1.169</b> | <b>0,969</b> | <b>1</b> | <b>0,984</b> | <b>0,995</b> |
|        | v2 | 15 Epoch | 39        | 1        | 2        | 1.209        | 0,977        | 0,951    | 0,964        | 0,969        |
|        |    | 25 Epoch | 39        | -        | 2        | 1.210        | 0,991        | 0,951    | 0,971        | 0,976        |
|        |    | 50 Epoch | 40        | -        | 1        | 1.210        | 0,997        | 0,976    | 0,986        | 0,98         |

Tablo 5.10. Eldivensiz sınıfı için eğitim sonuçlarının karşılaştırması

| Eldivensiz |    |          | TP         | FP        | FN        | TN         | Precision    | Recall       | F1           | mAP         |
|------------|----|----------|------------|-----------|-----------|------------|--------------|--------------|--------------|-------------|
| Yolov5     | v1 | 15 Epoch | 104        | 148       | 272       | 668        | 0,413        | 0,277        | 0,332        | 0,295       |
|            |    | 25 Epoch | 175        | 196       | 237       | 584        | 0,472        | 0,425        | 0,447        | 0,42        |
|            |    | 50 Epoch | 208        | 148       | 87        | 749        | 0,585        | 0,705        | 0,639        | 0,638       |
|            | v2 | 15 Epoch | 50         | 46        | 411       | 744        | 0,52         | 0,109        | 0,180        | 0,282       |
|            |    | 25 Epoch | 190        | 143       | 206       | 712        | 0,571        | 0,48         | 0,522        | 0,508       |
|            |    | 50 Epoch | 215        | 97        | 132       | 807        | 0,688        | 0,62         | 0,652        | 0,657       |
| Yolov8     | v1 | 15 Epoch | 221        | 104       | 50        | 817        | 0,681        | 0,815        | 0,742        | 0,744       |
|            |    | 25 Epoch | 217        | 102       | 66        | 807        | 0,68         | 0,768        | 0,721        | 0,781       |
|            |    | 50 Epoch | 221        | 111       | 47        | 813        | 0,666        | 0,825        | 0,737        | 0,773       |
|            | v2 | 15 Epoch | 253        | 119       | 41        | 838        | 0,68         | 0,86         | 0,759        | 0,804       |
|            |    | 25 Epoch | 244        | 89        | 72        | 846        | 0,732        | 0,773        | 0,752        | 0,808       |
|            |    | 50 Epoch | 234        | 81        | 79        | 857        | 0,744        | 0,749        | 0,746        | 0,819       |
| Yolov9     | v1 | 15 Epoch | 211        | 108       | 54        | 819        | 0,662        | 0,795        | 0,722        | 0,764       |
|            |    | 25 Epoch | 226        | 124       | 46        | 796        | 0,645        | 0,832        | 0,727        | 0,765       |
|            |    | 50 Epoch | 211        | 87        | 57        | 837        | 0,708        | 0,787        | 0,745        | 0,776       |
|            | v2 | 15 Epoch | 246        | 106       | 60        | 839        | 0,698        | 0,803        | 0,747        | 0,788       |
|            |    | 25 Epoch | 251        | 100       | 47        | 853        | 0,716        | 0,842        | 0,774        | 0,801       |
|            |    | 50 Epoch | <b>243</b> | <b>98</b> | <b>54</b> | <b>856</b> | <b>0,712</b> | <b>0,817</b> | <b>0,761</b> | <b>0,82</b> |

Tablo 5.11. Şapkasız sınıfı için eğitim sonuçlarının karşılaştırması

| Şapkasız |    |          | TP         | FP       | FN       | TN           | Precision   | Recall       | F1           | mAP          |
|----------|----|----------|------------|----------|----------|--------------|-------------|--------------|--------------|--------------|
| Yolov5   | v1 | 15 Epoch | 103        | 61       | 6        | 1.022        | 0,627       | 0,944        | 0,754        | 0,899        |
|          |    | 25 Epoch | 103        | 35       | 12       | 1.042        | 0,747       | 0,897        | 0,815        | 0,86         |
|          |    | 50 Epoch | 104        | 14       | 5        | 1.069        | 0,882       | 0,953        | 0,916        | 0,959        |
|          | v2 | 15 Epoch | 91         | 34       | 6        | 1.120        | 0,727       | 0,936        | 0,818        | 0,899        |
|          |    | 25 Epoch | 93         | 21       | 4        | 1.133        | 0,814       | 0,957        | 0,880        | 0,938        |
|          |    | 50 Epoch | 94         | 17       | 2        | 1.138        | 0,846       | 0,979        | 0,908        | 0,935        |
| Yolov8   | v1 | 15 Epoch | 105        | 9        | 3        | 1.075        | 0,917       | 0,972        | 0,944        | 0,975        |
|          |    | 25 Epoch | 105        | 8        | 3        | 1.076        | 0,927       | 0,972        | 0,949        | 0,981        |
|          |    | 50 Epoch | 103        | 8        | 4        | 1.077        | 0,928       | 0,963        | 0,945        | 0,98         |
|          | v2 | 15 Epoch | 92         | 17       | 3        | 1.139        | 0,841       | 0,968        | 0,900        | 0,969        |
|          |    | 25 Epoch | 94         | 12       | -        | 1.145        | 0,927       | 0,952        | 0,939        | 0,96         |
|          |    | 50 Epoch | 93         | 8        | 3        | 1.147        | 0,92        | 0,973        | 0,946        | 0,977        |
| Yolov9   | v1 | 15 Epoch | 105        | 12       | 2        | 1.073        | 0,897       | 0,981        | 0,937        | 0,952        |
|          |    | 25 Epoch | 105        | 10       | 2        | 1.075        | 0,91        | 0,981        | 0,944        | 0,973        |
|          |    | 50 Epoch | <b>105</b> | <b>7</b> | <b>3</b> | <b>1.077</b> | <b>0,94</b> | <b>0,972</b> | <b>0,956</b> | <b>0,981</b> |
|          | v2 | 15 Epoch | 94         | 14       | 1        | 1.142        | 0,869       | 0,989        | 0,925        | 0,948        |
|          |    | 25 Epoch | 94         | 8        | 1        | 1.148        | 0,918       | 0,989        | 0,952        | 0,98         |
|          |    | 50 Epoch | 93         | 9        | 2        | 1.147        | 0,909       | 0,979        | 0,943        | 0,979        |


