

T.C.
SİİRT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İHA İLE MEYVELERİN OLGUNLAŞMASININ TAKİBİ VE ÇÜRÜK TEŞHİSİ

YÜKSEK LİSANS TEZİ

Abdurrahman YILDIRIM
(223111003)

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Melih KUNCAN
II. Danışman: Dr. Öğr. Üyesi Burak YILDIRIM

Haziran-2024
SİİRT

TEZ KABUL VE ONAYI

Abdurrahman YILDIRIM tarafından hazırlanan “İHA ile Meyvelerin Olgunlaşmasının Takibi ve Çürük Teşhisi” adlı tez çalışması 30/05/2024 tarihinde aşağıdaki jüri tarafından oybirliği ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Yılmaz KAYA

.....

Danışman

Doç. Dr. Melih KUNCAN

.....

Üye

Doç. Dr. Mehmet Recep MİNAZ

.....

Yukarıdaki sonucu onaylarım.

Doç. Dr. Harun BEKTAŞ
Fen Bilimleri Enstitüsü Müdürü

ÖN SÖZ

Yüksek lisans eğitim sürecimde, bilgi, deneyim ve kıymetli zamanlarını benimle paylaşan, her konuda içtenlikle danışabileceğim değerli danışmanlarıma, Doç. Dr. Melih KUNCAN ve Dr. Öğr. Üyesi Burak YILDIRIM'a, teşekkürlerimi sunuyorum. Eğitimim ve çalışmalarım süresince sıkılmadan, yorulmadan beni destekleyen bu kıymetli hocalarıma minnettarım.

Ayrıca, bu süreçte beni anlayışla karşılayan, yorgunluk ve yoğunluk anlarımda yanımda olan, naif ve yapıcı tutumlarıyla yükümü hafifleten eşime, aileme ve arkadaşlarıma maddi ve manevi destekleri için içten teşekkür ediyorum.

Tez çalışmamın gerçekleştiği süreç boyunca beni motive eden, yanımda olan değerli dostlarım Veysel SEVİNÇLİ ve Emre YILMAZ'a da teşekkürlerimi iletiyorum. Bu destekler, bu zorlu süreçte benim için büyük bir güç kaynağı oldu.

Ayrıca bu tez çalışması kapsamında gerçekleştirilen deneyler, Siirt Üniversitesi Mühendislik Fakültesi İşaret İşleme Laboratuvarı'nda yapılmıştır. Bu vesileyle, İşaret İşleme Laboratuvarı personellerine katkılarından dolayı içten teşekkürlerimi sunarım.

Abdurrahman YILDIRIM
SİİRT-2024

İÇİNDEKİLER

Sayfa

ÖN SÖZiii
İÇİNDEKİLERiv
TABLolar LİSTESİv
ŞEKİLLER LİSTESİvi
KISALTMALAR LİSTESİ.....	...viii
ÖZETix
ABSTRACT.....	...x
1. GİRİŞ1
1.1. Meyvelerin Bozulma Nedenleri2
1.2. Araştırmanın Amacı4
1.3. Araştırmanın Önemi5
1.4. Araştırmanın Motivasyonu.....	...6
2. LİTERATÜR ARAŞTIRMASI7
3. MATERYAL VE METOT16
3.1. Materyal16
3.2. Metot20
3.2.1. Derin Öğrenme20
3.2.2. Performans Kriterleri33
4. BULGULAR VE TARTIŞMA35
4.1. Deneysel Uygulamalar42
4.2. YOLOv8 Modeli ve Literatürdeki Diğer Yaklaşımların Karşılaştırılması60
5. SONUÇ VE ÖNERİLER65
6. KAYNAKLAR67
ÖZGEÇMİŞ71

TABLolar LİSTESİ

	<u>Sayfa</u>
Tablo 3.1. Performans Kriterleri Hakkında Bilgiler.....	33
Tablo 4.1. YOLOv8 algoritmanın çıktılarına dayanan değerlendirme sonuçları.....	41
Tablo 4.2. Sunulan çalışmanın literatürdeki meyve tespiti ve sınıflandırma yaklaşımını karşılaştırılması.....	60



ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1. Ağaçtaki meyvelerin sertleştiği gösteriliyor.....	2
Şekil 1.2. Ağaçtaki meyvelerin kabuk rengi olumsuzluğu gösteriliyor.....	3
Şekil 1.3. Meyvenin hastalığı gösteriliyor.....	4
Şekil 3.1. İHA ile meyvelerin ağaçta iken veri toplama anları (a) Nar ağacı, (b) Elma ağacı, (c) Portakal ağacı.....	19
Şekil 3.2. İHA ile topladığımız bazı verilerin görüntüleri.....	20
Şekil 3.3. YOLO algoritmasının fotoğraf üzerinde çalışma prensibi	25
Şekil 3.4. YOLO algoritmanın genel tespit sistemi	26
Şekil 3.5. YOLOv8'in son YOLO modelleriyle karşılaştırılma	28
Şekil 3.6. YOLOv8 mimarisinin çalışma prensibi	32
Şekil 4.1. YOLOv8 ile yapılan çalışmanın F1-GD grafiği.....	36
Şekil 4.2. YOLOv8 ile yapılan çalışmanın K-GD grafiği	37
Şekil 4.3. YOLOv8 ile yapılan çalışmanın D-GD grafiği	38
Şekil 4.4. YOLOv8 ile yapılan çalışmanın K-D grafiği	39
Şekil 4.5. YOLOv8 kayıp fonksiyon değerlerin gösterimi.....	40
Şekil 4.6. YOLOv8 ile yapılan çalışmanın ortalama kesinlik sonuçlarının gösterimi.....	42
Şekil 4.7. Elma meyvesi dalda iken deneysel uygulamaları (a) Elma görseli, (b) Görselin analizi, (c) Analiz görselin grafiği	43
Şekil 4.8. Elma meyvesi dalda iken deneysel uygulamaları (a) Elma görseli, (b) Görselin analizi, (c) Analiz görselin grafiği	44
Şekil 4.9. Elma meyvesi deneysel uygulamaları (a) Elma görseli, (b) Görselin analizi, (c) Analiz görselin grafiği	45
Şekil 4.10. Elma meyvesi dalda iken deneysel uygulamaları (a) Elma görseli, (b) Görselin analizi, (c) Analiz görselin grafiği	46
Şekil 4.11. Nar meyvesi dalda iken deneysel uygulamaları (a) Nar görseli, (b) Görselin analizi, (c) Analiz görselin grafiği	47
Şekil 4.12. Nar meyvesi deneysel uygulamaları (a) Nar görseli, (b) Görselin analizi, (c) Analiz görselin grafiği	48
Şekil 4.13. Nar meyvesi deneysel uygulamaları (a) Nar görseli, (b) Görselin analizi, (c) Analiz görselin grafiği	49
Şekil 4.14. Nar meyvesi deneysel uygulamaları (a) Nar görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	50
Şekil 4.15. Muz meyvesi deneysel uygulamaları (a) Muz görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	51
Şekil 4.16. Muz meyvesi deneysel uygulamaları (a) Muz görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	52
Şekil 4.17. Muz meyvesi deneysel uygulamaları (a) Muz görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	53
Şekil 4.18. Muz meyvesi deneysel uygulamaları (a) Muz görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	54
Şekil 4.19. Portakal meyvesi deneysel uygulamaları (a) Portakal görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	55
Şekil 4.20. Portakal meyvesi deneysel uygulamaları (a) Portakal görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	56

Şekil 4.21. Portakal meyvesi deneysel uygulamaları (a) Portakal görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	57
Şekil 4.22. Portakal meyvesi deneysel uygulamaları (a) Portakal görseli, (b) Görselin analizi, (c) Analiz görselin grafiği.....	58



KISALTMALAR LİSTESİ

<u>Kısaltma</u>	<u>Açıklama</u>
CNN	: Convolutional Neural Network - Evrişimli Sinir Ağları
CPU	: Central Processing Unit - Merkezi İşlem Birimi
SSD	: Solid State Disk - Tek Çekim Çoklu Kutu Dedektörü
EQA	: Effective Quality Assessment - Etkin Kalite Değerlendirme
FPN	: Feature Pyramid Network - Özellik Piramidi Ağı
FPV	: First Person Of View - Birincil Kişi Görüş Açısı
GLCM	: Gray Level Co-Occurrence Matrix - Gri Seviye Birlikte Oluşum Matrisi
GPS	: Global Positioning System -Küresel Yer Belirleme Sistemi
GPU	: Graphics Processing Unit - Ekran Kartı
İHA	: İnsansız Hava Araçlar
IoU	: Intersection over Union – Kesişim Alanı / Birleşim Alanı
K-NN	: K-Nearest Neighbors - K-En Yakın Komşu
MLR	: Multiple Linear Regression - Çoklu Doğrusal Regresyon
MRI	: Magnetic Resonance İmaging - Manyetik Rezonans Görüntüleme
PAN	: Path Aggregation Network - Yol Toplama Ağı
PSO	: Particle Swarm Optimization - Parçacık Sürü Optimizasyonu
R-CNN	: Region-based Convolutional Neural Network - Evrişimli Sinir Ağları ile Bölge Bulma
RQ	: Respiratory Quotient - Solunum Katsayısı
SVM	: Support Vector Machine - Destek Vektör Makineleri
TSS	: Total Soluble Solids - Toplam Çözünür Katı Maddeler
PCA	: Principal Component Analysis - Temel bileşenler Analizi
VGG	: Visual Geometry - Görsel Geometri Grubu
YOLO	: You Only Look Once - Yalnızca Bir Kez Bakarsınız

ÖZET

YÜKSEK LİSANS TEZİ

İHA İLE MEYVELERİN OLGUNLAŞMASININ TAKİBİ VE ÇÜRÜK TEŞHİSİ

Abdurrahman YILDIRIM

**Siirt Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Danışman : Doç. Dr. Melih KUNCAN
II. Danışman : Dr. Öğr. Üyesi Burak YILDIRIM**

2024, 71 Sayfa

Tarım, insanlar için temel bir üretim sektörü olarak kabul edilmekte olup, sürekli olarak teknolojik ilerlemeler sayesinde önemli gelişmeler kaydetmiştir. Tarım, ülkelerin kalkınmasında etkili bir unsurdur nitekim ekonomisi tarıma dayalı olan bir çok ülke vardır. Tarımsal ekonomik ilerlemenin artırılabilmesi için modern ve teknolojik yöntemlerin kullanılması gerekmektedir. Bunun sonucunda tarımsal verimde önemli bir artış sağlanır ve ülkelerin ekonomisine büyük destek olur. Meyvelerin verimliliğinin artırılması, olgunlaşmış ürünlerin kalitesini ve miktarını iyileştirerek tüketicilerin fiziksel sağlığını ve satın alma motivasyonlarını etkileyebilir. Ayrıca, piyasa fiyatının belirlenmesinde de önemli bir faktördür.

Bu tez çalışması, tarım sektöründe meyve tespiti, analizi ve sayımı konularında YOLOv8 evrişimsel yapay sinir ağı modelinin etkinliğini araştırmaktadır. Çalışmada toplam 2223 görsel kullanılarak dört farklı meyve türü olan Elma, Portakal, Muz ve Nar sınıfları üzerinde çalışılmıştır. Modelin belirgin başarısı, özellikle meyvelerin olgunlaşma aşamalarını doğru bir şekilde belirleme yeteneği olarak öne çıkmaktadır. Eğitim süreci 60 döngü boyunca gerçekleştirilmiş olup, öğrenme hızı 2,5 ms olarak belirlenmiştir. Eğitim sürecinde modelin kayıp değeri sürekli olarak azalırken doğruluk değeri artmıştır. Detaylı değerlendirmeler sonucunda, modelin meyve türleri bazında başarı oranları şu şekildedir: Elma için %95,3, Portakal için %98,9, Muz için %93,8 ve Nar için %98,8. Modelin genel başarı oranı %97,09 olarak hesaplanmıştır, bu da modelin karmaşık ve değişken meyve özelliklerini doğru bir şekilde sınıflandırma yeteneğini vurgulamaktadır.

Elde edilen sonuçlar, YOLOv8 modelinin tarım sektöründeki meyve tespiti ve sınıflandırma görevlerinde güvenilir bir performans sergileyebildiğini ve çeşitli meyve türlerini başarıyla ayırt edebildiğini göstermektedir. Ayrıca, İnsansız Hava Aracı (İHA) tarafından elde edilen görüntülerin deneysel analizi, YOLOv8 modelinin tarımsal uygulamalarda etkin bir şekilde kullanılabilirliğini ortaya koymuştur. Model, farklı meyve konumlarındaki tespiti, nitel analizi ve sayımını içeren çeşitli tarımsal uygulamalarda başarı elde etmiştir. Bu bulgular, modelin tarım sektöründe İHA görüntülerini analiz ederek meyve tespiti konusunda güvenilir bir performans sergilediğini ve tarımsal uygulamalarda etkili bir araç olarak kullanılabileceğini vurgulamaktadır.

Anahtar Kelimeler: Evrişimsel Yapay Sinir Ağı, İHA (İnsansız Hava Aracı), Meyve Analizi, Meyve Sayımı, Tarımsal Ekonomik İlerleme, YOLOv8

ABSTRACT

MS THESIS

MONITORING THE MATURATION OF FRUITS AND DIAGNOSIS ROTTEN WITH UAV

Abdurrahman YILDIRIM

**The Graduate School of Natural and Applied Science of Siirt University
The Degree of Master of Science
In Electrical-Electronics Engineering**

Supervisor : Assoc. Prof. Dr. Melih KUNCAN

Second Supervisor : Assist. Prof. Dr. Burak YILDIRIM

2024, 71 Pages

Agriculture is considered a fundamental sector of production for humanity, having continuously advanced through technological innovations. Indeed, many countries with economies based on agriculture exist. To enhance agricultural economic progress, modern and technological methods must be employed. As a result, significant increases in agricultural productivity can be achieved, thereby providing substantial support to national economies. Improving the efficiency of fruit production can enhance the quality and quantity of ripe products, influencing consumers' physical health and purchasing motivations. Additionally, it plays a crucial role in determining market prices.

This thesis study investigates the effectiveness of the YOLOv8 convolutional artificial neural network model on fruit detection, analysis and counting in the agricultural sector. A total of 2223 images were used as the training set. The study was conducted on classes such as Apple, Orange, Banana and Pomegranate, which include four different types of fruits. The outstanding success of the model is especially evident in its ability to successfully determine fruit ripening stages. The training process took place over 60 cycles, and the learning speed was determined as 2,5 ms. During training, the loss value of the model continuously decreased and the accuracy value increased. As a result of detailed evaluations, the success rates achieved by the model on the basis of fruit types are as follows: 95,% for Apple, 98,% for Orange, 93,8% for Banana and 98.8% for Pomegranate. The overall success rate of the model was determined to be 97,09%, which highlights the model's ability to accurately classify complex and variable fruit characteristics.

The findings indicate that the YOLOv8 model can demonstrate reliable performance in fruit detection and classification tasks within the agricultural sector, successfully distinguishing between various fruit types. Furthermore, the experimental analysis of images obtained by Unmanned Aerial Vehicles (UAVs) has highlighted the effective usability of the YOLOv8 model in agricultural applications. The model has achieved success in various agricultural applications, including detection, qualitative analysis, and counting of fruits in different locations. These findings underscore the model's capability to reliably perform fruit detection from UAV images in the agricultural sector, positioning it as an effective tool for agricultural applications.

Keywords: Agricultural Economic Progress, Convolutional Artificial Neural Network, Fruit Analysis, Fruit Counting, UAV (Unmanned Aerial Vehicle), YOLOv8

1. GİRİŞ

Meyvelerin en yüksek kaliteyi sağlamak üzere sınıflandırılması ve bozulmuş miktarlarının yüzdesinin anlık olarak izlenmesi, arz ve sürekli artan talep dengesi çerçevesinde ürünlerin hızlı, güvenli ve verimli bir şekilde pazara sunulması açısından büyük önem arz etmektedir. Mevcut meyve sınıflandırma yöntemleri, belirli alanlarda kullanıcı gereksinimlerini tam olarak karşılayamamaktadır. Bu nedenle, ürünlerin tüketiciye zamanında ulaştırılmasında bazen sorunlar yaşanabilmektedir. Teknolojinin gelişmesiyle birlikte, tarımsal üretim girdilerinin çevresel etkilerini ve maliyetlerini azaltma gerekliliği her geçen gün artmaktadır. Meyvelerin sayılması, yetiştiricilerin verim tahmini yapması ve meyve bahçelerini yönetmesi açısından önemli bir görevdir. Etkili bir otomatik meyve algılama ve sayma algoritması, tarım işletmelerinin hasat süreçlerini optimize etme ve kolaylaştırma imkânı sunar. Yetiştiriciler, tarım arazilerindeki verim değişkenliğini daha iyi anlayarak iş gücü planlaması, depolama, paketlenme ve nakliye konusunda daha bilinçli ve ekonomik kararlar alabilirler. Meyve sınıflandırması, meyvelerin genişlik, uzunluk, ağırlık ve alan özelliklerine göre elektronik ortamda tasnif edilmesidir. Meyve sınıflandırma sistemlerinin temel prensibi, hesaplamalardan sonra meyvelerden elde edilen parametreler ve kullanılacak yöntemlerle sınıflama işleminin gerçekleştirilmesidir.