Tablo 5.12. Maskesiz sınıfı için eğitim sonuçlarının karşılaştırması

| Maskesiz |    |          | TP         | FP        | FN        | TN           | Precision    | Recall       | F1           | mAP          |
|----------|----|----------|------------|-----------|-----------|--------------|--------------|--------------|--------------|--------------|
| Yolov5   | v1 | 15 Epoch | 168        | 159       | 39        | 826          | 0,514        | 0,81         | 0,629        | 0,692        |
|          |    | 25 Epoch | 174        | 83        | 38        | 897          | 0,678        | 0,82         | 0,742        | 0,789        |
|          |    | 50 Epoch | 178        | 68        | 23        | 923          | 0,722        | 0,884        | 0,795        | 0,79         |
|          | v2 | 15 Epoch | 152        | 112       | 17        | 970          | 0,576        | 0,897        | 0,702        | 0,779        |
|          |    | 25 Epoch | 157        | 77        | 19        | 998          | 0,671        | 0,892        | 0,766        | 0,818        |
|          |    | 50 Epoch | 160        | 78        | 15        | 998          | 0,671        | 0,915        | 0,774        | 0,823        |
| Yolov8   | v1 | 15 Epoch | 168        | 43        | 57        | 924          | 0,797        | 0,746        | 0,771        | 0,819        |
|          |    | 25 Epoch | 175        | 43        | 33        | 941          | 0,803        | 0,84         | 0,821        | 0,846        |
|          |    | 50 Epoch | 171        | 52        | 39        | 930          | 0,766        | 0,814        | 0,789        | 0,8          |
|          | v2 | 15 Epoch | 159        | 67        | 13        | 1.012        | 0,702        | 0,926        | 0,799        | 0,844        |
|          |    | 25 Epoch | 152        | 47        | 28        | 1.024        | 0,764        | 0,842        | 0,801        | 0,822        |
|          |    | 50 Epoch | 158        | 49        | 37        | 1.007        | 0,762        | 0,812        | 0,786        | 0,82         |
| Yolov9   | v1 | 15 Epoch | 174        | 42        | 25        | 951          | 0,805        | 0,873        | 0,838        | 0,856        |
|          |    | 25 Epoch | 174        | 44        | 39        | 935          | 0,798        | 0,815        | 0,806        | 0,831        |
|          |    | 50 Epoch | 166        | 33        | 35        | 958          | 0,835        | 0,825        | 0,830        | 0,862        |
|          | v2 | 15 Epoch | 149        | 39        | 28        | 1.035        | 0,794        | 0,842        | 0,817        | 0,863        |
|          |    | 25 Epoch | <b>153</b> | <b>52</b> | <b>14</b> | <b>1.032</b> | <b>0,748</b> | <b>0,918</b> | <b>0,824</b> | <b>0,865</b> |
|          |    | 50 Epoch | 153        | 45        | 23        | 1.030        | 0,774        | 0,87         | 0,819        | 0,853        |


Tablo 5.13. Üniformasız sınıfı için eğitim sonuçlarının karşılaştırması

| Üniformasız |    |          | TP        | FP        | FN        | TN           | Precision    | Recall       | F1           | mAP        |
|-------------|----|----------|-----------|-----------|-----------|--------------|--------------|--------------|--------------|------------|
| Yolov5      | v1 | 15 Epoch | 42        | 29        | 120       | 1.001        | 0,595        | 0,26         | 0,362        | 0,394      |
|             |    | 25 Epoch | 67        | 27        | 60        | 1.038        | 0,715        | 0,528        | 0,607        | 0,613      |
|             |    | 50 Epoch | 71        | 16        | 40        | 1.065        | 0,817        | 0,64         | 0,718        | 0,73       |
|             | v2 | 15 Epoch | 39        | 43        | 75        | 1.094        | 0,475        | 0,341        | 0,397        | 0,42       |
|             |    | 25 Epoch | 56        | 17        | 62        | 1.116        | 0,763        | 0,473        | 0,584        | 0,622      |
|             |    | 50 Epoch | 65        | 24        | 36        | 1.126        | 0,729        | 0,645        | 0,684        | 0,719      |
| Yolov8      | v1 | 15 Epoch | 74        | 15        | 30        | 1.073        | 0,834        | 0,71         | 0,767        | 0,844      |
|             |    | 25 Epoch | <b>84</b> | <b>20</b> | <b>17</b> | <b>1.071</b> | <b>0,806</b> | <b>0,829</b> | <b>0,817</b> | <b>0,9</b> |
|             |    | 50 Epoch | 83        | 17        | 16        | 1.076        | 0,832        | 0,84         | 0,836        | 0,878      |
|             | v2 | 15 Epoch | 64        | 12        | 35        | 1.140        | 0,845        | 0,644        | 0,731        | 0,842      |
|             |    | 25 Epoch | 68        | 19        | 21        | 1.143        | 0,78         | 0,763        | 0,771        | 0,82       |
|             |    | 50 Epoch | 72        | 15        | 32        | 1.132        | 0,831        | 0,688        | 0,753        | 0,861      |
| Yolov9      | v1 | 15 Epoch | 78        | 21        | 32        | 1.061        | 0,791        | 0,71         | 0,748        | 0,806      |
|             |    | 25 Epoch | 83        | 20        | 17        | 1.072        | 0,802        | 0,83         | 0,816        | 0,835      |
|             |    | 50 Epoch | 87        | 17        | 14        | 1.074        | 0,831        | 0,86         | 0,845        | 0,835      |
|             | v2 | 15 Epoch | 69        | 21        | 26        | 1.135        | 0,764        | 0,729        | 0,746        | 0,811      |
|             |    | 25 Epoch | 69        | 21        | 25        | 1.136        | 0,77         | 0,731        | 0,750        | 0,804      |
|             |    | 50 Epoch | 70        | 11        | 22        | 1.148        | 0,859        | 0,763        | 0,808        | 0,865      |

Yukarıdaki tablolarda her sınıf için performans değerlendirme metriklerinin karşılaştırması bulunmaktadır. Sınıfların başarı değerlendirmesinde, literatürde en çok kullanılan ve performans değerlendirmede önemli metrikler arasında yer alan mAP değeri en yüksek algoritmalar işaretlenmiş aynı mAP değerine sahip sınıflarda ise F1 puanına göre algoritma seçimi yapılmıştır. Bu değerlendirmeye göre sonuçlara bakıldığında şef üniforması ve üniformasız sınıfları için Yolov8 algoritması, diğer sınıflar (maske, eldiven, şapka, maskesiz, eldivensiz, şapkasız) için ise Yolov9 algoritması daha başarılı sonuçlara ulaşmıştır. Şekil 5.22-29. da tüm sınıfların eğitim sonuçlarına ait süre ve mAP değerlerinin serpm diyagramı bulunmaktadır.




Şekil 5.22. Şef üniforması sınıfı mAP50 – süre grafiği




Şekil 5.23. Eldiven sınıfı mAP50 – süre grafiği







Şekil 5.24. Şapka sınıfı mAP50 – süre grafiği




Şekil 5.25. Maske sınıfı mAP50 – süre grafiği




Şekil 5.26. Eldivensiz sınıfı mAP50 – süre grafiği



Şekil 5.27. Şapkasız sınıfı mAP50 – süre grafiği




Şekil 5.28. Maske sınıfı mAP50 – süre grafiği



Şekil 5.29. Üniformasız sınıfı mAP50 – süre grafiği


Eğitim sonuçlarında süre dikkat alınarak elde edilen mAP değerleri yukarıdaki grafiklerle belirtilmiştir. mAP değerlerinin bulunduğu bu grafikler her sınıf için en uygun algoritmanın seçimi hakkında bir fikir sunmaktadır. Grafiklerde mAP değeri ve sürenin ortalaması alınarak ayrılan kısımlardan, mAP değerinin yüksek ve sürenin az olduğu ilk kısım, sınıfların tespitinde kullanılabilecek algoritmalar hakkında bilgi vermektedir. Sınıfların çoğunda Yolov8 algoritması en iyi süre ve en yüksek mAP değerine ulaşmıştır. Maske sınıfında ise Yolov9 algoritması daha başarılı bulunmuştur.

Şekil 5.30. da ise tüm sınıflar için en iyi mAP değerine sahip, en hızlı algoritmalar seçilmiştir. Sonuçlara bakıldığında Yolov8 ve Yolov9 algoritmalarının Yolov5 algoritmasına kıyasla daha başarılı sonuçlara ulaştığı anlaşılmaktadır.




Şekil 5.30. Sınıflar için en iyi tahmin algoritmaları

Eğitim sonuçlarından elde edilen veriler süre, mAP değeri ve F1 puanı dikkate alınarak değerlendirilmiş ve sınıflara göre algoritma seçimleri yorumlanmıştır. Süre dikkate alındığında çoğunlukla Yolov8 algoritması seçilirken süre dikkate alınmadığında Yolov9 algoritması seçilmiştir. Fakat süreler bakıldığında eğitimlerin 5,4 dk. ile 48,5 dk. arasında değiştiği görülmektedir. Bu nedenle süreler arasındaki fark çok yüksek olmadığından ve tüm sınıflar kategorisinde en yüksek mAP değerine Yolov9 algoritması v2 için 50 epoch sayısında ulaşıldığından gerçek zamanlı uygulamalarda en iyi performans değerine Yolov9'un ulaşacağı ve daha başarılı tespitlerde bulunacağı düşünülmektedir. Bu kapsamda daha önce eğitimde kullanılmamış videolar üzerinde test edilmek üzere bu algoritma seçilerek test edilmiş ve başarılı sonuçlara ulaşılmıştır. Şekil 5.31. ve Şekil 5.32. de Yolov9 algoritması v2 - 50 epoch için eğitim sonuçlarına ait grafikler bulunmaktadır.