Tarımsal ürünlerin kalitesi (doku, renk, şekil, boyut, şeker içeriği ve besin değeri), pazar kabulünü belirler ve bu nedenle depolama ve hasat sonrası işleme (nakliye ve depolama koşulları gibi) üzerinde doğrudan veya dolaylı olarak etkisi vardır. Bu nedenle, tarımsal ürünlerin çoğu aşırı olgunlaşma aşamalarında çok hassastır. Bu nedenle, hasat edildikten sonra, kalite parametrelerine (sertlik, renk, boyut ve şekil) göre farklı sınıflara ayrılmalı ve tüketiciler için hemen pazara gönderilmelidir.

Bunun sonucunda tarımsal verimde önemli bir artış sağlanır ve ülkelerin ekonomisine büyük destek olur. Meyvelerin verimliliğinin artırılması, olgunlaşmış ürünlerin kalitesini ve miktarını iyileştirerek tüketicilerin fiziksel sağlığını ve satın alma motivasyonlarını etkileyebilir. Ayrıca, piyasa fiyatının belirlenmesinde de önemli bir faktördür. Meyvelerin bozulması birçok sebepleri vardı, bunlarında birkaç tanesi inceledi. birinci sebebi meyvenin sertliği , Meyvenin kabuk rengi ve meyvenin hastalığı bu sebeplerden dolayı meyvelerin ve sebzelerin bozulmuş olup olmadığını test ederiz.

1.1. Meyvelerin Bozulma Nedenleri

Meyvelerin bozulma nedenleri, birçok biyolojik ve çevresel faktöre bağlı olarak çeşitlilik göstermektedir. Bu bağlamda, meyve sertliği, meyvenin kabuk rengi ve meyvenin hastalıkları, bozulma süreçlerini etkileyen üç ana etken olarak öne çıkmaktadır.

- Meyve Sertliği

Taze meyvelerin kalite kriterlerinden biri de sert bir dokuya sahip olmalarıdır. Depolama süresi boyunca, ağırlık kaybına bağlı olarak sertliğin azalması beklenir. Araştırmacıların tarafından gerçekleştirilen bir çalışmada, farklı sıcaklıklarda muhafaza edilen meyvelerde, ağırlık kaybına bağlı olarak yumuşama gözlemlenmiştir. Deneme süresi boyunca görülen küçük artışlar, özellikle çok düşük sıcaklıklarda soğuk hasarı ve su kaybı nedeniyle meyvelerin elastik bir yapıya kavuşmasından sonra ortaya çıkmıştır (Akbulak ve Özer, 2003).

Dhall ve çalışma arkadaşlarının gerçekleştirdiği araştırmada, 12°C ve oda sıcaklığında vakumlanarak ve vakumlanmadan depolanan salatalıklarda, ayrıca 12°C'de vakumlanarak saklanan meyvelerde sertliğin daha iyi korunduğu tespit edilmiştir. Bu sonucun, vakumlama ile modifiye atmosfer koşulları yaratılarak yüksek nem sağlanmasından kaynaklandığı gösterilmiştir. Tan ve çalışma arkadaşları, meyvelerin muhafazası üzerine yaptıkları çalışmada, meyvelerin farklı bölgelerinde sertlik ölçümlerinin değişiklik gösterdiğine dikkat çekmişlerdir. Meyvenin üst kısmının daha sert, alt kısmının ise daha yumuşak bir kabuk yapısına sahip olduğu belirtilmiştir. Uç, bir meyvenin sertlik değerinin 7-8 farklı bölgeden alınan ölçümlerle belirlenmesi gerektiğini ve ortalama değerlerin değerlendirilmesi gerektiğini vurgulamıştır. Yapılan ölçümlerde, 4°C'de saklanan meyvelerin sertlik oranlarını 25°C'de saklanan meyvelere kıyasla daha iyi koruduğu belirlenmiştir (Dhall ve ark., 2012).



Şekil 1.1. Ağaçtaki meyvelerin sertleştiği gösteriliyor

- **Meyvenin Kabuk Rengi**

Taze ve olgun bir ürünün rengi, türüne, olgunluk seviyesine ve yaşlanma sürecine göre değişir. Taze kabul edilen bir elmanın siyah değil, canlı yeşil veya kırmızı olması beklenir. Depolama koşullarına bağlı olarak, zamanla oluşan bazı fiziksel ve kimyasal değişimler, meyvenin et ve kabuk renginde değişikliklere yol açacaktır.

Hasat sonrası renkteki değişim, olumlu veya olumsuz etkiler doğurabilir. Elmada kararmak, domateste yeşermek ve sert kavunda turuncu renk oluşumu gibi istenmeyen renk değişimleri bu duruma örnektir. Olgunlaşma sürecinde, ürünlerde klorofil miktarında azalma gözlemlenir (Anonim, 2016).Şekil1.2’de görüldüğü gibi meyvenin kabuk renginin meyvenin bozulduğunu gösteriliyor.



Şekil 1.2. Ağaçtaki meyvelerin kabuk rengi olumsuz gösteriliyor

- **Meyvenin hastalığı**

Bakteriler nemli ve serin havalarda gelişim gösterir. Bu sebeple enfeksiyonlarını genellikle mart-nisan aylarında yaprak sapları ve genç sürgünler üzerinde gerçekleştirirler. Sıcak ve kurak dönemlerde ise pasif bir duruma geçerler (Anonim, 2016). Genç sürgünlerde hastalığın belirtileri şunlardır: yaprak saplarında siyahlaşma, yaprak yüzeyinde lekelerin oluşması, yaprakların turgorunu kaybetmesi ve orta damar boyunca kıvrılarak aşağı doğru sarkması, Hastalık genç sürgünlerde soğuktan etkilenmiş gibi zarar verir; sürgünler hızla kurur ve yaprakları dökülür. Hastalığın ilerleyen evrelerinde siyah lekeler yaprak sapından dala doğru yayılır, daldaki lekeler oval ve uzun şekildedir. Yapraklar dökülür ve zamanla lekeler kırmızı-kahverengi renge döner. Eski lekeler zamanla çatlayarak daldan ayrılır (Anonim, 2016).



Şekil 1.3. Ağaçtaki meyvelerin hastalığı gösteriliyor

1.2. Araştırmanın Amacı

Bu çalışmanın temel amacı, meyvelerin olgunlaşıp satışa hazır hale gelene kadar toplam meyve üretimini tahmin etmeyi, bozulmuş meyveleri tespit etmeye ve bozulmaya yatkın meyve tespit etmeyi, bu ürünleri bozulmadan önce hasat etmek için ilgili kişiye bildirmeyi amaçlayan bir proje geliştirmeyi hedefliyoruz. Meyve ağaçlarından elde edilen görüntülerin analizi, İnsansız Hava Araçları'nın görüntü işleme tekniklerinin kullanımıyla gerçekleştirilecektir. çalışmanın başarısı, meyve hasadı ve satış stratejilerini iyileştirme, kaynakları daha verimli kullanma ve genel olarak tarım sektöründe sürdürülebilir verimlilik artışını yansıtmaya kapasitesine sahiptir. Bu kapsamda belirlenen hedefler şunlardır:

1. Tarafımızca belirlenen bazı meyvelerin dalında iken İHA tarafından toplanan görüntüleri üzerinden geliştirilecek görüntü işleme algoritmalarıyla bu meyvelerin olgunlaşmasının takibini ve çürük durumlarını analiz etmek.

2. Geliştirilecek YOLOv8 modelinin görüntü işleme algoritmalarının performansını literatürdeki etkili algoritmalarla karşılaştırmayı amaçlıyoruz.

3. Elde edilen verilere dayanarak meyvelerin gelişim süreçlerini raporlamak.

Bu tez çalışmasında, İHA destekli görüntü işlemleri kullanılarak elde edilecek dijital veriler, ağaçlarından alınan meyve görüntüleri üzerinde kullanılarak, meyvelerin ağaçlarında iken hasat edilmeden önce döndürülmesi ve olgunlaşmanın belirlenmesi sağlanacak. Tamamen evrimsel bir ağa dayalı nokta dedektörü, görüntülerdeki aday bölgeleri çıkaracaktır. Daha sonra ikinci bir evrimsel ağa dayalı bir sayma algoritması,

her bölgedeki meyve sayısını tahmin edecektir. Son olarak algoritmaların, olgun meyvelerin sayısı ile bozulmuş meyvelerin sayısına ilişkin bir tahmin atayacaktır.

Bu amaçlar doğrultusunda gerçekleştirilecek olan çalışma, tarım sektöründe daha etkili ve verimli bir bozulma yönetimi sağlamayı hedeflemektedir.

1.3. Araştırmanın Önemi

Tarım, insanlar için temel bir üretim sektörü olarak kabul edilmekte olup, sürekli olarak teknolojik ilerlemeler sayesinde önemli gelişmeler kaydetmiştir. Tarım, ülkelerin kalkınmasında etkili bir unsurdur nitekim ekonomisi tarıma dayalı olan birçok ülke vardır. Tarımsal ekonomik ilerlemenin artırılabilmesi için modern ve teknolojik yöntemlerin kullanılması gerekmektedir. Bunun sonucunda tarımsal verimde önemli bir artış sağlanır ve ülkelerin ekonomisine büyük destek olur. Meyvelerin verimliliğinin artırılması, olgunlaşmış ürünlerin kalitesini ve miktarını iyileştirerek tüketicilerin fiziksel sağlığını ve satın alma motivasyonlarını etkileyebilir. Ayrıca, piyasa fiyatının belirlenmesinde de önemli bir faktördür.

Günümüzde, tarımın modernizasyonu ve gıda endüstrisindeki ilerlemeler, çeşitli disiplinler arasında işbirliğini vurgulamaktadır. Tez çalışma kapsamında İHA kullanarak meyvenin erken hastalık teşhisini gerçekleştirme konusunda bahçecilik, tarım, bilgisayar bilimi ve gıda teknolojisi uzmanlarını bir araya getiriyoruz. Bu yaklaşım, erken hastalık tespiti, sınıflandırma ve derecelendirme sistemleri ile yenilikçi tahribatsız test tekniklerinin geliştirilmesinde çığır açmıştır (Gül ve ark.,2021). Çalışmada, meyve ürünlerinin verimini artırmak ve daha iyi kaliteyi tüketiciye ulaşmasını sağlamayı hedefleyerek bu alanlardaki iş birliklerinin somut bir örneğini sunmaktadır.

Çalışma kapsamında daha önceki çalışmalara dayanarak büyük ekili meyve tarlaları en düşük maliyetle, en kısa sürede incelenip değerlendirilebilme ve en yüksek performansı nasıl elde etmektir.

İHA kullanılarak görüntü işleme sayesinde meyvelerin olgunlaşmanın takibi ve hangi meyvelerin bozulmaya yatkın olduğunu belirleyecek ve bu bilgiden yararlanarak o meyvelerin hasadını ve bozulmadan önce bu halleriyle nasıl değerlendirileceğini öğrenip raporlayacağız.

1.4. Arařtırmanın Motivasyonu

- **Tarım verimlilięi ve kalitesi üzerine etkileri:** İHA'lar, tarım sektöründe kullanıldığında, meyve bahçelerini izleme ve yönetme yeteneklerini önemli ölçüde artırabilir. Bu bağlamda tez çalışma kapsamında, meyve olgunlaşma süreçlerinin daha etkili bir şekilde takip edilmesini ve bu süreçlerin tarım verimlilięi ve kalitesi üzerindeki potansiyel etkilerini inceleyebilir.

- **İHA Teknolojisinin Tarım Pratięine Entegrasyonu:** İHA'lar, çeşitli sensörler ve kameralar aracılığıyla tarım alanlarını detaylı bir şekilde gözlemleyebilir. İHA teknolojisinin tarım süreçlerine nasıl entegre edilebileceğini ve bu entegrasyonun meyve üretimi üzerindeki akademik boyutta etkilerini anlamayı amaçlar.

- **Bozulmuş meyvelere erişimi azaltma olasılığı üzerinde çalışmak:** Bu tez çalışmasında, İHA'lar, tarım alanlarını düzenli olarak izleyerek bozuk meyvelerin erken teşhis edilmesine katkıda bulunabilir.

- **Veri Analitięi ve Yapay Zekâ Uygulamaları:** İHA'lar tarafından sağlanan büyük veri setleri, yapay zekâ algoritmaları ile analiz edilebilir. Meyve olgunlaşması ve çürük teşhisiyle ilgili verilerin daha derinlemesine incelenmesine ve gelecekteki tahmin modellerinin akademik açıdan geliştirilmesine katkı sağlar.

Bu motivasyonlar tez çalışma kapsamında , tarım sektöründe önemli bir bilimsel alanı temsil etmektedir. Tarım verimlilięi, kalitesi, sürdürülebilirlik, hastalık kontrolü ve teknolojik entegrasyon gibi kritik konular üzerinde derinlemesine bir anlayış sağlaması beklenmektedir.

2. LİTERATÜR ARAŞTIRMASI

Meyvelerin olgunlaşma ve çürük teşhisi, geleneksel gözlem yöntemlerinin sınırlamaları nedeniyle yapay zeka ve çağdaş teknolojilerin kullanımıyla daha hızlı ve doğru bir hale gelmiştir. İnsanlar, meyve olgunlaşma durumunu renk, şekil, sertlik ve dokuya bakarak tahmin edebilirler. Benzer şekilde, çürüme belirtileri de kahverengi lekeler, yumuşaklık ve kötü koku gibi faktörlere dayanarak gözlemlenebilir. Ancak, bu yöntemlerin doğruluğu sınırlıdır ve gelişmiş teknolojilerin ihtiyaçları karşılamada avantajlı olduğu durumlar ortaya çıkmıştır.

Günümüzde, meyve tespiti ve teşhisi alanında radyasyon, ultrasonik dalgalar, lazerler ve manyetik rezonans görüntüleme (MRI) gibi gelişmiş tekniklerin kullanılmasıyla daha sofistike yöntemlere yönelinmiştir. Bu teknikler, meyve özelliklerini invazif olmayan bir şekilde değerlendirmek için boyut, renk, doku, şeker içeriği ve kusur veya hastalıklar gibi faktörleri içerir. Araştırmacılar, yapay zeka destekli algoritmaların hızlı ve doğru meyve sınıflandırması, hastalık tespiti ve meyve raf ömrü tahminindeki potansiyelini keşfetmektedirler.

Bu multidisipliner yaklaşım, bahçecilik, tarım, bilgisayar bilimi ve gıda teknolojisi alanlarından uzmanları bir araya getirerek işbirliklerine olanak sağlamıştır. Bu işbirlikleri, erken hastalık tespiti, sınıflandırma sistemleri ve tahribatsız test tekniklerinin geliştirilmesinde önemli bir rol oynamaktadır. Son yıllarda, tarım sektöründeki teknolojik gelişmeler, sürekli bilimsel araştırmalar ve yeni yöntemlerin benimsenmesi, tarım uygulamalarında önemli kolaylıklar sağlamıştır. Şimdi bu gelişmeleri daha detaylı bir şekilde inceleyelim.

Chu ve çalışma arkadaşları, elma tespitinde doğru ve sağlam sonuçlar elde etmek amacıyla "Bastırma Maskesi R-CNN" adını verdikleri yeni bir derin öğrenme tabanlı çerçeve geliştirmişlerdir. Bu çalışmada, renkli bir kamera kullanılarak farklı aydınlatma koşulları altında elde edilen kapsamlı bir elma bahçesi veri seti kullanılmıştır. Standart Mask R-CNN'ye bir bastırma dalı eklenerek geliştirilen bu yeni çerçevenin performansı değerlendirilmiştir. Yapılan değerlendirmeler sonucunda, Bastırma Maskesi R-CNN ağının %90,5 başarı oranı ile üstün sonuçlar elde ettiği gösterilmiştir (Chu ve ark., 2021). Bu çalışmanın sonuçları, Elma tespiti gibi zorlu ve değişken aydınlatma koşullarında bile yüksek doğruluk sağlayabilen bir modelin mümkün olduğunu ortaya koymaktadır.

Li ve arkadaşlarının yaptığı çalışmada, otomatik elma sıralama görevinde belirli elma türlerinin sınıflandırılması amacıyla önerilen bir sığ evrişimli sinir ağı (CNN) mimarisi incelenmektedir. Çalışma kapsamında belirli sayıda elma görseli etiketlenmiş ve bu görseller veri büyütme işlemiyle eğitim verileri haline getirilmiştir. Caffe çerçevesi kullanılarak eğitim ve parametre optimizasyonu gerçekleştirilmiştir. Deney sonuçları, elma görüntülerinin tıkanma durumunda dahi sınıflandırma doğruluğunun %92'ye ulaştığını göstermektedir. Blok oylama yöntemi kullanılarak önerilen yöntem, dal ve yapraklar, çürük lekeler ve diğer elma türlerinden kaynaklanan parça tıkanması durumlarında da başarılı sonuçlar elde edebilmiştir. Önerilen sığ ağ, az sayıda parametreye sahip olup sınırlı bir veri kümesiyle aşırı uyuma karşı direnç göstermektedir. Bu çalışma, akıllı görsel Nesnelerin İnterneti'nde sınıflandırmayla ilgili görevlere alternatif bir yaklaşım sunmakta ve derin sinir ağlarının karmaşıklığını azaltarak gücünü korumaktadır (Li ve ark., 2020). Bu çalışmanın bulguları, sınırlı veri setleriyle bile yüksek doğrulukla çalışan ve aşırı uyuma karşı direnç gösteren sığ evrişimli sinir ağlarının, Nesnelerin İnterneti ve benzeri uygulamalarda etkili bir şekilde kullanılabileceğini göstermektedir.

Kesler ve çalışma arkadaşlarının gerçekleştirdiği çalışmada, muz meyvesinin yedi farklı olgunlaşma aşamasının yapay zekâ yardımıyla belirlenmesi hedeflenmiştir. Bu çerçevede, muz meyvesi dalından ayrıldıktan sonra her olgunlaşma evresinde fotoğrafları çekilerek 700 görüntüden oluşan bir veri seti oluşturulmuştur. Sınıflandırma sürecinde AlexNet gibi derin öğrenme yöntemleri kullanılmış ve %96,63 doğruluk oranı elde edilmiştir (Kesler ve ark., 2023). Bu çalışma, muz meyvesinin olgunlaşma sürecini doğru bir şekilde izlemek için yapay zekâ tabanlı bir yöntemin etkili olduğunu göstermektedir. AlexNet gibi derin öğrenme mimarilerinin kullanımı, yüksek doğruluk oranları elde edilmesini sağlamış ve bu tür sınıflandırma görevleri için güçlü bir araç olduğunu kanıtlamıştır.

Ranjan Sapkota ve Karkee'nin çalışmasında, YOLOv8 ve Mask R-CNN gibi makine öğrenimi modellerinin performansları karşılaştırılmıştır. İki farklı meyve bahçesi koşulu altında gerçekleştirilen deneyler, YOLOv8'in Mask R-CNN'ye göre daha yüksek hassasiyet ve hatırlama oranlarına sahip olduğunu ortaya koymaktadır. Elde edilen verilerle eğitilen YOLOv8 modeli, tanımlamada %90 başarı elde etmiştir. Karşılaştırıldığında, aynı veri kümesi için kullanılan Mask R-CNN modeli %81 başarı

sağlamıştır. Olgunlaşmamış yeşil elmaların tanımlandığı ikinci veri seti üzerinde YOLOv8, %93, Mask R-CNN ise %85 başarı göstermiştir (Ranjan Sapkota ve Karkee, 2023). Bu çalışma, YOLOv8 modelinin, özellikle meyve tespiti ve sınıflandırma görevlerinde Mask R-CNN modeline göre üstün performans gösterdiğini kanıtlamaktadır.

Bargoti ve Underwood yapmış olduğu çalışmada , mango, badem ve elma gibi meyve bahçelerinde meyve tespiti bağlamında kullanılan son teknoloji ürünü bir nesne tespit çerçevesi olan Faster R-CNN'yi tanıtmaktadır. Meyve bahçeleri arasında bilgi aktarımının, Derin Evrişimli Sinir Ağı'nın doğrudan ImageNet özelliklerinden başlatılmasına kıyasla ihmal edilebilir performans artışına katkıda bulunduğu tespit edilmiştir. Son olarak, Faster R-CNN çerçevesi için bir döşeme yaklaşımı tanıtılmıştır, bu da görüntü başına 100-1000 arasında meyve içeren meyve bahçesi verileri üzerinde çalışmak üzere tasarlanmıştır. Bu çalışma, elma ve mango için % 90 puanı ile meyve bahçeleri için performansını elde etmiştir (Bargoti ve Underwood, 2017).

Mo ve arkadaşları Faster R-CNN algoritması kullanılarak gerçekleştirilen obje algılamasının Elma ve Portakal nesnelere üzerindeki performansını değerlendirmeyi amaçlamaktadır. Çalışma kapsamında, Faster R-CNN algoritması, Elma ve Portakal nesnelere için eğitilmiş ve test edilmiştir. Performans ölçütleri olarak algılama doğruluğu kullanılmıştır. Elde edilen sonuçlara göre, Elma nesnesi için %94, Portakal nesnesi için ise %90 algılama doğruluğu elde edilmiştir (Mo ve ark., 2018).

Wang ve arkadaşlarının yaptığı araştırma, bilgisayarlı görüntü işleme ve yapay zeka uygulamalarında yaygın olarak kullanılan obje algılama algoritmalarının performansını değerlendirmeye odaklanmıştır. YOLO, Fast R-CNN, Faster R-CNN, YOLOv2, YOLOv3 ve Improved Faster R-CNN gibi önde gelen obje algılama algoritmaları, Elma ve Portakal gibi temsil edici nesnelere üzerindeki algılama doğruluğu bakımından karşılaştırılmıştır. Çalışma, Improved Faster R-CNN'nin hem Elma (%92,51) hem de Portakal (%90,73) nesnelere için en yüksek doğruluk oranlarına sahip olduğunu gösterirken, YOLOv3'ün özellikle Elma için yüksek doğruluk oranlarına (%91,89) ve Portakal için etkileyici bir performansa (%88,70) sahip olduğunu belirlemiştir (Wang ve ark., 2019).

Dulkadir ve Gültekin yaptıkları çalışmada çoklu robotlu otonom tarımsal hasat sistemlerinde muz olgunluk seviyesi sınıflandırmasını gerçekleştirmek için derin öğrenme temelli yöntemlerin kullanımını ele almaktadır. Özellikle, robotik sistemlerdeki

sınırlı işlem kaynaklarına uygun küçük modellerin karşılaştırılması yapılmıştır. YOLOv5s, YOLOv8n ve YOLOv8m modelleri, muz olgunluk seviyelerini belirlemek için kullanılan veri kümesi üzerinde eğitilmişlerdir ve her bir sınıf için ortalama olarak 0,9 üzerinde kesinlik değerleri elde ederek başarılı bir sınıflandırma performansı sergilemişlerdir. Yapılan sınıflandırma çalışması, YOLOv5s, YOLOv8n ve YOLOv8m modellerinin %90 , %92 ve %93 başarı oranlarına ulaşarak etkileyici bir performans sergilediğini göstermiştir (Dulkadir ve Gültekin., 2023).

Dhakate ve Ingole Hindistan'ın birçok eyaletinde yüksek verimle yetişen ve kar elde edilen nar meyvesinin, çeşitli hastalıkların bitkilere zarar vermesi nedeniyle düşük ürün verimi ile karşılaşmasını ele almaktadır. Çalışmada, görüntü işleme ve sinir ağı yöntemleri kullanılarak fitopatolojinin ana konularından biri olan hastalık tespiti ve sınıflandırılması için bir çözüm önerilmektedir. Nar yaprakları, mantar, bakteri ve iklim koşullarına bağlı olarak ortaya çıkan çeşitli hastalıklardan etkilenebilir, bunlar arasında Bakteriyel Yanıklık, Meyve Lekesi, Meyve Çürüklüğü ve Yaprak Lekesi bulunmaktadır. Geliştirilen sistem, renkli görüntüler üzerinde k-ortalama kümeleme segmentasyonu ve GLCM yöntemiyle doku özelliklerinin çıkarılması gibi işlemleri içermektedir. Bu yöntem, genel doğruluk oranı %90 olarak belirlenen hastalıkların doğru bir şekilde tespiti ve sınıflandırılmasını gerçekleştirmektedir (Dhakate ve Ingole, 2015).

Kantale ve Thakare nar bitkilerindeki hastalıkları tanıma ve makine öğrenmesi yaklaşımını kullanarak bireysel sınıflarda sınıflandırma yapma amacını taşımaktadır. Görüntü işleme teknikleri kullanılarak, bitki hastalıkları için Ada-boost sınıflandırıcısı kullanılmıştır. PSO (Parçacık Sürü Optimizasyonu) algoritması, özellik optimizasyonunu gerçekleştirmek üzere kullanılmış ve çoklu sınıf sınıflandırması gerçekleştirilmiştir. Yapılan testler, Ada-boost algoritması ile elde edilen doğruluk oranının %92,9'a ulaştığını göstermektedir (Kantale ve Thakare, 2020).

Saragih ve Emanuel muzun olgunluğunu sınıflandırmak için CNN'ni kullanmaktadır. Muzun olgunluğu, olgunlaşmamış/yeşil, sarımsı-yeşil, olgunlaşma ortası ve aşırı olgunlaşma olmak üzere dört sınıfa ayrılmıştır. MobileNet V2 ve NASNetMobile adlı önceden eğitilmiş iki model, bilgisayarlı görme ve makine öğrenimi tekniklerinin uygulanmasında kullanılmıştır. Deney, Google Colab ortamında ve çeşitli kütüphaneler (OpenCV, Tensorflow, scikit-learn) kullanılarak gerçekleştirilmiştir. Elde edilen sonuçlar, MobileNet V2 modelinin, NASNetMobile modeline göre daha yüksek doğruluk

ve daha hızlı yürütme süresi sunduğunu göstermektedir. Ulaşılan en yüksek doğruluk oranı %96,18'dir (Saragih ve Emanuel, 2021).

Kızılboğa'nın yaptığı çalışmada, görsel hasar bırakan elma ve ayva yüzeyindeki hastalıkların sınıflandırılması amacıyla evrişimli derin ağ modelinden oluşan 10 katmanlı bir model geliştirilmiştir. Ayrıca, aktarımlı öğrenme kullanılarak, hazır modellerden VGG16, Inception ve ResNet derin ağ mimarileri de entegre edilmiştir. Elde edilen öznelik vektörleri, Geleneksel makine öğrenme yöntemleri arasında SVM ve K-En Yakın Komşu gibi yöntemlerle sınıflandırılmıştır. Çalışma, görsel hasar tespiti konusunda gerçek zamanlı bir sistem geliştirmeyi amaçlamıştır. Geliştirilen sistem, elma ve ayva hastalıklarını tanıma konusunda %88 başarı elde ederek, klasik makine öğrenme yöntemlerinden daha üstün bir performans sergilemiştir (Kızılboğa, 2021).

Zhou ve arkadaşları, elma meyvelerinin sayısını tahmin etmek amacıyla geliştirilen iki meyve tanıma algoritmasını inceledikleri bir çalışma gerçekleştirmişlerdir. Bu algoritmalar, genç, küçük yeşil meyvecikler ile olgun kırmızı elma meyveleri olmak üzere iki meyve gelişim dönemini renk özelliklerine dayalı olarak sınıflandırmaktadır. Çalışmada, doğal ışık altında beyaz bir perde arka planı ve kırmızı bir kalibrasyon küresi kullanılarak çekilen elli ağacın iki farklı gelişim aşamasındaki görüntüler üzerinden algoritmaların performansı değerlendirilmiştir. Meyve sayma algoritması ile değerlendirilen ağaç başına meyve sayısı ile elle sayılan meyveler arasında %80 ve %85 gibi yüksek başarı oranları elde edilmiştir. Meyve olgunlaşma döneminde, tanıma algoritmaları tarafından değerlendirilen meyve sayısı ile gerçek meyve verimi arasında %70 civarında bir yakınlaşma tespit edilmiştir. Ayrıca, gerçek ve tahmin edilen elma verimi arasında %71 gibi güçlü bir ilişki gözlemlenmiştir (Zhou ve ark., 2012).

Linker ve arkadaşlarının çalışması, meyve bahçelerinde renkli görüntüler kullanarak elma sayısını tahmin etmeye yönelik bir algoritma geliştirme ve doğrulama çabalarını detaylı bir şekilde sunmaktadır. Algoritma, genç, küçük yeşil meyve aşamalarını ile olgun kırmızı elma meyvelerini renk özelliklerine dayalı olarak sınıflandırarak çalışmaktadır. Dört aşamalı algoritma, elma olasılığı yüksek olan pikselleri tespit eder, tohum alanları oluşturur, bu alanların konturlarını ayırır ve elde edilen yayları birleştirerek elma modeliyle karşılaştırır. Yapılan iki ayrı veri seti değerlendirmesi, algoritmanın doğru tespit oranının %85'e kadar ulaşabildiğini, ancak aydınlatma ve renk doygunluğunun hatalı pozitif tespit oranını etkilediğini ortaya

koymaktadır. Özellikle düşük pozlanmış ve dağınık ışık altında çekilen görüntülerde başarı oranının %95'e kadar çıkarken yanlış pozitif tespit oranının %5'in altında kaldığı belirlenmiştir (Linker ve ark., 2012).

Devanna ve arkadaşları, kara araçlarının görüşe dayalı algılama sistemleri ile donatılmasının, meyve bahçelerinde hassas tarım görevlerini yerine getirmek için zengin bir bilgi kaynağı sağlama potansiyeli üzerinde durmaktadır. Çalışma, özellikle tüketici sınıfı bir kamerayla donatılmış bir çiftçi robotu kullanarak otomatik nar tespiti için bir yarı denetimli derin öğrenme çerçevesi sunmaktadır. Geleneksel derin öğrenme yöntemlerindeki zaman alıcı ve emek yoğun görüntü etiketleme süreçlerini aşmak amacıyla, önerilen sistem, hedef görev için ince ayar yapabilen yeni bir çok aşamalı transfer öğrenme yaklaşımını benimsemektedir. Çalışma, kontrollü koşullarda meyvelerin işlenmesinden başlayarak, daha karmaşık saha senaryolarında etkili bir şekilde meyve segmentasyonuna genişletilebilecek bir çerçeve sunmaktadır. Gerçekleştirilen deneysel testler, nar bahçesinde kullanılan DeepLabv3+ (Resnet18) mimarisi ile elde edilen %86,42 F1 puanı ve %97,94 IoU gibi doğru segmentasyon sonuçlarını ortaya koymaktadır (Devanna ve ark., 2022).

Asriny ve arkadaşları tarafından sunulan çalışma, bilgisayar görüntüsü geliştirilmesi amacıyla Evrişimli Sinir Ağı kullanarak portakal görüntülerini belirli özelliklere göre sınıflandırmak üzere bir sınıflandırma modeli önermektedir. Model, "İyi-portakal-derece-1", "İyi-portakal-derece-2", "Olgunlaşmamış-portakal", "Çürük-portakal" ve "Hasarlı-portakal" olmak üzere beş sınıfa portakalı meyveleri sınıflandırmaktadır. Toplam 1000 portakal görüntü, akıllı telefon kamerası kullanılarak elde edilmiştir ve her sınıf için eğitim verileri (%60), doğrulama verileri (%20) ve test verileri (%20) içeren bir veri setine bölünmüştür. Modelin doğruluğunu değerlendirmek amacıyla K-Fold Cross-Validation yöntemi kullanılmıştır ve çalışmada CNN'in gizli katmanının 256 düğümden oluştuğu belirtilmiştir. Yapılan deneyler sonucunda elde edilen başarı oranı %92,8 olarak belirlenmiştir (Asriny ve ark., 2020).

Nar sağlığının izlenmesi amacıyla değerli bilgiler sağlamaktadır. Bu çerçevede, önceki literatür çalışmalarında, nar meyvelerinin olgunluk ve kaliteye göre tespiti ve sınıflandırılmasında Yolo-v3, CNN-LSTM ve DeepLabv3+ gibi çeşitli derin öğrenme modellerinin kullanıldığı çeşitli yaklaşımlar incelenmiştir. Bu çalışmada ise, Yolo-v7 yöntemi kullanılarak, nar meyvelerinin farklı büyüme aşamalarındaki tespiti ve beş ayrı

sınıfa (olgun, orta büyüme, erkenci, çiçek ve tomurcuk) sınıflandırılması hedeflenmiştir. Küçük etiketlerin zorluklarına rağmen, önerilen yöntem, 587 görüntü ve 1109 etiket içeren test veri setinde sırasıyla 0,888, 0,916, 0,943, 0,824 performans değerleri elde ederek tatmin edici sonuçlar ortaya koymuştur (Nergiz, 2023).