Şekil 5.31. F1-Güven Eğrisi

Şekil 5.31. deki F1 güven eğrisi belirli bir güven aralığında tüm sınıflardaki başarı oranını temsil etmektedir. Tüm sınıflar için 0,432 güven aralığında 0,90 başarıya ulaşılmıştır.



Şekil 5.32. Kesinlik - Duyarlılık Eğrisi

Şekil 5.32. deki Kesinlik - Duyarlılık eğrisi farklı güven aralıklarında kesinlik ve duyarlılık arasındaki dengeyi belirtirken eğrinin sağ üst köşeye yaklaşması yani daha büyük bir alan daha başarılı sonuçlar ve daha iyi bir model demektir. Bu alanın sınıf sayısına oranı ise tüm sınıflar için mAP değerine eşittir.

Şekil 5.33. te test veri setindeki görsellerin Yolov9 algoritmasının v2-50 epoch sonuçları, Şekil 5.34. te ise veri setinde bulunmayan videolardan test edilmesi ile elde edilen sonuçlar bulunmaktadır (İTM Life, 2015).



Şekil 5.33. Test veri setindeki görsellerden örnekler



Şekil 5.34. Veri setinde bulunmayan videolardan örnekler

## 6. SONUÇLAR VE ÖNERİLER

Sağlıklı bir yaşam için sağlıklı beslenmek en temel gerekliliklerden biridir. Sağlıklı beslenme için güvenilir gıdaların tüketilmesi gerekmektedir. Gıda güvenliğinin sağlanmasında rol oynayan hijyen standartlarına uyum kapsamında ekipman, araç gereç ve personel temizliğine dikkat edilmeli ve özen gösterilmelidir. Özellikle personelin KKE kullanımı bu konuda önem arz etmektedir.

Tez çalışmasında gıda güvenliği alanında KKE ile ilgili uygunsuzlukların süreklilik esasına dayalı ve otomatik bir şekilde tespit edilebilmesi adına görüntü işleme ve nesne tespit yöntemlerinden faydalanılarak KKE tespiti yapılmıştır. Çalışmadan elde edilen sonuçların hızlı ve güvenilir bir şekilde sağlanması ve gerçek zamanlı uygulamalarda KKE tespitine temel teşkil etmesi adına Yolo algoritması kullanılmıştır. Birçok versiyona sahip Yolo algoritmasından, çalışma kapsamında kullanılanlar Yolov5, Yolov8 ve Yolov9'dur. Yolov5 algoritması, çok hızlı ve kullanımı kolay bir PyTorch modelidir. Aynı zamanda geniş bir kullanıcı topluluğuna sahip olması nedeniyle de tercih edilmiştir. Bu şekilde modelin sürekli güncellenerek geliştirilmesi sağlanmaktadır. Son versiyonlardan Yolov8 (2023) ve Yolov9 (2024) algoritmalarının tercih edilmesinde ise yüksek mAP ve doğruluk değerlerine ulaşabilmesi ve yeni yayınlanmaları etkilidir.

Çalışmada, epoch sayısının ve veri sayısındaki değişimlerin model başarısı üzerindeki etkisi tespit edilerek en başarılı modeli seçebilmek için iki versiyon ve farklı epoch sayıları kullanılmıştır. Fakat gıda sektöründe personel ile ilgili görüntülere gizlilik nedeniyle ulaşılamadığından ve görseller manuel bir şekilde stok resim sitelerinden temin edildiğinden 2. versiyon için veri sayıları fazla artırılamamıştır. Çalışma için yüksek GPU bulunan güçlü bilgisayarlar gerektiğinden ve Colab bunu ücretsiz bir şekilde sağladığından eğitim Colab'da yapılmıştır. Fakat süre kısıtlamasına bağlı eğitimin kesilmesi nedeniyle en fazla 50 epoch için eğitim gerçekleştirilmiştir.

Eğitim sonuçları, performans değerlendirme metriklerinden F1 puanı, mAP değeri ve süre dikkate alınarak değerlendirilmiştir. İlk değerlendirme mAP değeri ve F1 puanı dikkate alınarak yapılmıştır. Aynı mAP değerine sahip sınıflar için F1 puanı yüksek algoritmalar seçildiğinde sınıfların çoğunda (eldiven, şapka, maske, eldivensiz, şapkasız, maskesiz) Yolov9 algoritması başarılı bulunurken diğer sınıflarda (şef üniforması, üniformasız) Yolov8 algoritması başarıya ulaşmıştır.

Her sınıf için mAP50 - süre grafiđi dikkate alınarak ikinci bir deęerlendirme yapıldığında ise sınıfların çoęunda en iyi sonuçlara Yolov8 algoritması ile ulařılırken maske ve maskesiz sınıflarında Yolov9 algoritması daha başarılı bulunmuřtur. Ayrıca sınıflarla ilgili sonuçlara bakıldığında tüm sınıfların yüksek mAP deęerleri ile başarılı sonuçlara ulařtığı tespit edilmiřtir.