Jayanth ve arkadaşları tarafından sunulan çalışma, bilgisayarlı görü ve derin öğrenme yöntemleri kullanılarak tazelik derecelendirme sisteminin kapsamlı bir analizi sunulmaktadır. Dijital fotoğrafların görsel analizi, ResNet, VGG ve GoogLeNet gibi çeşitli derin öğrenme yöntemlerinin kullanıldığı bir model temelinde gerçekleştirilmiştir. İlgi alanının için AlexNet temel alınan YOLO kullanılmıştır. Önerilen model, meyve kalitesini hızlı ve doğru bir şekilde değerlendirmek için çeşitli evrişimli sinir ağı türlerine dayanmaktadır. Model, sınıflandırma için belirli, karmaşık ve faydalı görsel özellikleri etkili bir şekilde yakalamaktadır. Test sonuçlarına göre, önerilen modelin doğru sınıflandırma oranı elma, muz ve portakal için sırasıyla %93,5, %90,5 ve %92,5 olarak belirlenmiştir (Jayanth ve ark., 2023).

Mazen ve Nashat tarafından yapılan çalışmada, farklı muz salkımlarının olgunlaşma aşamalarını doğru bir şekilde sınıflandırmak amacıyla görüntü işleme araçlarının tasarlanması ve uygulanması gerekliliği vurgulanmaktadır. İlk olarak, dört sınıflı bir ev yapımı veritabanı hazırlanmıştır. Daha sonra, muz meyvesinin olgunlaşma aşamalarını sınıflandırmak ve tanımlamak için renk, kahverengi lekelerin gelişimi ve Tamura istatistiksel doku özelliklerini içeren yapay sinir ağı tabanlı bir çerçeve önerilmiştir. Çalışmada elde edilen sonuçlar ve performans, Naive Bayes, SVM, k-en yakın komşular, karar ağacı ve diskriminant analizi gibi çeşitli sınıflandırıcı tekniklerle karşılaştırılmıştır. Çalışmanın sonuçları, önerilen sistemin %97,75 genel tanıma oranına sahip olduğunu göstermektedir (Mazen ve Nashat, 2019). Bu çalışma, muz meyvesinin olgunlaşma aşamalarını sınıflandırmak için renk, kahverengi lekeler ve doku özelliklerini kullanarak yüksek doğruluk oranları elde edebilen bir yapay sinir ağı tabanlı çerçevenin etkinliğini göstermektedir. Farklı sınıflandırıcı tekniklerle karşılaştırıldığında, önerilen sistemin üstün performans sergilediği ve %97,75 genel tanıma oranı ile güvenilir bir çözüm sunduğu ortaya konulmuştur.

Rajkumar ve arkadaşları tarafından sunmuş olduğu çalışma, muz meyvelerinin olgunlaşma/olgunluk durumuna göre zNose aroma tespit tekniği kullanılarak sınıflandırılması amacıyla bir araştırma gerçekleştirilmiştir. Çalışma kapsamında, muz

meyvelerinin kalite parametreleri olan solunum katsayısı (RQ), toplam çözünür katı maddeler (TSS), nem içeriği ve her olgunlaşma/olgunluk aşamasındaki sertlik belirlenmiş ve elde edilen sonuçlar zNose lezzet verileriyle ilişkilendirilmiştir. Muz meyvelerinin olgunlaşma/olgunluk aşamalarını belirlemek ve ayrıca gözlemlenen verilerin değişkenliğini test etmek için temel bileşen analizi PCA kullanılmıştır. Meyve kalite parametrelerini tahmin etmek amacıyla çoklu doğrusal regresyon MLR kullanılarak modeller oluşturulmuştur. Elde edilen sonuçlara göre, tahmin edilen solunum katsayısı, toplam çözünür katı maddeler, nem içeriği ve sıklığa karşılık gelen belirleme katsayıları (r^2) sırasıyla 0,93, 0,94, 0,96 ve 0,95 olarak bulunmuştur (Rajkumar ve ark., 2015).

Dewi ve arkadaşlarının çalışması, muz çeşitlerinin belirlenmesinde cep telefonu kamerasıyla çekilen görüntülerin bilgisayarlı görüntü işleme yöntemleriyle analiz edilmesini ele almaktadır. Çalışmada, muz parmaklarının şekil ve kabuk dokusu özellikleri gibi ayırıcı özellikler kullanılmıştır. Şekil özellikleri morfolojik tanımlayıcılar ve dışbükey gövde kullanılarak, kabuk dokusu özellikleri ise yerel ikili desen LBP yöntemiyle elde edilmiştir. Muz çeşitlerinin ayırt edilmesinde aşırı öğrenme makinesi ELM sınıflandırıcısı kullanılmış ve toplamda 76 muz parmağı görüntüsü 3 katmanlı bir test setinde değerlendirilmiştir. Test sonuçları, şekil ve LBP özelliklerinin birlikte kullanılmasının, olgunlaşmamış Ambon ve Hijau muzlarını ayırt etmede %93'ün üzerinde yüksek doğruluk, kesinlik ve geri çağırma değerlerine sahip olduğunu göstermektedir (Dewi ve ark., 2022). Bu çalışma, görüntü işleme ve makine öğrenimi tekniklerinin tarımsal ürün sınıflandırma ve kalite kontrolü gibi uygulamalarda nasıl etkili bir şekilde kullanılabileceğini göstermektedir. Özellikle, cep telefonu gibi yaygın teknolojilerin kullanılmasıyla elde edilen görüntülerin analiz edilmesi, tarım endüstrisinde verimlilik ve doğruluk açısından önemli bir adım olarak değerlendirilmektedir.

Kumar ve arkadaşlarının gerçekleştirdiği çalışmanın temel amacı, Makine Zekası ve Dijital Görüntü İşleme tekniklerini birleştirerek manuel kalite değerlendirme süreçlerindeki zorlukları aşmaktır. Bu araştırma, mevcut derecelendirme kriterleriyle ilişkilendirilen yeni kalite parametrelerini ayrıntılı bir şekilde tanımlayarak, Nar meyvelerinin sınıflandırılması ve kalite değerlendirmesi için kapsamlı bir yaklaşım sunmaktadır. Ayrıca, çalışma EQA adını verdiği özgün bir metodolojiyi önermektedir. Bu metodoloji, yapay sinir ağlarıyla gerçekleştirilen araştırma sonuçlarının %97,83 doğruluk oranına ulaştığını belirlemiştir (Kumar ve ark., 2019). Bu araştırma, nar

meyvelerinin olgunluk durumunu ve kalitesini objektif bir şekilde deęerlendirmek için modern teknolojilerin etkili kullanımını vurgulamaktadır.

Mirhaji ve arkadaşları yapmış oldukları çalışma kapsamında , hassas tarım uygulamalarında önemli bir adım olan meyve yükü tahminini geliştirmeyi hedefledikleri çalışmalarında, portakal tespiti ve sayımı için YOLO tespit modellerini kullanmışlardır. Bu modeller, transfer öğrenme yöntemiyle adapte edilerek turuncu meyveleri RGB görüntülerde tespit etmek ve saymak üzere eğitilmiştir. Modelin performansı ve verim tahminlerinin doğruluęu, 1115 ağaçlı bir meyve bahçesinde incelenmiştir. Çalışma süreci, farklı aydınlatma koşullarında portakal ağaçlarının görüntü veri kümesinin oluşturulması, YOLO modellerinin eğitilmesi ve test edilmesi, modellerin deęerlendirilmesi ve meyve bahçesinin verim deęişim haritasının çıkarılması gibi üç aşamadan oluşmaktadır. Test sonuçlarına göre, YOLOv4'ün %90,8 mAP ile başarılı bir performans sergiledięi belirlenmiştir (Mirhaji ve ark., 2021). Bu çalışma, portakal tespiti ve sayımı için transfer öğrenme yöntemiyle adapte edilmiş YOLO modellerinin yüksek doğruluk oranlarıyla kullanılabilceęini göstermektedir.

Lee'nin gerçekleştirdięi çalışmada, YOLOv2 modeli kullanılarak meyvelerin özelliklerine göre sınıflandırılması ve üç farklı tipe ayrılması amaçlanmıştır. Deneyde, 640 adet mandalina görüntüsü kullanılarak üç farklı sınıfa ait model deęerlendirmesi yapılmıştır: normal, çürük ve olgunlaşmamış mandalina portakalların Deney sonuçları, öğrenme modelinin doğruluęunun öğrenme sayısına baęlı olarak deęişkenlik gösterdięini ortaya koymuştur. Normal mandalina portakalları %60,5 ile en yüksek doğruluęu gösterirken, olgunlaşmamış mandalina portakalları %61,8 ile en yüksek doğruluęu sağlamıştır. Çürük mandalinalar ise %86,0 doğruluk oranı ile en yüksek performansı sergilemiştir (Lee, 2021). Bu çalışma, YOLOv2 modelinin meyve sınıflandırma ve kalite deęerlendirmesi için etkili bir araç olarak kullanılabilirlięini göstermektedir.

3. MATERYAL VE METOT

3.1. Materyal

Bu tez çalışması, insansız hava aracı (İHA) verilerinin toplanması için geliştirilen metodolojiyi ayrıntılı bir şekilde ele almaktadır. Çalışma, Python programlama dilinde gerçekleştirilmiş olup, veri toplama sürecinde kullanılan İHA modeli olarak DJI Phantom 2 & Zenmuse H4-3D'nin özelliklerini detaylı bir şekilde tanımlamaktadır. Bu model, özelleştirilmiş H4-3D 3-Eksenli Gimbal Desteği ile donatılmıştır ve Can-bus Uzatma Modülü aracılığıyla iosd veya 2.4 G Bluetooth Datalink bağlantısını sağlamaktadır. Ayrıca, AV çıkışı ve video-downlink güç kabloları üzerinden FPV deneyimi sunma yeteneği vardır. Akıllı GPS otopilot sistemi sayesinde daha hassas ve güvenli uçuşlar gerçekleştirilebilirken, 5200mAh kapasiteli akıllı lipo bataryası ile 25 dakikaya kadar uçuş süresi sunmaktadır.

Veri toplama sürecinde, OpenCV ve Roboflow gibi güçlü görüntü işleme araçları kullanılarak detaylı bir veri analizi gerçekleştirilmiştir. Python'un veri analizi ve işleme yeteneklerini desteklemek için pandas kütüphanesi kullanılarak elde edilen veriler etkili bir şekilde düzenlenmiş ve işlenmiştir. Ayrıca, işlemlerin görselleştirilmesi ve sonuçların anlaşılabilir bir şekilde sunulması için matplotlib, seaborn ve diğer görselleştirme araçları entegre edilmiştir. Verilerin yönetimi ve depolanması süreci, işlem adımlarının düzenli bir şekilde gerçekleştirilmesini sağlamak amacıyla os ve shutil kütüphaneleriyle desteklenmiştir. Veri setinin uygun bir şekilde bölünmesi ve işlenmesi için split-folders yöntemi kullanılarak veri seti yönetimi sağlanmıştır.

Model eğitimi ve performans değerlendirmesi aşamasında ise Ultralytics kütüphanesi başarıyla kullanılmıştır. Bu kütüphane, verileri üzerinde eğitilen modellerin performansını değerlendirmek amacıyla kullanıcıya geniş bir esneklik sağlamıştır.

Bu tez çalışması, İHA kullanarak verilerinin etkili bir şekilde toplanması ve yönetilmesi için kapsamlı bir metodoloji sunmaktadır. Kullanılan çeşitli kütüphaneler, her biri belirli bir amaca hizmet ederek araştırmanın başarıyla yürütülmesinde önemli bir rol oynamıştır. Elde edilen sonuçlar, görüntü işleme ve veri analizi alanındaki Python tabanlı araçların etkili kullanımıyla elde edilen değerli bulgulara dayanmaktadır.

Günümüzde önemli bir gelişme gösteren İHA'larının nesne tanıma süreçlerindeki işlevselliği dikkat çekmektedir. İHA'lar, pilot ve yolcu içermeyen, genellikle uzaktan kumandalı veya otomatik olarak görev yapan hava araçlarıdır. Bu araçlar, çeşitli ekipmanlarla donatılarak askeri, sivil (hobi ve ticari) ve bilimsel amaçlarla kullanılmaktadır. Sivil kullanımda İHA'ların geniş uygulama alanları ve mesleki kullanımlarda sağladığı avantajlar, bu teknolojinin hızla yayılmasına neden olmaktadır. Ancak, bu artan kullanım beraberinde yasal düzenlemelerin yetersizliği ve bazı olumsuzlukları da getirmektedir. Birçok ülkede İHA kullanımına yönelik eksik veya sürekli revize edilen mevzuatlar bulunmaktadır. ABD, ICAO ve EUROCONTROL gibi uluslararası kuruluşlar, İHA kullanımıyla ilgili yasal çerçeveyi detaylı şekilde değerlendirmektedir. Türkiye'de ise Sivil Havacılık Genel Müdürlüğü, İHA'ların kullanımıyla ilgili düzenlemeleri ve denetimleri yürütmektedir (Kahveci ve Nazlı, 2017).

Son yıllarda, yapay zekâ teknolojilerinin insansız hava araçlarıyla etkileşimi önemli ölçüde artmıştır. İHA'ların uygulama alanlarının genişlemesi, bu teknolojilerin sunduğu yeni fırsatları beraberinde getirmiştir. Drone ve yapay zekâ teknolojilerindeki gelişmeler, bu adaptasyon sürecini hızlandırmıştır. Yapay zekâ kullanımının mühendislik disiplinlerindeki yaygınlığı, yeni metodolojilerin ve alternatif yaklaşımların ortaya çıkmasına olanak sağlamıştır. Bu çerçevede, görüntü işleme teknikleri, adım adım görüntü yakalama, sayısallaştırma ve iyileştirme süreçlerini içeren alternatif bir yöntem olarak geliştirilmiştir. Bu çalışma, bir quadcopter İHA üzerinde görüntü işleme tekniklerinin uygulanması, algoritmaların geliştirilmesi ve İHA'nın bu tekniklere tepkilerinin incelenmesi amaçlanmaktadır (Soyhan ve ark., 2021).

İnsansız Hava Araçları , casusluk, keşif, saldırı, gözetleme, film yapımı, afet kurtarma, paket teslimatı, depo yönetimi gibi çeşitli amaçlarla kullanılmaktadır. makine öğrenimi algoritmalarını kullanarak İHA görüntülerinden nesnelere tespit etmeye yönelik yaklaşımları ele almaktadır. Gelişen bilgisayarlı görme sistemleri, büyük veri kümeleri, hızlı işlem kapasitesine sahip GPU ve CPU'lar, daha etkili algoritmalar sayesinde, İHA'larla entegre çalışan sistemlerin nesne algılama konusunda ilerlemeler kaydetmesini sağlamıştır. Nesne tespiti, farklı yönelimlere, arka planlara ve kapanmalara sahip görüntülerde zorlu bir görevdir. Bu bağlamda, nesne tespiti, İHA tarafından sağlanan görüntü ve video akışlarını etkili bir şekilde sınıflandırarak işlevsel kategorilere ayırmayı amaçlamaktadır (Ayalew ve Pooja., 2019).

İnsansız Hava Araçları'nın tarihi, hava balonlarından başlayarak uçak teknolojisindeki gelişmelerle günümüzdeki modern İHA'lara kadar uzanmaktadır. Tarım sektöründe İHA'ların kullanımı, bitkilerde hastalık tespit edilmesi, yabancı ot florasının izlenmesi, hassas kimyasal uygulamalar, hayvan kontrolü, su stresi değerlendirmeleri, verim ve olgunluk analizleri gibi birçok alanda önemli avantajlar sağlamaktadır. Ancak, yasal düzenlemeler ve kısıtlamalar İHA'ların potansiyelini tam anlamıyla ortaya koymalarını engelleyebilmektedir. Bu nedenle, tarımda İHA kullanımının yaygınlaşması için uygun düzenlemelerin yapılması gerekmektedir (Türkseven ve ark., 2016). Tarım sektöründe İnsansız Hava Araçları'nın kullanımı, tarım uygulamalarını daha verimli, sürdürülebilir ve hassas hale getirebilir. Ancak, her uygulama için özelleştirilmiş çözümler geliştirmek ve yerel düzenlemelere uyumluluğu sağlamak, bu teknolojinin tarım endüstrisinde başarılı bir şekilde entegre edilmesi için kritik öneme sahiptir.