Sınıfların tespit başarılarına göre mAP deęeri en yüksek ve en hızlı algoritmalar seilerek üçüncü bir deęerlendirme yapılmak istendiğinde; řef üniforması, řapka, řapkasız ve üniformasız sınıfları için Yolov8 en başarılı algoritma seilirken eldiven, eldivensiz, maske, maskesiz sınıfları için Yolov9 algoritması daha başarılı seilmiřtir.

Fakat süreler arasında çok fark olmadığından (5,4 dk - 48,5 dk.) ve alıřma sonuçlarına genel olarak bakıldığında tüm sınıflar için en yüksek mAP deęerine Yolov9 algoritmasının 2. versiyonunda 50 epoch sayısında ulařıldığından Yolov9 algoritması kullanılarak modelin daha önce görmedięi videolar üzerinde test iřlemi yapılmıřtır. Bu řekilde modelin başarısı gerek anlamda test edilmiř ve başarılı sonuçlara ulařılmıřtır. Yolov9 - v2- 50 için kesinlik deęeri 0,885, duyarlılık deęeri 0,909, F1 deęeri 0,897 ve mAP deęeri ise 0,927 elde edilmiřtir. Gerek zamanlı uygulamalarda en iyi deęere Yolov9 - v2 - 50 modeli ile ulařılabilecektir.

alıřmada karşılařılan kısıtlamalardan dolayı veri sayısında ve epoch sayısında istenilen deęerlere ulařılamadığından daha sonra yapılacak alıřmalarda veri sayısı ve epoch sayısı daha da artırılarak nesne tespit başarısı takip edilebilir. Ayrıca elde edilen analiz sonuçlarına göre KKE kullanmayan kiřilerin tespit edildięi bir uyarı sistemi oluřturulabilir. Bu řekilde, gıda güvenlięinin saęlanması için tam zamanlı ve otomatik sistemler kurularak ekstra iř yükü oluřturmadan hijyen kontrolü saęlanabilecektir.



## KAYNAKLAR

- Ahmed M. I. B., Sarairoh L., Rahman A., Al-Qarawi S., Mhran A., Al-Jalaoud J., Al-Mudaifer D., Al-Haidar F., AlKhulaifi D., Youldash M., et al. (2023). Personal Protective Equipment Detection: A Deep-Learning-Based Sustainable Approach. *Sustainability*, 15, 13990.
- Alateeq, M. M., PP, F. R., & Ali, M. A. (2023). Construction site hazards identification using deep learning and computer vision. *Sustainability*, 15(3), 2358.
- Alpaydın, E. (2013). *Yapay öğrenme*. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Azizan, M. A. and Zaini, N. (2023). "Video Analysis to Detect Dress Code Violations in Laboratories". 2023 IEEE Symposium on Industrial Electronics & Applications (ISIEA), Kuala Lumpur, Malaysia.
- Başaran, G., Çağıl, G. (2022). Koruyucu Gözlük Kullanımının Görüntü İşleme Yöntemiyle Tespit Edilmesi. *El-Cezerî Fen ve Mühendislik Dergisi*, 9(1), 86-95.
- Bhing, N. W. and Sebastian, P. (2021). "Personal Protective Equipment Detection with Live Camera". 2021 IEEE International Conference on Signal and Image Processing Applications (ICSIPA), Kuala Terengganu, Malaysia.
- Brownlee, J., (2022, Ağustos). Difference Between a Batch and an Epoch in a Neural Network. Erişim: 12 Mayıs 2024. <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/>
- Büyükburgaz, E. (2024, Nisan). YOLOv1'den YOLOv9'a Genel Bakış. Erişim: 13 Mayıs 2024. <https://enesbuyukburgaz.medium.com/yolov1den-yolov9-a-genel-bak%C4%B1%C5%9F-2b2b20c1bb03>
- Can, E. (2022, Şubat). Nesne Tespitinde Çapa Kutuları (Anchor Boxes for Object Detection). Erişim: 12 Mayıs 2024. <https://medium.com/@emirreccann.17/nesne-tespitinde-çapa-kutuları-anchor-boxes-for-object-detection-f5cc2c8c8799>
- Casuat, C. D., Merencilla, N. E., Reyes, R. C., Sevilla, R. V. and Pascion, C. G. (2020). "Deep-Hart: An Inference Deep Learning Approach of Hard Hat Detection for Work Safety and Surveillance". 2020 IEEE 7th International Conference on Engineering Technologies and Applied Sciences (ICETAS), Kuala Lumpur, Malaysia.
- CDC, (2018). Burden of Foodborne Illness: Overview. Erişim: 8 Mayıs 2024. <https://www.cdc.gov/foodborneburden/estimates-overview.html>
- Chen, J., Deng, S., Wang, P., Huang, X., Liu, Y. (2023). Lightweight Helmet Detection Algorithm Using an Improved YOLOv4. *Sensors*, 23, 1256.
- Çilek, S. (2020). Görüntü İşleme Nedir? Erişim: 11 Mayıs 2024. <https://www.simurgai.com/Görüntü-İşleme-Nedir/>
- Delhi, V. S. K., Sankarlal, R. and Thomas, A. (2020). Detection of Personal Protective Equipment (PPE) Compliance on Construction Site Using Computer Vision Based Deep Learning Techniques. *Front. Built Environ.*, 6:136.
- Durga, G. L., Potluri, H., Vinnakota, A., Prativada, N. P. and Yelavarti, K. (2022). "Face Mask Detection using MobileNetV2". 2022 Second International Conference on Artificial Intelligence and Smart Energy (ICAIS), Coimbatore, India.
- 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).
- Freepik. Erişim: 9 Aralık 2023 – 8 Nisan 2024. [www.freepik.com](http://www.freepik.com)
- Google Colab. Erişim: 23 Mart 2024 – 25 Nisan 2024. <https://colab.research.google.com/>

- Google İmage. Erişim: 23 Aralık 2023 – 5 Nisan 2024. <https://images.google.com/>
- Göral, V. (2021, Şubat). Sağlıklı yaşamın anahtarı "güvenli gıda" Erişim: 08.05.2024, [www.haberler.com](http://www.haberler.com)
- Hayat, A., Morgado-Dias, F. (2022). Deep Learning-Based Automatic Safety Helmet Detection System for Construction Safety. *Appl. Sci.*, 12, 8268.
- Huang, L., Fu, Q., He, M., Jiang, D., Hao, Z. (2021). Detection Algorithm of Safety Helmet Wearing Based on Deep Learning. *Concurrency Computat Pract Exper*, 33:e6234.
- İTM Life. (2015). Bir operasyonun perde arkası (video). Erişim: 23 Nisan 2024. <https://www.youtube.com/watch?v=K0tqGIBmqCM>
- Ji, X., Gong, F., Yuan, X., Wang, N. (2023). A high-performance framework for personal protective equipment detection on the offshore drilling platform. *Complex & Intelligent Systems*.
- Jocher, G. (2022). Yolov5. Erişim: 15 Mayıs 2024. <https://github.com/ultralytics/yolov5>
- Khan, S., Mishra, B., Ali, A., Kamal, M., Qader M. R., Haider, M. (2021). "Face Mask Detection from Live-Stream Surveillance Video using Convolutional Neural Network". 2021 International Conference on Decision Aid Sciences and Application (DASA), Sakheer, Bahrain.
- Korkmaz, A., Ağdaş, M. T. (2023). Deep Learning-Based Automatic Helmet Detection System in Construction Site Cameras. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 12:3, 773–782.
- Kundu, R., (2023). YOLO: Algorithm for Object Detection Explained [+Examples]. Erişim: 11 Mayıs 2024. <https://www.v7labs.com/blog/yolo-object-detection>
- Lee, Y., Jung, S., Kang, K., Ryu H., Ryu, H. (2023). Deep learning-based framework for monitoring wearing personal protective equipment on construction sites. *Journal of Computational Design and Engineering*, 10:2, 905–917.
- Mathur, S. and Jain, T. (2023). "Segmenting Personal Protective Equipment Using Mask R-CNN". 2023 11th International Conference on Internet of Everything, Microwave Engineering, Communication and Networks (IEMECN), Jaipur, India.
- Meşeci, E. (2021, Ağustos). R-CNN Ailesi Part I: R-CNN & Fast R-CNN. Erişim: 12 Mayıs 2024. <https://elifmeseci.medium.com/r-cnn-ailesi-part-i-6aaf775d05d2>
- Mevzuat, (2011). Gıda Hijyeni Yönetmeliği. Erişim: 11 Mayıs 2024. <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=15592&MevzuatTur=7&MevzuatTertip=5>
- Nath, N. D., Behzadan, A. H. and Paal, S. G. (2020). Deep Learning for Site Safety: Real-Time Detection of Personal Protective Equipment. *Automation in Construction*, 112, 103085.
- Nath, N. D., & Behzadan, A. H. (2020). Deep convolutional networks for construction object detection under different visual conditions. *Frontiers in Built Environment*, 6, 97.
- Nath, N. D., & Behzadan, A. H. (2020). "Deep learning detection of personal protective equipment to maintain safety compliance on construction sites". In *Construction Research Congress 2020*, Tempe, Arizona, USA.
- Nugraha, K. O. P. P., Rifai, A. P. (2023). Convolutional Neural Network for Identification of Personal Protective Equipment Usage Compliance in Manufacturing Laboratory. *Jurnal Ilmiah Teknik Industri*.
- Onbaşı, E., Cinar, A. (2021). Environmental monitoring program: An early warning system supporting microbiological safety in the food industry. *Gıda The Journal of Food*, 46 (5), 1313-1330.