Bu tez çalışması, meyve tespiti amacıyla kullanılan yüksek çözünürlüklü görüntü elde etme amacıyla İnsansız Hava Araçları kullanılarak oluşturulan bir veri seti incelenmektedir. İHA teknolojisinin tarım sektöründeki potansiyelini değerlendirmek üzere tasarlanan bu araştırma, tarım alanlarını hızlı ve etkili bir şekilde tarayabilme, yüksek çözünürlüklü detayları yakalama ve meyve bahçelerini çeşitli perspektiflerden inceleme gibi avantajları ele almaktadır. İHA teknolojisinin tarım uygulamalarındaki etkilerini anlamayı ve tarım süreçlerini optimize etmeyi hedeflemektedir. İHA'ların tarım alanındaki kullanımının geniş bir perspektifte çözümler sunarak verimliliği artırabileceği ve tarım süreçlerini iyileştirebileceği üzerine odaklanmaktadır. Bu bağlamda, İHA teknolojisinin tarım sektöründe daha etkili bir şekilde nasıl kullanılabileceğini anlamak için gelecekte daha fazla araştırma ve geliştirme çalışmalarına ihtiyaç duyulmaktadır. Bu tez, tarım endüstrisinde İHA teknolojisinin uygulanabilirliğini ve potansiyelini daha derinlemesine inceleyerek sektöre katkıda bulunmayı amaçlamaktadır.

Bu tez çalışma kapsamında, Şekil 3.1'de görüldüğü gibi insansız Hava Araçları tarafından elde edilen yüksek çözünürlüklü görüntüler, meyve tespiti algoritmasının eğitimi ve testi için kullanılan önemli bir veri setini sağlamaktadır. Oluşturulan bu veri seti, meyve bahçelerindeki meyveleri farklı olgunluk seviyelerinde ve çeşitlerde içeren çeşitli senaryoları içermektedir. İHA teknolojisinin kullanımı, tarım alanlarını hızlı ve etkili bir şekilde tarayabilme, yüksek çözünürlüklü detayları yakalama ve meyve bahçelerini çeşitli perspektiflerden inceleme avantajları sağlamaktadır.



Şekil 3.1. İHA'ile meyvelerin ağaçta iken veri toplama anları (a) Nar ağacı, (b) Elma ağacı, (c) Portakal ağacı

Aynı zamanda, İHA kullanımının tarım alanlarının taranmasıyla birlikte, veri setinin çeşitlenmesi ve zenginleşmesi açısından da katkı sağladığı belirlenmiştir. Bu metodoloji, meyve tespiti algoritmalarının genel performansını artırmak ve gerçek dünya koşullarına daha iyi adapte olmasını sağlamak amacıyla tercih edilmiştir. Bu çalışma kapsamında İHA kullanımıyla elde edilen veri seti, meyve tespiti alanında yapay zekâ modellerinin geliştirilmesi ve tarım endüstrisindeki verimliliğin artırılması açısından önemli bir katkı sağlamaktadır.



Şekil 3.2. İHA ile topladığım bazı verilerin görüntüleri

Şekil 3.2’de Gösterildiği bazı verilerin bizzat Siirt ve Mersin illerinde gerçekleştirilen veri toplama sürecinde, çeşitli kaynaklardan elde edilen dört farklı meyve türünün özelliklerini içeren geniş bir veri seti oluşturuldu. Kaggle kaynaklarından alınan bilgilerin yanı sıra, Siirt ve Mersin illerinden bizzat toplanan 2223 farklı görüntü, İnsansız Hava Araçları tarafından çekildi. Bu görüntüler, çeşitli hava koşulları, günün farklı saatleri ve aydınlatma şartları göz önüne alınarak titizlikle seçilerek veri seti oluşturuldu.

Oluşturulan veri seti, meyve tespit etme amacıyla şu şekilde bölünmüştür: %80’i eğitim, %5’i test ve %15’i doğrulama amaçlarıyla ayrılmıştır. Bu dağılım, görüntülerin doğruluğunu sağlamak ve veri setindeki tekrarları önlemek için düzenlenmiştir. Meyvenin olgunlaşma sürecinin izlenmesi ve çürük teşhisinin sınıflandırılması için ise veri seti %80 eğitim ve %20 test olarak ayrılmıştır.

3.2. Metot

3.2.1. Derin Öğrenme

Derin öğrenme, birden fazla işlem katmanından oluşan hesaplama modellerinin, çeşitli soyutlama düzeylerindeki veri temsillerini öğrenmesini sağlayan bir yaklaşımı ifade eder. Bu metodoloji, konuşma tanıma, görsel nesne algılama, nesne tanıma ve ilaç keşfi gibi çeşitli alanlarda, en son teknolojik gelişmelerle önemli ölçüde ilerlemiştir.

Derin öğrenme, bir makinenin her katmandaki temsilini önceki katmandaki temsilden nasıl türeteceğini belirlemek için geri yayılım algoritmasını kullanarak karmaşık yapıları keşfetmeyi amaçlar. Derin evrişimli ağlar, özellikle görüntü, video, konuşma ve ses işleme alanlarında büyük ilerlemeler sağlarken, yinelenen sinir ağları ise metin ve sıralı veri işleme gibi alanlarda odaklanmıştır (LeCun ve ark., 2015).

Meyve olgunlaşmasının izlenmesi ve çürük teşhisi için derin öğrenme yöntemleri, meyve gelişimi süreçlerini anlamak ve çürükleri erken teşhis etmek açısından önemli bir potansiyele sahiptir. Bu uygulamada, meyve görüntülerinden elde edilen veriler üzerinde eğitilen derin öğrenme modelleri, meyve olgunlaşması ve çürük tespiti konularında etkili çözümler sunabilir.

Derin öğrenme yöntemlerinin literatürde en sık kullanılan dallarından biri olan Evrişimli Sinir Ağları , sinyallerin sınıflandırılması alanında yaygın olarak tercih edilen bir yöntemdir (LeCun ve ark., 2015).

Derin öğrenme, nesne tespiti ve izleme gibi alanlarda son yıllarda yükselen bir yapay zekâ metodolojisidir. İnsan hatalarını en aza indirmeye potansiyeli sayesinde geniş bir ilgi görmüştür. Bu teknikler, geniş veri setlerini kullanarak çeşitli alanlarda etkili bir şekilde algılama ve yorumlama kapasitesi sunar. Özellikle etiketli verilerin hızla arttığı görüntü işleme alanı, derin öğrenme algoritmalarının popülerliğini artırmıştır. Bu büyük veri setlerinden anlamlı bilgilerin çıkarılması için metin, görüntü ve ses dosyalarına anlam kazandırılması, derin öğrenme yöntemleriyle başarılı bir şekilde gerçekleştirilmektedir. Son dönemde nesne tespiti ve izleme çalışmalarında belirgin bir artış gözlemlenmektedir. Özellikle hareketli görüntülerde nesne tespiti ve takip edilecek nesnenin belirlenmesi, derin öğrenme algoritmalarının kullanımıyla daha etkili bir şekilde çözümlenmektedir (Tan ve ark., 2021).

Derin öğrenme, karmaşık problemleri çözmek için geliştirilmiş bir yapay zekâ yaklaşımıdır ve genellikle büyük miktarda etiketlenmiş veri üzerinde çalışabilen sinir ağlarını içerir. Bu metodoloji, derin sinir ağları aracılığıyla karmaşık desenleri ve ilişkileri keşfetme kabiliyetiyle öne çıkar ve model parametrelerini genellikle büyük veri kümeleri üzerinde ayarlar. Özellikle nesne sınıflandırma ve otomatikleştirme sistemlerinde kullanıldığında önemli başarılar elde edilmiştir. Derin öğrenme, bilgi işleme ve öğrenme süreçlerini insan benzeri bir biçimde gerçekleştirmesiyle dikkat çeker, bu da geniş bir

uygulama yelpazesini içinde etkili bir şekilde kullanılmasına olanak tanır (İsa ve ark., 2023).

Görsel nesne algılama konusunda derin öğrenmeye dayalı bir yaklaşım detaylı bir şekilde incelenmiştir. Çalışmanın temel katkıları arasında, dedektör tarafından kullanılan özelliklerin hızlı bir biçimde hesaplanabilmesini sağlayan yeni bir görüntü temsilini, yani İntegral Görüntüyü tanıtmayı öne çıkarmaktadır. Bununla birlikte, AdaBoost tabanlı bir öğrenme algoritması, geniş bir özellik kümesinden az sayıda kritik görsel özelliği seçerek etkin sınıflandırıcılar oluşturmaktadır. Üçüncü önemli katkı ise karmaşık sınıflandırıcıları birleştiren bir yöntemdir; bu metod, ilgilenilen nesneyi içerme olasılığının düşük olduğunu belirleyen bir kaskad yapısı sunmaktadır. Görüntü işleme teknikleri, anlamlı bilgiler çıkarmak için kullanılmakta olup, derin öğrenme algoritmaları özellikle videolar üzerinde nesne tespiti ve izleme gibi karmaşık görüntü işleme problemlerini başarıyla çözme potansiyeline sahiptir. Görüntüler üzerinde nesnelerin hızlı bir şekilde tespitini gerçekleştiren ilk algoritma olarak öne çıkmaktadır (Viola ve Jones., 2001). Viola-Jones yöntemi, hızlı ve etkili nesne tespiti sağlamasıyla bilim literatüründe önemli bir başarı olarak kabul edilmektedir. Bu çalışma, görsel nesne algılama alanındaki bu ilerlemeleri detaylı bir şekilde ele alarak, derin öğrenme yöntemlerinin bu alandaki kritik katkılarını vurgulamaktadır.

Derin öğrenme yöntemleri, nesne tespiti, sınıflandırma ve izleme konularında yaygın olarak kullanılmaktadır. İncelenen çalışmalarda, özellikle YOLO, Faster R-CNN ve SSD gibi algoritmalar öne çıkmaktadır; bu algoritmalar nesneleri hızlı ve etkili bir şekilde tespit etme yetenekleriyle dikkat çeker. YOLO, yüksek başarı oranı ve hızın kritik olduğu uygulamalarda tercih edilmektedir. Nesne sınıflandırma sürecinde, tespit edilen nesnenin özelliklerine göre sınıflandırma yöntemleri çeşitlenmektedir; bu bağlamda, renk ve doku temelli yöntemlerin daha yüksek başarı oranları sağladığı gözlemlenmiştir. Bu bulgular, nesne sınıflandırma sürecinde doğru özelliklerin belirlenmesinin başarı oranını önemli ölçüde etkileyebileceğini göstermektedir (Tan ve ark., 2021).

Görüntü işleme alanındaki sürekli çalışmalar ve derin öğrenme odaklı araştırmalar, endüstriyel sektörlerde önemli ilerlemelere öncülük etmektedir. Bu algoritmaların, robotik, havacılık ve İHA'ları gibi sektörlerde uygulanması, makinelerin görsel verileri daha etkili bir şekilde anlamalarını ve çeşitli ortamlara daha iyi adapte olmalarını sağlar. Bu teknolojik avantajlar, sistemlerin, özellikle robotlar ve İnsansız

Hava Araçları gibi, performansını ve güvenilirliğini artırmak adına önemli bir katkı sunmaktadır. Gelecekte, bu disiplinlerdeki ilerlemelerin daha da genişleyerek, gelişmiş robotik sistemler, akıllı havacılık platformları ve benzeri uygulamalarda yeni fırsatlar yaratacağı öngörülmektedir. Bu bağlamda, görüntü işleme ve derin öğrenme tekniklerinin entegrasyonu, endüstriyel uygulamalarda inovasyon ve verimlilik artışına önemli bir temel oluşturmaktadır.

İnceldiğim literatürlere dayanarak, derin öğrenme yöntemleri, meyvelerin olgunlaşma takibi ve çürük teşhisi yapmak amacıyla kullanıldığında, başlangıç aşaması veri toplama sürecidir. Meyve olgunlaşmasının takibi için modelin eğitimi için gerekli olan fotoğrafların bir veri setine kaydedilmesi gereklidir. Bu, meyvelerin farklı olgunluk seviyelerini ve çürük durumlarını içeren geniş bir veri yelpazesini içermelidir. Veri setinin hazırlanmasının ardından, bir sonraki adım veri etiketlemedir. Bu aşamada, veri setinde bulunan meyvelerin konumu, boyutu ve diğer özellikleri etiketlenerek derin öğrenme modelinin doğru bir şekilde meyveleri tanımasını sağlamak için gerekli olan referans noktaları belirlenir. Bu etiketleme süreci, modelin doğru eğitim alabilmesi ve gerçek dünya koşullarında başarılı bir performans sergilemesi açısından kritiktir.

Etiketleme işlemi tamamlandıktan sonra, bir sonraki adım derin öğrenme modelinin seçimidir. Bu bağlamda, meyvelerin takibi ve tespiti için popüler olarak kullanılan modeller arasında YOLO, Faster R-CNN ve SSD gibi nesne tespit modelleri bulunmaktadır. Bu modeller, meyve olgunlaşma takibi ve çürük teşhisi konularında yüksek doğruluk ve hızlı işleme kapasitesi sağlama potansiyeline sahiptir.

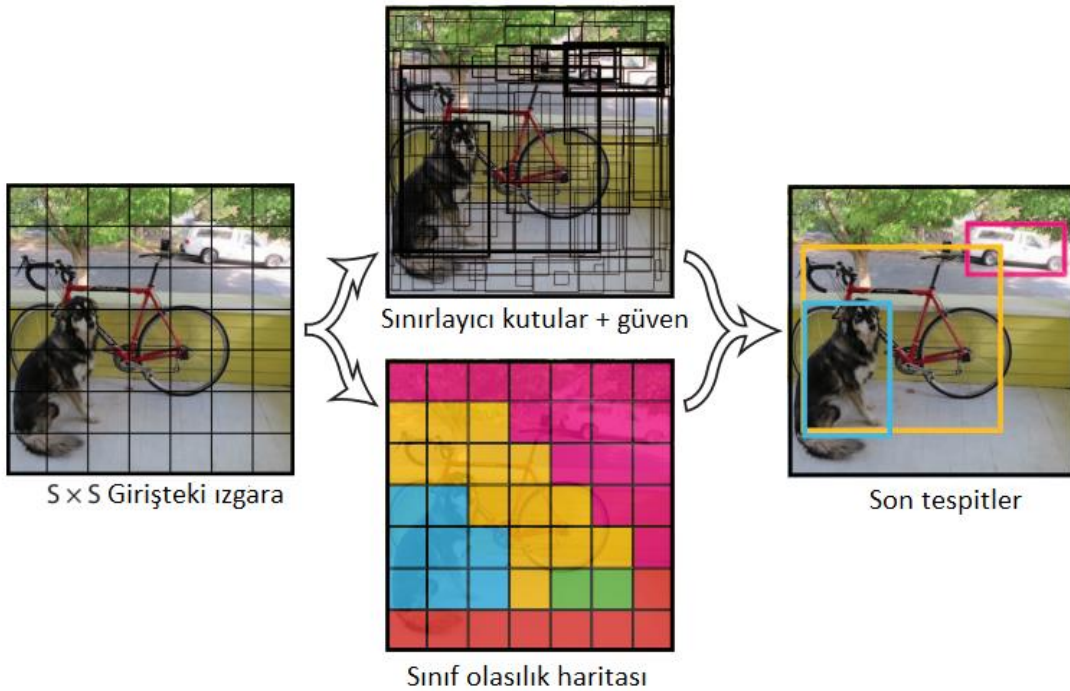
Bu adımların başarıyla tamamlanması, derin öğrenme tabanlı sistemlerin tarım uygulamalarında meyve olgunlaşma takibi ve çürük teşhisi alanlarında etkili bir şekilde kullanılmasını sağlar. Veri toplama, etiketleme ve uygun model seçimi, bu teknolojinin tarım endüstrisinde verimliliği artırma ve ürün kalitesini iyileştirme potansiyelini destekleyen kritik unsurları oluşturur.

Bu tez çalışmasında, YOLO modeli tercih edilmiştir ve bu model, açık kaynaklı olarak CNN yöntemiyle geliştirilmiştir.

Nesne algılama süreçlerini birleştiren bir sinir ağı yaklaşımını detaylı bir şekilde geliştirilmiştir. görüntünün tamamındaki özellikleri kullanarak her sınırlayıcı kutuyu tahmin eder ve aynı anda tüm sınıflardaki tüm sınırlayıcı kutularını tahmin eder. YOLO tasarımı, yüksek ortalama kesinliği korurken uçtan uca eğitim ve gerçek zamanlı hızlar

sağlar. Sistem, giriş görüntüsünü $S \times S$ ızgarasına böler ve her ızgara hücresi, içerdiği nesnelere tespit etmekten sorumludur. Güven puanları, modelin bir kutunun bir nesneyi içerip içermediği ve tahmin edilen kutunun gerçekte ne kadar örtüştüğü konusundaki güvenini ifade eder. Model, her sınırlayıcı kutu için beş tahmin içerir: x , y , w , h ve güven. Ayrıca, her ızgara hücresi, sınıf olasılıklarını tahmin eder. Test zamanında bu tahminleri çarparak her kutu için sınıfa özgü güven puanları elde edilir. Yapmış olduğu algılamayı bir regresyon problemi olarak modelleyerek, görüntüyü $S \times S$ ızgarasına bölerek B sınırlayıcı kutularını, güvenlerini ve sınıf olasılıklarını tahmin eder. Nesne tanıma süreçlerini tek bir sinir ağında birleştirerek hem yüksek kesinliği koruyan hem de gerçek zamanlı hızlara olanak tanıyan bir yaklaşım sunmaktadır (Redmon ve ark., 2016).

Redmon ve arkadaşları tarafından geliştirilen YOLO modeli, özellikle gerçek zamanlı uygulamalar için idealdir. Örneğin, otomobil sürüşü sırasında yol işaretlerini tanıma, güvenlik kameralarında nesne tespiti, endüstriyel robotik sistemlerde nesne manipülasyonu gibi birçok alanda etkili bir şekilde kullanılmaktadır. YOLO'nun performansı hem bilgisayarlı görü işleme araştırmalarında hem de endüstriyel uygulamalarda önemli bir referans noktası olarak kabul edilmektedir. YOLO algoritmasının çalışma prensibi şekil 3.3'de gösterilmektedir .



Şekil 3.3. YOLO algoritmasının fotoğraf üzerinde çalışma prensibi (Redmon, 2016)

YOLO, nesne tespiti konseptini görüntü piksellerinden sınırlayıcı kutu koordinatlarına ve sınıf olasılıklarına tek bir regresyon problemi olarak dönüştüren hızlı ve etkili bir yapay zekâ yaklaşımını temsil eder. Tek bir bakışta görüntü üzerinde nesne tespiti yapabilme yeteneğiyle öne çıkar. görüntü üzerinde tek bir bakışta nesne tespiti yapabilme yeteneğiyle öne çıkar. YOLO'nun basit ve etkili tasarımı, yüksek ortalama hassasiyeti korurken uçtan uca eğitim ve gerçek zamanlı hızlar sağlar. YOLO, genel olarak görüntü üzerinde mantık yürüterek, eğitim ve test süresince tam görüntüyü görmesi sayesinde diğer tekniklere kıyasla avantajlar sunar. Hızlı çalışma hızı, geniş bağlamı görebilme yeteneği ve genelleştirilebilir temsiller öğrenme avantajları, YOLO'nun diğer nesne algılama yöntemlerinden üstün kılmasını sağlar. Ancak, küçük nesnelerin yerini belirleme konusundaki zorlukları ve doğruluk açısından belirli sınırlamaları da göz önünde bulundurmak önemlidir (Redmon ve ark., 2016). YOLO algoritmasının genel tespit sistemi şekil 3.4'de verilmiştir .



Şekil 3.4. YOLO algoritmasının genel tespit sistemi (Redmon, 2016)

YOLO algoritmasının tarım uygulamalarındaki potansiyeli, meyve bahçelerindeki olgunlaşma durumunun izlenmesi ve potansiyel çürüklerin tespit edilmesi süreçlerini optimize etme kapasitesine dayanmaktadır. Algoritmanın temel özelliği, tek bir giriş resmi üzerinde birden çok nesneyi aynı anda tespit edebilmesi ve bu sayede gerçek zamanlı analizlerde üstün performans sergileyebilmesidir. meyve olgunlaşma takibi açısından, YOLO algoritması meyve bahçelerindeki meyvelerin olgunluk durumunu hızlı bir şekilde belirleyerek hasat zamanlamasını optimize etme olanağı sunmaktadır. Bu, tarım işletmelerinin ürün verimliliğini artırmasına ve kaynakları daha etkili bir şekilde yönetmesine yardımcı olabilir.

Öte yandan, çürük teşhisi konusunda YOLO algoritması, potansiyel çürük alanlarını tespit ederek hızlı müdahale imkanı sağlamaktadır. Bu sayede, ürün kayıpları minimize edilebilir ve ürün kalitesi önemli ölçüde artırılabilir.

YOLO nesne algılama algoritması, gerçek zamanlı nesne tespiti için tasarlanmış olan bir CNN tabanlı metodolojidir. Bu algoritma, görüntülerdeki nesnelerin sınırlayıcı kutularını ve ilgili sınıf etiketlerini tahmin etmek amacıyla tek bir geçişte işlem yapar. YOLO model ailesi, zaman içinde evrim geçirerek çeşitli versiyonlarla geliştirilmiştir, her biri öncekine kıyasla performans ve özellik açısından yenilikler sunmaktadır.

YOLO serisinin farklı sürümleri, nesne tespiti konusunda önemli gelişmeler ve yenilikler getirmiştir. İşte bu sürümlerin her biri hakkında daha ayrıntılı bir inceleme:

YOLOv1 (2015): Bu model, nesne tespitini sınıflandırma problemi yerine regresyon problemi olarak ele alır. Giriş görüntüsünü bir ızgaraya böler ve her ızgara hücresi için sınırlayıcı kutuları ve güven değerlerini tahmin eder. Maksimum olmayan bir bastırma NMS kullanarak tekrarlanan tespitleri ortadan kaldırır. Bu yaklaşım, hızlı ve etkin nesne tespiti sağlar.

YOLOv2 (2016): Darknet-19 mimarisini kullanarak önemli iyileştirmeler sunar. 9000'den fazla nesne kategorisinin algılanması, toplu normalleştirme ve bağlantı kutuları gibi özellikler eklenmiştir. Bu sürüm, daha geniş bir nesne yelpazesini tanıyabilme kapasitesiyle öne çıkar.

YOLOv3 (2018): Darknet-53 mimarisi ile genişletilmiştir ve Darknet-19'dan kalan bağlantılarla geliştirilmiştir. Bu sürüm, birden fazla ölçekli çıkarım ve özellikle küçük nesnelerin tespiti konusunda iyileştirmeler içerir. YOLOv3, farklı nesne boyutlarına duyarlı bir şekilde performans gösterebilir.

YOLOv4 (2020): Yenilikçi özellikler olarak ağırlıklı artık bağlantılar, çapraz mini toplu normalleştirme, kendi kendine düşmanlık eğitimi ve mish aktivasyon işlevini içerir. Bu özellikler, modelin daha doğru ve hızlı olmasını sağlar.


YOLOv5 (2021): PyTorch çerçevesi altında uygulanmıştır ve odak katmanı, CSP gibi özellikler içerir. Hız ve basitlik odaklıdır, bu da pratik uygulamalarda geniş kullanımını sağlar.

YOLOv6 (2022): Küçük modeller için tek yollu bir omurga ve büyük modeller için verimli çok dallı bloklar içerir. Performans ve ölçeklenebilirlik açısından önemli geliştirmeler sunar, bu da çeşitli uygulamalarda kullanılabilirliğini artırır.

YOLOv7 (2022): Çıkarım aşamasında birden fazla hesaplama modülünü birleştirerek planlı, yeniden parametrelendirilmiş bir model önerisi sunar. Bu, modelin daha verimli ve doğru sonuçlar üretmesini sağlar.

YOLOv8 (2023): YOLO model ailesinin en güncel sürümüdür ve hız ile doğruluk açısından önceki modellere kıyasla daha üstün performans sergiler. Bu sürüm, önceki sürümlerin başarılarını bir araya getirerek çeşitli geliştirmeler içerir. YOLOv8, modelin genel verimliliğini, ölçeklenebilirliğini ve nesne tespiti konusundaki hassasiyetini artırmayı hedefler (Neamah ve Karim, 2023).

Şekil 3.5'de, YOLOv8'in son YOLO modelleriyle karşılaştırılması gösterilmektedir. Bu karşılaştırma, YOLOv8'in diğer sürümlere göre sağladığı iyileştirmeleri ve gelişmeleri daha net bir şekilde ortaya koymaktadır. Bu evrim süreci, YOLO modellerinin sürekli olarak geliştirilip optimize edildiğini ve her yeni sürümün önceki sürümlere göre önemli yenilikler ve performans artışları sunduğunu göstermektedir. YOLO ailesi, nesne tespiti alanında etkili ve yenilikçi çözümler sunmaya devam etmektedir.



Şekil 3.5. YOLOv8'in son YOLO modelleriyle karşılaştırılması

Şekil 3.5'te YOLOv8, önceki versiyonlarına kıyasla belirgin bir performans artışı sunmaktadır, özellikle hız, doğruluk ve mimari açısından önemli geliştirmeler içermektedir. Bu yeni iterasyon, YOLOv7 modelinden daha hızlı ve daha doğru bir performans sergileyerek, 53,7 Ortalama Ortalama Hassasiyet puanı ile yeni bir başarı seviyesine ulaşmıştır.

Algoritmanın temel stratejisi, diğer nesne algılama yöntemlerinden farklı olarak, nesne algılama görevini görüntünün farklı kısımlarında tekrar tekrar yürütmek yerine, bu işlemi tek bir geçişte tamamlamaktır. Bu yaklaşım, YOLOv8'in nesnelere yüksek doğrulukla tespit ederken aynı zamanda hızlı ve verimli bir performans sergilemesine olanak tanır. YOLOv8'in benzersiz mimarisi, EfficientDet adlı derin öğrenme modelini kullanmaktadır. Bu model, hafif ve hızlı olmasına rağmen yüksek doğruluk seviyelerine ulaşmayı hedefler. EfficientDet, geniş bir görüntü veri kümesi üzerinde eğitilerek gerçek dünyadaki nesnelere modellerini ve özelliklerini öğrenme yeteneğine sahiptir. Eğitildikten sonra, bu ağ yeni görüntülerde nesne algılama görevlerini hızlı ve doğru bir şekilde gerçekleştirebilir, görüntüdeki nesnelere varlığını ve konumlarını belirleyebilir.

YOLOv8 ağını etkili bir şekilde kullanmak üzere kullanıcıların tercih edebileceği bir dizi terminal veya komut istemi komutu mevcuttur. Bu komutlar, meyve olgunlaşmasının izlenmesi ve çürük teşhisi gibi özel görevlerin YOLOv8 ağı tarafından başarıyla gerçekleştirilmesini sağlamak üzere tasarlanmıştır.

Görev (Task): YOLOv8 ağının icra etmesi gereken belirli bir görevi belirten bir parametredir. Örneğin, meyve olgunlaşmasını izleme veya çürük teşhisi gibi spesifik görevler, YOLOv8 ağının başarıyla gerçekleştirebileceği görevlere örnek teşkil eder. (Detect, Segment ve Classify seçenekleri arasından seçim yapılabilir.)

Tespit (Detect): YOLOv8 ağı, belirli bir görseli veya videoda yer alan meyveleri tespit etme görevini yerine getirir. Bu süreçte model, her bir meyvenin etiketini öngörür ve bu etiketleri görüntü veya videodaki ilgili meyvelere uygular.

Bölme (Segmentasyon): YOLO ağı, görseli veya videodaki her bir meyvenin konumunu ve boyutlarını belirleme sürecini ifade eder. Bu yöntem, görüntüdeki meyvelerin bireysel olarak tanımlanmasını ve ayrıştırılmasını sağlar. Bölme işlemi, her bir meyvenin sınırlarını ve boyutlarını hassas bir şekilde tespit ederek, bunların tek tek izole edilmesine imkân tanır.

Sınıflandırma (Classify): YOLO ağı, görsel veya videodaki meyvelerin belirli bir kategoriye ait olup olmadığını tahmin etme işlemini gerçekleştirir. Bu işlem, örneğin, bir görüntüdeki meyvenin olgun, ham ya da çürük olduğunu sınıflandırmayı amaçlar. Sınıflandırma süreci, meyvelerin belirli özelliklerine (örneğin, renk, doku, şekil) dayalı olarak uygun sınıflara ayrılmasını sağlar. Böylelikle, kalite kontrol süreçleri daha hızlı ve

etkili bir şekilde yürütülür ve ürünlerin hassas bir biçimde değerlendirilmesi mümkün hale gelir.

Döngü (Epoch): YOLOv8 modelinin eğitimi sırasında, veri kümesindeki tüm örneklerin bir kez işlenmesini ifade eden bir terimdir. YOLOv8 modeli, her döngüde veri kümesindeki örneklerden öğrenir ve ağı günceller. Bu süreç, ağın genel performansını artırmak ve istenen sonuçları elde etmek için tekrarlanan bir eğitim adımudur.

Resim Boyutu (Imgsz): YOLO ağı için belirleyici olan görüntü veya video dosyalarının boyutu parametresidir. Bu boyut, ağın meyve olgunlaşması ve çürük teşhisi gibi karmaşık görevleri etkin bir şekilde gerçekleştirebilmesi için belirlenir. Doğru boyut seçimi, ağın algılama hassasiyetini ve sınıflandırma doğruluğunu etkiler.

Argümanlar (Args): YOLO ağının eğitim ve test süreçlerinde kullanılan ayarları ve parametreleri içeren kritik bir kategoriye ifade eder. Bu ayarlar, ağın genel performansını, sınıflandırma doğruluğunu ve nesne tespit başarısını doğrudan etkileyebilir.

Göster (Show): YOLO ağının çıkışlarını görsel olarak sunan bir komuttur. Bu, ağın meyve olgunlaşması ve çürük teşhisi görevlerindeki doğruluğunu ve performansını değerlendirmeyi kolaylaştırır.

Mod (Mode): YOLO ağının çalışma modunu belirleyen bir terimdir. Eğitim modu ve test modu gibi farklı modlar bulunabilir.

Eğitim (Train): YOLO ağının meyve olgunlaşması ve çürük teşhisi görevi için veri kümesindeki örnekler üzerinde eğitilmesini ifade eder. Bu süreçte model, öğrenme yeteneklerini artırmak ve belirli bir görevi daha etkili bir şekilde yerine getirmek için veri setinden bilgi çeker.

YOLOv8, YOLO nesne algılama modelinin en son sürümüdür. Önceki versiyonlardan farklı olarak, FPN ve PAN mimarilerini içeren yeni bir sinir ağı mimarisi ile gelir. Bu mimariler, özellik kanallarının sayısını artırırken, giriş görüntüsünün uzaysal çözünürlüğünü azaltarak farklı ölçek ve çözünürlükteki nesnelere tespit edebilen özellik haritaları oluşturur. Ayrıca, YOLOv8'in öne çıkan bir özelliği, etiketleme sürecini basitleştiren bir araç sunmasıdır. Bu araç, otomatik etiketleme, etiketleme kısayolları ve özelleştirilebilir kısayol tuşları gibi kullanışlı özellikler içermekte, modelin eğitimini kolaylaştırmaktadır. Model, önceki versiyonlarına kıyasla gelişmiş son işlem teknikleri ile donatılmıştır. Sinir ağı tarafından üretilen tahmini sınırlayıcı kutular ve nesne skorları

üzerinde uygulanan bu teknikler, algılama sonuçlarını rafine eder, gereksiz algılamaları azaltır ve tahminlerin genel doğruluğunu artırır. Bu teknikler arasında, Soft-NMS adlı, örtüşen sınırlayıcı kutulara yumuşak bir eşik uygulayan bir teknik bulunmaktadır (Reis ve ark.,2023).