- Özkan, E. B. (2022, Eylül). R-CNN, Fast R-CNN ve Faster R-CNN Mimarileri. Erişim: 12 Mayıs 2024. <https://medium.com/@elifbeyzaozkan/r-cnn-fast-r-cnn-ve-faster-r-cnn-mimarileri-f0b720ab931c>
- Ragab, M. G. et al. (2024). “A Comprehensive Systematic Review of YOLO for Medical Object Detection (2018 to 2023)”. *IEEE*, 12, 57815-57836.
- Resmigazete, (2010). Veteriner Hizmetleri, Bitki Sağlığı, Gıda ve Yem Kanunu. Erişim: 11 Mayıs 2024. <https://www.resmigazete.gov.tr/eskiler/2010/06/20100613-12.htm>
- Reyes, R. C., Sevilla, R. V., Zapanta, G. S., Merin, J. V., Maaliw, R. R., Santiago, A. F. (2022). “Safety Gear Compliance Detection Using Data Augmentation-Assisted Transfer Learning in Construction Work Environment”. 2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT), Bangalore, India.
- Roboflow. Erişim: 13 Ocak 2024 – 23 Mart 2024. <https://roboflow.com/>
- Ruparelia, S., Jethva, M. and Gajjar, R. (2021). “Real-time Face Mask Detection System on Edge using Deep Learning and Hardware Accelerators”. 2021 2nd International Conference on Communication, Computing and Industry 4.0 (C2I4), Bangalore, India.
- Saraç, M. E. (2020). CNN, R-CNN, Fast R-CNN, Mask R-CNN. Erişim: 12 Mayıs 2024. <https://merveelifsarac.medium.com/cnn-r-cnn-fast-r-cnn-mask-r-cnn-c90a1a4d76fb>
- Shah, N., Patel, R., Mistry, R. and Mangrulkar, R. (2022). “Realtime Risk Monitoring System using Convolutional Neural Network for COVID19 Pandemic”. 2022 6th International Conference on Computing, Communication, Control and Automation (ICCUBEA), Pune, India.
- Son, H., Kim, C. (2021). Integrated worker detection and tracking for the safe operation of construction machinery. *Automation in Construction*, 126, 103670.
- Soyer, A. (2024). Gıdalarda Kontaminasyon kaynakları ve Önlenmesi. Erişim: 8 Mayıs 2024, <https://acikders.ankara.edu.tr/mod/resource/view.php?id=102964>
- Tang, S., Roberts, D., Golparvar-Fard, M. (2020). Human-object interaction recognition for automatic construction site safety inspection. *Automation in Construction*, 120, 103356.
- Tarımorman, (2024). ALO 174 Gıda Hattı Çalışmaları. Erişim: 11 Mayıs 2024. <https://www.tarimorman.gov.tr/Konu/1439/ALO-174-Gida-Hatti#:~:text>
- Tekyaygil, F. (2020). Başarabilirsin: Makine Öğrenmesi’ne Giriş 1 - Makine Öğrenmesi ve Yapay Zekâ. Erişim: 5 Mayıs 2024. <https://medium.com/deep-learning-turkiye/basarabilirsin-makine-ogrenmesine-giris-1-makine-ogrenmesi-ve-yapay-zeka-a1eda8762846>
- Temür, G. (2024). Nesne Algılama ve Sınıflandırma. Erişim: 5 Ocak 2024. [http://www.gunaytemur.com/d\\_2024/na\\_hafta\\_4.pdf](http://www.gunaytemur.com/d_2024/na_hafta_4.pdf)
- Thakur, D., Pal, P., Jadhav, A., Kable, N., V B. and Deshpande, S. (2023). “YOLOv8- Based Helmet and Vest Detection System for Safety Assessment”. 2023 International Conference on Network, Multimedia and Information Technology (NMITCON), Bengaluru, India.
- Tomás, J., Rego, A., Viciano-Tudela, S., Lloret, J. (2021). Incorrect Facemask-Wearing Detection Using Convolutional Neural Networks with Transfer Learning. *Healthcare*, 9, 1050.
- Udatewar, P., Desai, A., Godghase, G., Nair, A., Kosamkar, P. (2021). “Personal Protective Equipment Kit Detection using Yolo v5 and TensorFlow”. 2021 International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON), Pune, India.

- Ultralytics, (2023, Kasım). COCO Veri Seti. Erişim: 15 Mayıs 2024. <https://docs.ultralytics.com/tr/datasets/detect/coco/>
- Ultralytics, (2024, Şubat). YOLOv9: Nesne Algılama Teknolojisinde İleriye Doğru Bir Atılım. Erişim: 13 Mayıs 2024. <https://docs.ultralytics.com/tr/models/yolov9/#programmable-gradient-information-pgi>
- VOSviewer. Erişim: 23 Mayıs 2024. <https://www.vosviewer.com/>
- Wang, Z., Wu, Y., Yang, L., Thirunavukarasu, A., Evison, C., Zhao, Y. (2021). Fast Personal Protective Equipment Detection for Real Construction Sites Using Deep Learning Approaches. *Sensors*, 21, 3478.
- Wang, Z., Cai, Z., Wu, Y. (2023). An improved YOLOX approach for low-light and small object detection: PPE on tunnel construction sites. *Journal of Computational Design and Engineering*, 10:3, 1158–1175.
- WHO, (2022). Food safety. Erişim: 8 Mayıs 2024, <https://www.who.int/news-room/fact-sheets/detail/food-safety>
- Wu, B., Pang, C., Zeng, X., Hu, X. (2022). ME-YOLO: Improved YOLOv5 for Detecting Medical Personal Protective Equipment. *Appl. Sci.*, 12, 11978.
- Yung, N. D. T., Wong, W. K., Juwono, F. H. and Sim, Z. A. (2022). “Safety Helmet Detection Using Deep Learning: Implementation and Comparative Study Using YOLOv5, YOLOv6, and YOLOv7”. 2022 International Conference on Green Energy, Computing and Sustainable Technology (GECOST), Miri Sarawak, Malaysia.
- Zhang, Q., Pei, Z., Guo, R., Zhang, H., Kong, W. et al. (2022). An Automated Detection Approach of Protective Equipment Donning for Medical Staff under COVID-19 Using Deep Learning. *CMES-Computer Modeling in Engineering & Sciences*, 132(3), 845-863.
- Zeng, L., Duan, X., Pan, Y. et al. (2023). Research on The Algorithm of Helmet-Wearing Detection Based on The Optimized Yolov4. *Vis Comput*, 39, 2165–2175.
- Zhou, F., Zhao, H. and Nie, Z. (2021). “Safety Helmet Detection Based on YOLOv5”. 2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA), Shenyang, China.