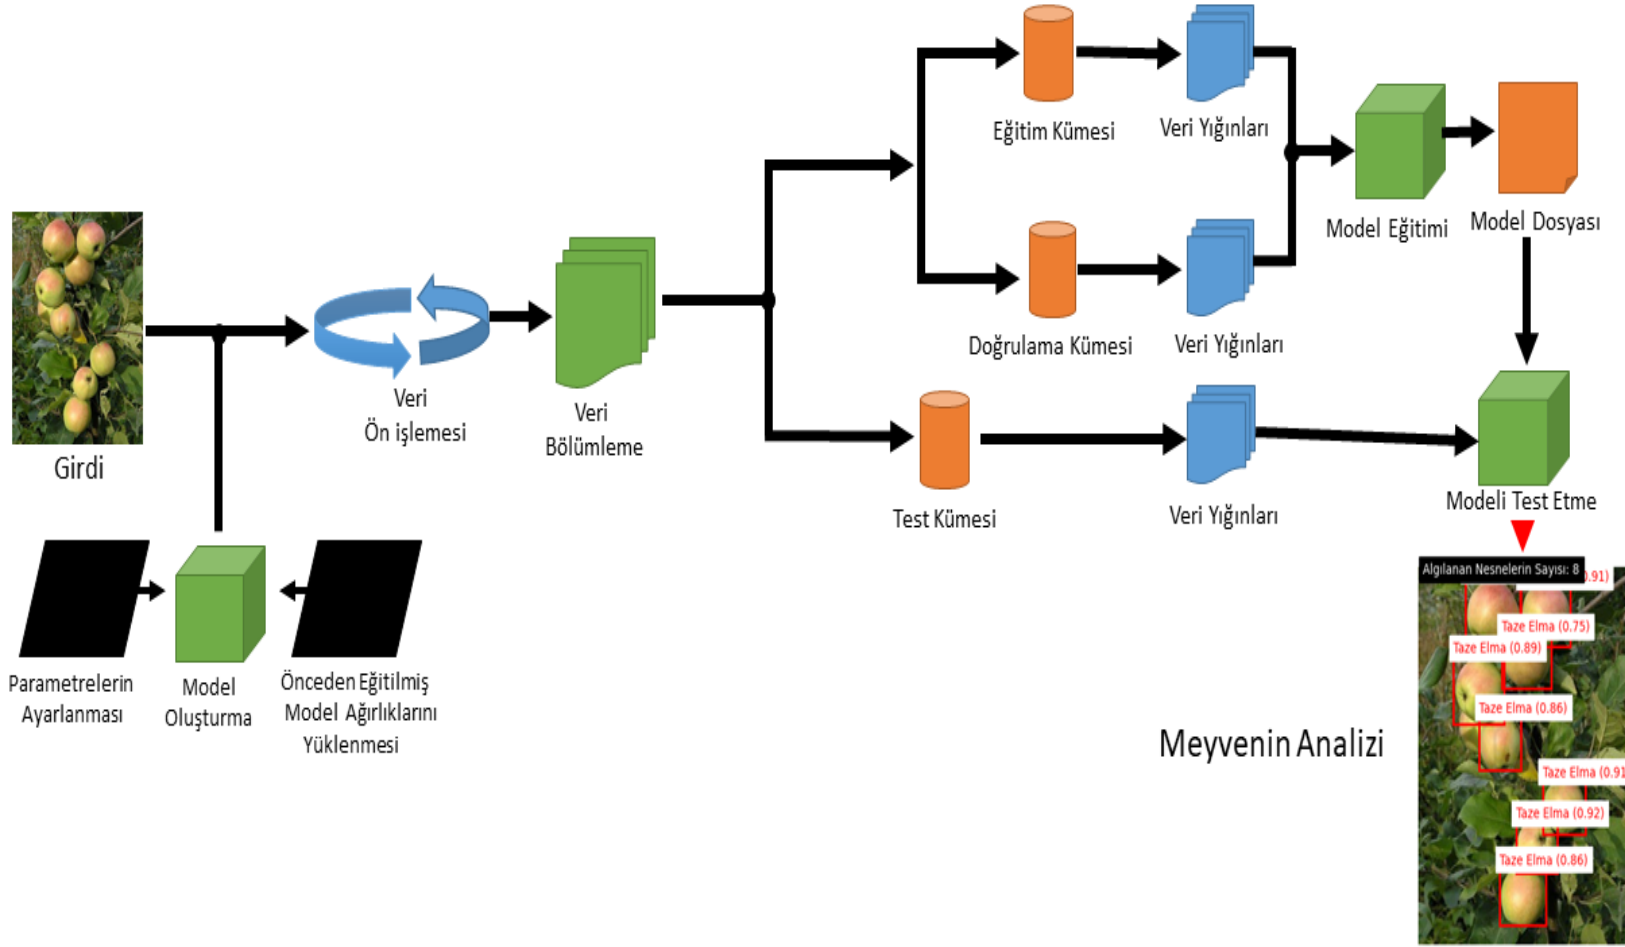
YOLOv8 mimarisi, görüntüde belirli bölgeleri seçmek yerine, görüntüdeki nesnelere algılamak ve etrafına sınırlayıcı kutular çizmek için görüntünün tamamına bir sinir ağı uygulamaktadır. YOLO mimarilerinin tasarımları, girdi görüntüsünü $S \times S$ ızgaralara bölen tek bir derin evrişimli sinir ağıdır. Her ızgara alanı, güven derecesine karşılık gelen ortalanmış hedef sınırlama kutusunu tahmin etmekten sorumludur ve bu tahminleri olasılık sınırları ile birleştirir. Güven derecesini veren formül, denklem (3.1)'de verilmiştir.

$$\text{Güven oranı} = pr(\text{sınıf}|\text{nesne}). pr(\text{nesne}). IoU = pr(\text{sınıf}). IoU \quad (3.1)$$

Bu formülde, $pr(\text{sınıf}|\text{nesne})$ terimi, belirli bir sınıfın nesneye ait olma olasılığını ifade ederken, $pr(\text{nesne})$ terimi görüntüde nesnenin var olma olasılığını temsil eder. IoU ise tahmin edilen sınırlayıcı kutunun gerçek sınırlayıcı kutuya ne kadar iyi örtüştüğünü ölçer. Çarpımın sonucu olan güven oranı, nesnenin doğru bir şekilde tanımlanıp tanımlanmadığını belirleyen bir güven skorunu oluşturur. YOLO mimarileri, her bir ızgara hücresinin istenen nesnenin varlığını belirten bir vektöre sahip olmasını sağlar. Bu vektör, nesnenin sınıfı ve konumu hakkında bilgi içerir. Aşamalı yapısı sayesinde modeller, zaman içinde daha iyi öğrenip daha doğru sonuçlar vermeye eğilimlidir. Bu tasarımların çalışma mekanizması, ilgili bölgede tespit edilen objeler içerisinde doğruluk oranı en yüksek olan objenin korunmasına dayanır. Bu mekanizma, görüntü tanıma ve nesne tespit süreçlerinin verimliliğini ve doğruluğunu artırır.

Bu tez çalışma kapsamında tasarlanan modelin genel çalışma prensibi olan YOLOv8, veri kümesindeki meyveleri eğitmek için kullanıldığında, ilk adım olarak giriş görüntüsünü bir ızgaraya böler. Her ızgara hücresi, içindeki nesnelere tahmin etmekten sorumludur. Bu ızgara sistemi, YOLOv8'in görüntüleri hızlı ve verimli bir şekilde işlemesini sağlar. veri kümesindeki her görüntü, taze elma, çürük elma, taze portakal, çürük portakal, taze muz, çürük muz, taze nar ve çürük nar olmak üzere sekiz kategoriden biriyle etiketlenmiştir. Her meyvenin çevresine çizilen sınırlayıcı kutular, modelin öğreneceği temel gerçeği sağlar. YOLOv8, tek atışlı bir dedektördür, yani tahminlerini ağ üzerinden tek geçişte yapar. Görüntüyü farklı ölçeklerde veya en boy oranlarında

birden çok kez taramaz. Her bir ızgara hücresi için sınırlayıcı kutuları ve sınıf olasılıklarını aynı anda tahmin eder. Model, tahminlerini veri kümesindeki gerçek etiketlerle karşılaştırır ve "temel gerçek" adını verdiğimiz farkı hesaplar. Bu fark, bir kayıp fonksiyonu kullanılarak ölçülür ve eğitim sürecinin amacı, bu kaybı en aza indirmektir. Şekil 3.6'de Oluşturulan YOLOv8 modelinin mimarisinin çalışma prensibi gösterilmiştir. Eğitim süreci, modelin dahili parametrelerini ayarlamak için geri yayılım adı verilen ve kaybı azaltan bir süreç kullanır. Bu süreç, stokastik gradyan iniş (SGD) veya Adam gibi optimizasyon algoritmaları kullanılarak gerçekleştirilir. eğitimin amacı , veri kümesindeki farklı görüntülerle birçok yinelemede tekrarlanır. Model, her kategoriye ayırt eden görsel özellikleri öğrenir ve yeni görsellerin kategorisini doğru bir şekilde tahmin edebilir. diğ er bir amacı ise modelin ağırlıklarını ayarlamak ve optimize etmek için



Şekil 3.6. Oluşturulan YOLOv8 modelinin mimarisinin çalışma prensibi

veri setini beslemektir. Eğitim sonrasında modelin doğruluk oranı ve performansı değerlendirilir. Oluşturulan modelin gerçek dünya verileriyle test edilerek doğruluk ve hassasiyet kontrol edilmelidir.

Modelin eğitiminden sonra, genelleme yeteneğini değerlendirmek için ayrı bir test setinde test edilir. YOLOv8, taze ve çürük meyveler içeren özel bir veri kümesinden öğrenir.

3.2.2. Performans Kriterleri

Bu tez çalışması, gerçekleştirilen YOLOv8 modelinin verilerden genelleme yeteneğini değerlendirmek ve başarısını değerlendirmek amacıyla f-ölçüleri, ortalama kesinlik, duyarlılık ve kesinlik kriterlerinden yararlanmıştır.

Bahsedilen kriterlerin hesaplanmasında kullanılan temel değerler Tablo 3.1’de sunulmaktadır.

Tablo 3.1. Performans kriterleri hakkında bilgiler

		Var olan Durum	
		Pozitif Durumlar	Negatif Durumlar
Tahmin Değer	Pozitif	TP	FP
	Negatif	FN	TN

TP: pozitif sınıfın doğru bir şekilde sınıflandırılmış örneklerini ifade eder,

TN: negatif sınıfın doğru bir şekilde sınıflandırılmış örneklerini simgeler,

FP: pozitif sınıfın yanlış bir şekilde sınıflandırılmış örneklerini belirtirken,

FN: negatif sınıfın yanlış bir şekilde sınıflandırılmış örneklerini ifade eder.

Ortalama kesinlik, nesne algılama ve bölme sistemlerinin performansını değerlendirmek üzere geniş bir kabul görmüş bir ölçüdür. Bu metrik, özellikle hızlı nesne algılama ve sınıflandırma modelleri, örneğin YOLO gibi, için yapılan performans analizlerinde tercih edilen bir değerlendirme aracıdır. Ortalama kesinlik değerleri, 0 ile 1 arasındaki duyarlılık değerleri üzerinden hesaplanarak, modelin doğruluğu ve güvenilirliği hakkında önemli bilgiler sunar.

Ortalama kesinlik, her bir sınıf için ayrı ayrı hesaplanan kesinlik değerlerinin aritmetik ortalaması alınarak elde edilmektedir. Bu değer, birden fazla sınıfın

etkileşiminden doğan genel bir ortalama sunar. Ortalama kesinlik, duyarlılık ve kesinlik arasındaki dengeyi korurken, aynı zamanda yanlış pozitif ve yanlış negatif değerleri dikkate alarak modelin performansını kapsamlı bir şekilde değerlendirir. Bu özellik, çoğu algılama uygulaması için uygun ve güvenilir bir ölçüt olarak kabul edilmektedir (Ren ve ark., 2015).

Sınıflandırma süreci, verilerin doğru veya yanlış sınıflandırılmasına dayalı bir oluşumu içermektedir. Bu temel kriterlere odaklanılarak, bu tez kapsamında kullanılan özel kriterlerin elde edilmiş biçimi ve matematiksel formülasyonları ayrıntılı bir biçimde açıklanmaktadır.

Kesinlik, doğru bir şekilde sınıflandırılmış pozitif örneklerin, gerçekten pozitif olan örneklerin oranını ölçen bir metriktir. Matematiksel ifadesi denklem (3.2)'de verilmiştir .

$$Kesinlik = \frac{TP}{TP+FP} \quad (3.2)$$

Duyarlılık, gerçek pozitif örneklerin doğru bir şekilde tahmin edilme oranını ölçen bir metriktir. Tüm gerçek pozitifler içinde doğru bir şekilde tahmin edilenlerin oranını ifade eder. Matematiksel ifadesi denklem (3.3)'te verilmiştir .

$$Duyarlılık = \frac{TP}{TP+FN} \quad (3.3)$$

F1 puanı, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıyla hesaplanan bir ölçüdür. Matematiksel ifadesi denklem (3.4)'te verilmiştir .

$$F1 Puanı = 2 * \frac{kesinlik*duyarlılık}{kesinlik+duyarlılık} \quad (3.4)$$

Ortalama kesinlik, algılanan nesne sınırlayıcı kutularının gerçek referans değerleriyle karşılaştırılarak hesaplanan bir değerlendirme puanı sağlar. Bu puan, modelin tespitlerinin doğruluğunu ne kadar iyi yansıtıyorsa, o kadar yüksektir. Matematiksel ifadesi denklem (3.5)'te verilmiştir .

$$Ortalama Kesinlik (mAP) = \frac{1}{n} \sum_{k=1}^n AP_K \quad (3.5)$$

$$AP = \int_0^1 Kesinlik_{(duyarlılık)} dR \quad (3.6)$$

4. BULGULAR VE TARTIŞMA

Bu bölüm, YOLOv8 modelinin tez çalışması bağlamında elde edilen performansını çeşitli ölçütlerle değerlendirmeyi amaçlamaktadır. F1 puanı, kesinlik, duyarlılık ve Kesinlik-Duyarlılık sonuçları, modelin sınıflandırma yeteneğini detaylı bir şekilde incelemektedir. Bu ölçütler, modelin doğruluğunu belirlemede kilit bir rol oynar. Modelin ortalama performansı, farklı ölçütlerin birleştirilmesiyle elde edilen genel bir değerlendirmeyi içermektedir. Bu, modelin çoklu ölçütlere göre nasıl performans sergilediğini anlamak açısından önem taşımaktadır. Ayrıca, kayıp fonksiyon sonuçları analizi ve modelin eğitim sonuçları, modelin eğitim sürecinin etkinliği hakkında önemli bilgiler sunmaktadır. Kayıp fonksiyon sonuçları, modelin ne kadar etkili bir şekilde öğrendiğini ve hata toleransının düzeyini gösterir. Modelin eğitim sonuçları, performansın eğitim sürecinde nasıl evrimleştiğini ve modelin ne kadar hızlı öğrendiğini gösterir.

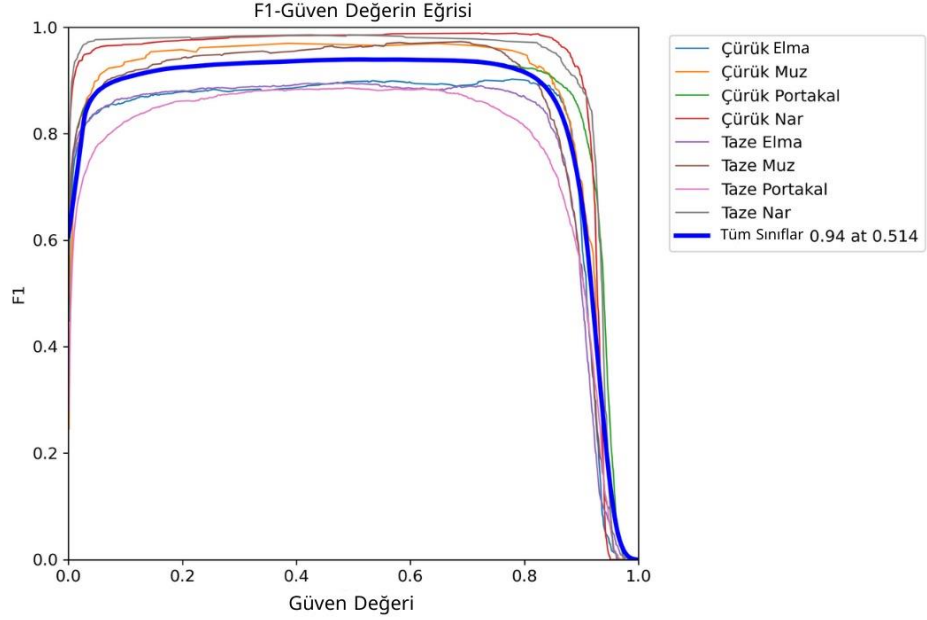
Bu analizler, tez çalışmasının model geliştirme ve değerlendirme aşamalarına daha derin bir anlayış kazandırmayı amaçlamaktadır. bu bölüm, YOLOv8 modelinin performansının çeşitli açılardan detaylı bir şekilde incelendiği bir değerlendirme sunmaktadır.

- **YOLOv8 Modelin F1 puanların Analizi**

F1 Puanı, bir modelin kesinlik ve duyarlılık ölçümlerini birleştirerek performansını değerlendiren önemli bir metrik olarak öne çıkmaktadır. Bu puan, bir sınıfın doğruluğunu değerlendirirken hem yanlış pozitiflerin hem de yanlış negatiflerin etkisini dengeler. F1 Puanı, genellikle nesne algılama ve sınıflandırma modellerinin etkinliğini ölçmede kullanılan güvenilir bir ölçüdür. F1 Puanı analizine odaklandığımızda, farklı sınıflar için elde edilen değerlerin genelde yüksek olduğunu gözlemliyoruz. Taze elma için %86,8, çürük elma için %86,1, taze portakal için %85,8, çürük portakal için %90,9, taze muz için %90,2, çürük muz için %92,3, taze nar için %97,3 ve çürük nar için %92,3 gibi sınıf bazında yüksek F1 Puanı değerleri elde edilmiştir.