## EKLER

### Yolov5 algoritmasının 15-25-50 epoch sayıları için eğitim ve test kodları

```
# train yolov5s on custom data for 15 epochs
# time its performance
%%time
%cd /content/yolov5/
!python train.py --img 416 --batch 16 --epochs 15 --data {dataset.location}/data.yaml --cfg ./models/custom_yolov5s.yaml --weights '' --name yolov5s_results --cache
```

```
# train yolov5s on custom data for 25 epochs
# time its performance
%%time
%cd /content/yolov5/
!python train.py --img 416 --batch 16 --epochs 25 --data {dataset.location}/data.yaml --cfg ./models/custom_yolov5s.yaml --weights '' --name yolov5s_results --cache
```

```
# train yolov5s on custom data for 50 epochs
# time its performance
%%time
%cd /content/yolov5/
!python train.py --img 416 --batch 16 --epochs 50 --data {dataset.location}/data.yaml --cfg ./models/custom_yolov5s.yaml --weights '' --name yolov5s_results --cache
```

```
%cd /content/yolov5/
!python detect.py --weights runs/train/yolov5s_results/weights/best.pt --img 416 --conf 0.4 --source /content/yolov5/RESTAURANT-CHEF/test/images
```

### Yolov8 algoritmasının 15-25-50 epoch sayıları için eğitim, doğrulama ve test kodları

```
%cd {HOME}

!yolo task=detect mode=train model=yolov8s.pt data={dataset.location}/data.yaml data={dataset.location}/data.yaml epochs=15 imgsz=416 plots=True
```

```
%cd {HOME}

!yolo task=detect mode=train model=yolov8s.pt data={dataset.location}/data.yaml data={dataset.location}/data.yaml epochs=25 imgsz=416 plots=True
```

```
%cd {HOME}

!yolo task=detect mode=train model=yolov8s.pt data={dataset.location}/data.yaml data={dataset.location}/data.yaml epochs=50 imgsz=416 plots=True
```

```
%cd {HOME}

!yolo task=detect mode=val model={HOME}/runs/detect/train/weights/best.pt data={dataset.location}/data.yaml
```

```
%cd {HOME}

!yolo task=detect mode=predict model={HOME}/runs/detect/train/weights/best.pt conf=0.25 source={dataset.location}/test/images save=True
```

Yolov9 algoritmasının 15-25-50 epoch sayıları için eğitim, doğrulama ve test kodları

```
%cd {HOME}/yolov9
```

```
!python train.py \  
--batch 32 --epochs 15 --img 416 --device 0 --min-items 0 --close-mosaic 15 \  
--data {dataset.location}/data.yaml \  
--weights {HOME}/weights/gelan-c.pt \  
--cfg models/detect/gelan-c.yaml \  
--hyp hyp.scratch-high.yaml
```

```
%cd {HOME}/yolov9
```

```
!python train.py \  
--batch 32 --epochs 25 --img 416 --device 0 --min-items 0 --close-mosaic 15 \  
--data {dataset.location}/data.yaml \  
--weights {HOME}/weights/gelan-c.pt \  
--cfg models/detect/gelan-c.yaml \  
--hyp hyp.scratch-high.yaml
```

```
%cd {HOME}/yolov9
```

```
!python train.py \  
--batch 32 --epochs 50 --img 416 --device 0 --min-items 0 --close-mosaic 15 \  
--data {dataset.location}/data.yaml \  
--weights {HOME}/weights/gelan-c.pt \  
--cfg models/detect/gelan-c.yaml \  
--hyp hyp.scratch-high.yaml
```

```
%cd {HOME}/yolov9
```

```
!python val.py \  
--img 416 --batch 32 --conf 0.001 --iou 0.7 --device 0 \  
--data {dataset.location}/data.yaml \  
--weights {HOME}/yolov9/runs/train/exp/weights/best.pt
```

```
!python detect.py \  
--img 416 --conf 0.1 --device 0 \  
--weights {HOME}/yolov9/runs/train/exp/weights/best.pt \  
--source /content/chef.mp4
```

## ÖZ GEÇMİŞ

Cansunur Çokokumuş, Samsun Anadolu Lisesi’ni bitirdikten sonra Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği bölümünden 2015 yılında mezun oldu. 2021 yılında OMÜ LEE Akıllı Sistemler Mühendisliği Ana Bilim Dalı Yüksek Lisans programına girdi.

### İletişim Bilgileri

ORCID ID : 0000-0003-4040-1979

### Yayınlanmış Çalışmalar:

Çokokumuş, C. ve Elevli, S., (2024). “Kişisel Koruyucu Ekipman Denetiminde Görüntü İşleme Uygulamaları”. Karadeniz 15. Uluslararası Uygulamalı Bilimler Kongresi, Rize.