Modelin genel performansını gösteren %94,1'lik F1 Puanı, doğru pozitifleri ve gerçek pozitifleri başarılı bir şekilde tahmin etme kabiliyetini vurgular. Grafik üzerindeki bu

yüksek puanlar, modelin çeşitli sınıfları etkili bir şekilde tanıma ve sınıflandırmada başarılı olduğunu göstermektedir.Şekil 4.1’de F1 Puan grafiği verilmiştir.



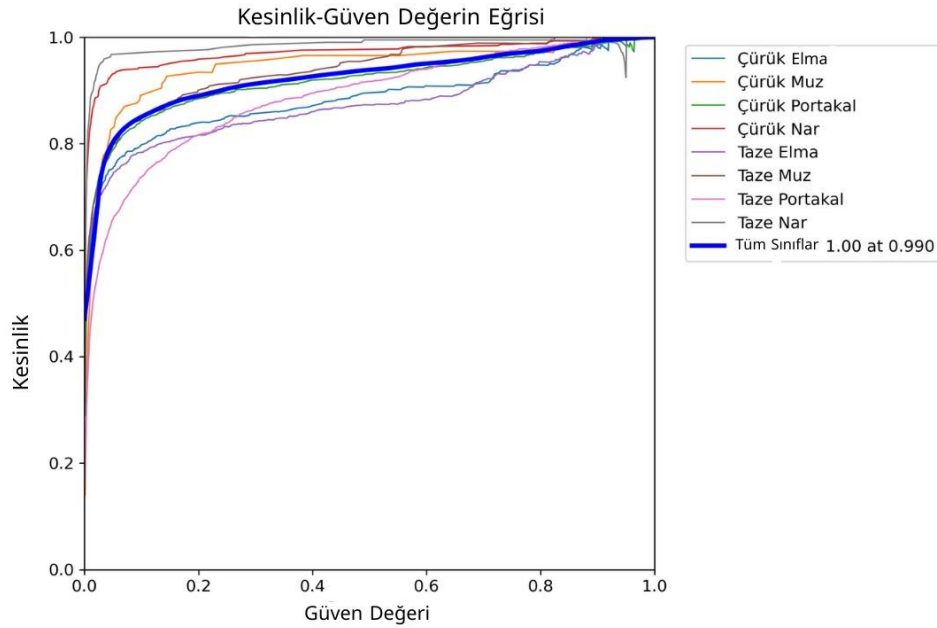
Şekil 4.1. YOLOv8 ile yapılan çalışmanın F1-GD grafiği

F1 Puanı sonuçlarına göre, modelin çoğu sınıf için yüksek performans sergilediği ve sınıflar arasında dengeli bir tahmin yeteneğine sahip olduğu açıkça görülmektedir. Bu durum, YOLOv8 modelinin nesne algılama görevinde etkili bir şekilde kullanılabilir bir güçlü bir algoritma olduğunu ortaya koymaktadır.

- YOLOv8 Modelin Kesinlik Değerlerin Analizi

Kesinlik, bir modelin doğru pozitif tahmin yeteneklerini ölçerek, yanlış pozitifleri en aza indirme amacına katkı sağlayan önemli bir performans metriğidir. Kesinlik değerlendirmeleri grafiğinde, farklı sınıflar için elde edilen kesinlik değerlerini detaylı bir şekilde incelemekteyiz. Kesinlik, doğru pozitif tahminlerin toplam tahmin sayısına oranını gösterir, bu da yanlış pozitifleri en aza indirmeyi amaçlar. Yüksek kesinlik değerleri, modelin yanlış pozitifler yapma olasılığının düşük olduğunu gösterir. Grafik analizi, sınıf bazında kesinlik değerlerinin genellikle yüksek olduğunu göstermektedir.taze elma için %87,5, çürük elma için %90,2, taze portakal için %92,3, çürük portakal için %93,3, taze muz için %96,6, çürük muz için %96,6, taze nar için %99,5 ve çürük nar için %97,8 olarak elde edilen kesinlik değerleri belirtilmiştir.

Model, genel olarak %94,2 kesinlik oranına ve 0,990 üzerinde bir güven değerine sahipken, kesinlik değeri 1'e yaklaşmıştır. Bu sonuçlar, modelin sınıfları doğru bir şekilde tanıma ve yanlış pozitifleri en aza indirme konusunda başarılı olduğunu göstermektedir. Kesinlik sonuç grafiği Şekil 4.2'de detaylı bir şekilde sunulmuştur.

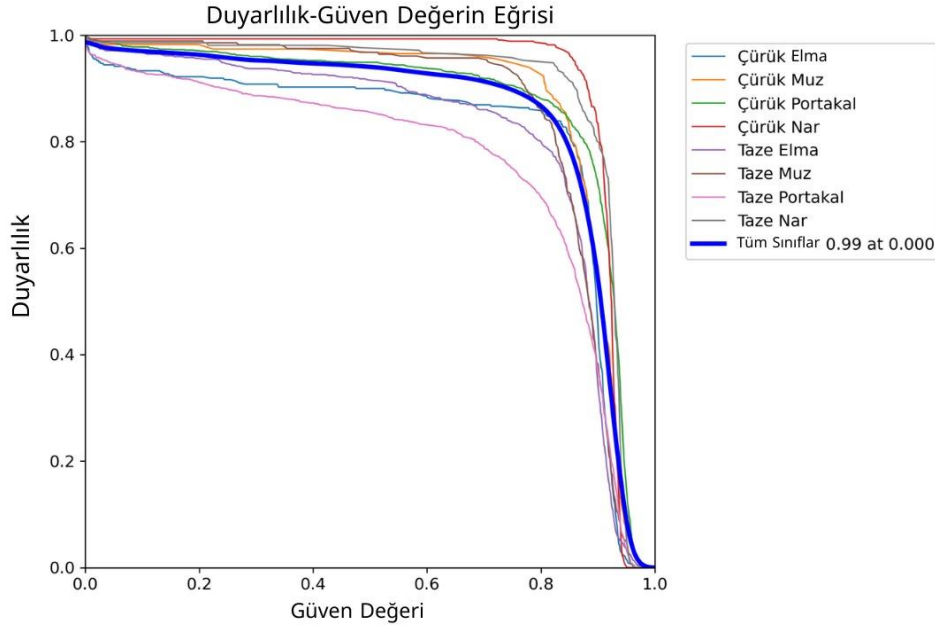


Şekil 4.2. YOLOv8 ile yapılan çalışmanın K-GD grafiği

- YOLOv8 Modelin Duyarlılık Sonuçların Analizi

Duyarlılık, bir modelin gerçek pozitif tahmin yeteneklerini değerlendiren ve yanlış negatifleri en aza indirme odaklı kritik bir performans metriğidir. Duyarlılık değerlendirmeleri grafiği, farklı sınıflar için elde edilen Recall değerlerini ayrıntılı bir şekilde incelememize olanak tanır. Duyarlılık, gerçek pozitif tahminlerin gerçek pozitiflerin toplam sayısına oranını ifade eder ve yanlış negatifleri minimize etmeyi amaçlar. Bu değer, modelin gerçek pozitifleri doğru bir şekilde tahmin etme yeteneğini yüksek çözünürlükte gösterir. İncelenen grafik, sınıf bazında Duyarlılık değerlerinin genellikle yüksek olduğunu vurgular. Taze elma için %91,2, çürük elma için %89,6, taze portakal için %84,5, çürük portakal için %94,5, taze muz için %96,5, çürük muz için %96,6, taze nar için %97,4 ve çürük nar için %99,3 olarak elde edilen Duyarlılık değerleri bu ayrıntılı analizin bir parçasıdır. Modelin genel performansı %93,7'lik bir Duyarlılık oranı ile ölçülmüştür ve 0 güven değerinde tüm meyvelerin tespiti sınıflarının 0,99 duyarlılık değerine ulaştığı gösterilmektedir.

Bu sonuçlar, modelin bu sınıfları gerçek pozitifleri başarılı bir şekilde tahmin etme konusunda etkili bir performans sergilediğini ortaya koymaktadır. Duyarlılık sonuç grafiği, modelin sınıflandırma yeteneğini daha detaylı bir şekilde anlamamıza katkı sağlamaktadır. Duyarlılık sonuç grafiği Şekil 4.3'te detaylı bir şekilde sunulmuştur.



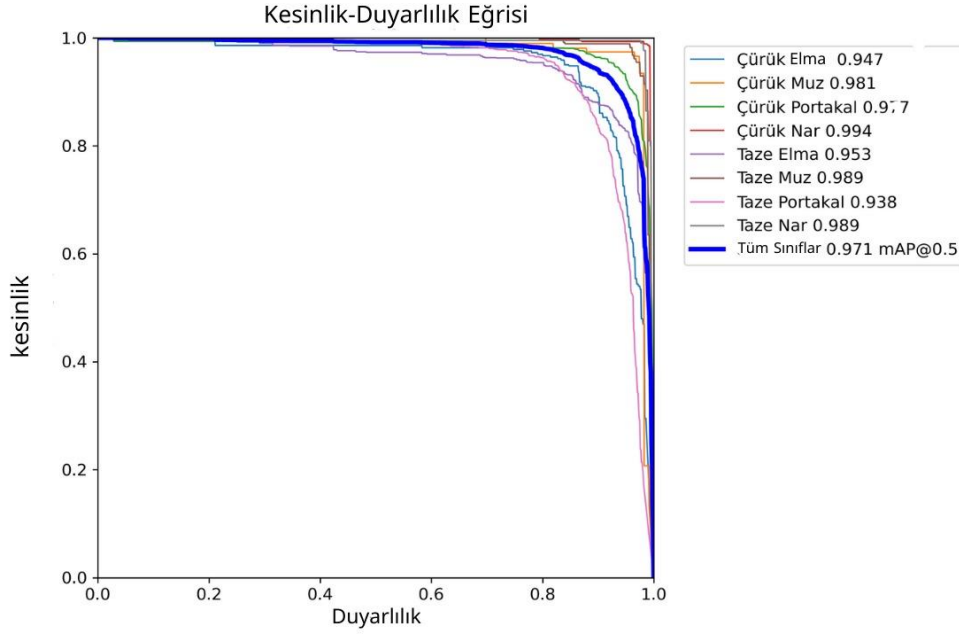
Şekil 4.3. YOLOv8 ile yapılan çalışmanın D-GD grafiği

YOLOv8 Modelin Kesinlik-Duyarlılık Sonuçların Analizi

Kesinlik, bir modelin yanlış pozitifleri minimize ederek doğru pozitif tahminlerini ne kadar başarılı bir şekilde gerçekleştirdiğini ölçen önemli bir performans metriğidir. Duyarlılık, gerçek pozitifleri ne kadar etkili bir şekilde tahmin ettiğini değerlendirir ve yanlış negatifleri minimize etmeyi hedefler. Kesinlik-Duyarlılık grafiği, çeşitli sınıflar için elde edilen Kesinlik ve Duyarlılık değerlerini ayrıntılı bir şekilde gösterir. Sınıf bazında analizde dikkat çeken noktalar şunlardır: taze elma için %98,9, çürük elma için %94,7, taze portakal için %93,8, çürük portakal için %97,7, taze muz için %98,8, çürük muz için %98,1, taze nar için %97,4 ve çürük nar için %99,3 olarak belirlenen Kesinlik-Duyarlılık değerleri.

Modelin genel performansını yansıtan %97,1 değerindeki ortalama kesinlik, farklı sınıflardaki doğruluk düzeylerini dengeli bir şekilde koruyabildiğini göstermektedir. Bu durum, modelin çoklu sınıflar arasında tutarlı bir performans sergileyebildiğini ve sınıflar arasında dengeli bir tahmin yeteneğine sahip olduğunu vurgular. Kesinlik-Duyarlılık

grafığı, modelin hem doğru pozitifleri hem de gerçek pozitifleri etkili bir şekilde tahmin etme kapasitesini görsel olarak açıklar. Şekil 4.4'te kesinlik-duyarlılık sonuç grafığı verilmiştir.



Şekil 4.4. YOLOv8 ile yapılan çalışmanın K-D grafığı

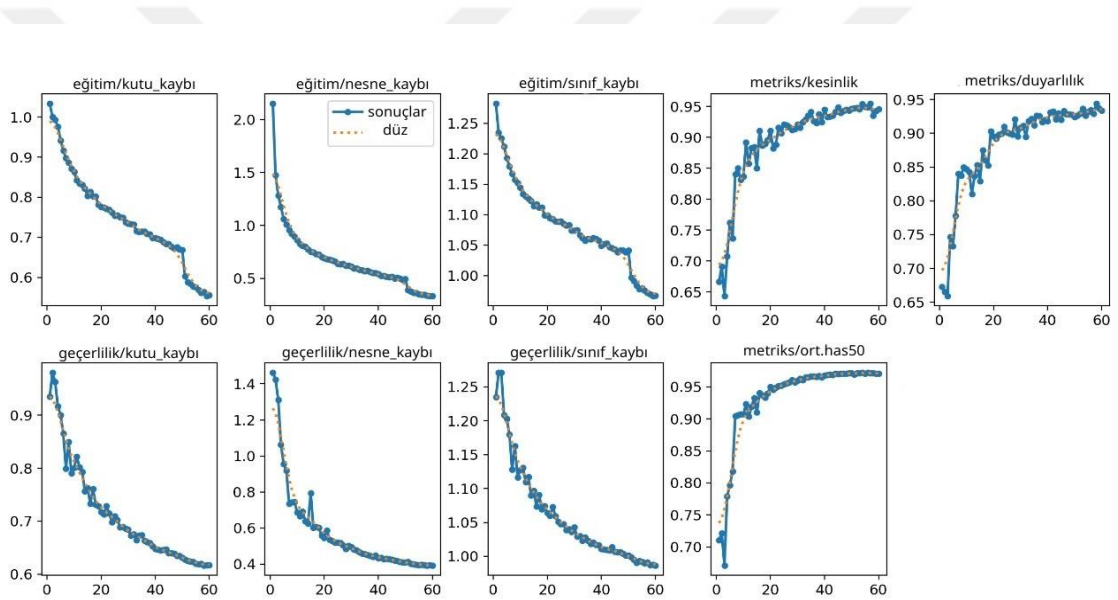
YOLOv8 Modelin kayıp fonksiyon Sonuçların Analizi

Kayıp fonksiyon, bir modelin tahminlerinin gerçek değerlere göre ne kadar sapma gösterdiğini ölçen ve eğitim sürecinde modelin iyileştirilmesine katkı sağlayan önemli bir metrik olarak kabul edilir. Bu bağlamda, YOLOv8 modelinin eğitim sürecinde elde edilen kayıp fonksiyon değerlerinin analizi, modelin performansının değerlendirilmesi açısından önem taşımaktadır. Ayrıca, YOLOv8'n algoritmasının nesne dedektörü olarak kullanıldığı veri kümesinde, 60 epok süresince sınıflandırma için hem eğitim hem de geçerleme kayıplarının incelenmesi bu değerlendirmenin bir parçasıdır. Kayıp fonksiyon değeri, modelin tahminlerinin gerçek değerlere olan uzaklığını nicel olarak ölçer. Bu değer minimize edilmesi, modelin daha doğru ve kesin tahminler yapabilmesi için eğitilmesini amaçlar. Düşük bir kayıp fonksiyon değeri, modelin eğitiminin daha etkili olduğunu ve tahminlerinin gerçek değerlere daha yakın olduğunu gösterir.

Analizimizde, kayıp fonksiyon değerlerini incelediğimiz grafiklerde genellikle eğitim süreci boyunca bu değerlerin azaldığını gözlemliyoruz. Bu durum, modelin zamanla daha doğru tahminler yapma yeteneğinin arttığını ve tahmin hatalarının

azaldığını gösterir. Dolayısıyla, eğitim sürecindeki bu olumlu gelişmeler, YOLOv8 modelinin performansının arttığını ve veri kümesindeki nesne dedektörü görevini daha etkili bir şekilde yerine getirdiğini yansıtmaktadır.

Bu bağlamda, kayıp fonksiyon değerlerinin düşmesi, modelin genel performansının iyileştiğini ve eğitim sürecindeki başarıların sürdürülebilir olduğunu göstermektedir. Elde edilen sonuçlar, modelimiz YOLOv8 algoritmasının başarılı bir nesne dedektörü olarak kullanımının ve 60 epok boyunca gerçekleştirilen sınıflandırma görevinin, modelin eğitimini optimize etme konusundaki etkileyici sonuçlarını vurgulamaktadır. Şekil 4.5'te kayıp fonksiyon değerleri gösterilmiştir.



Şekil 4.5. YOLOv8 kayıp fonksiyon değerlerin gösterimi

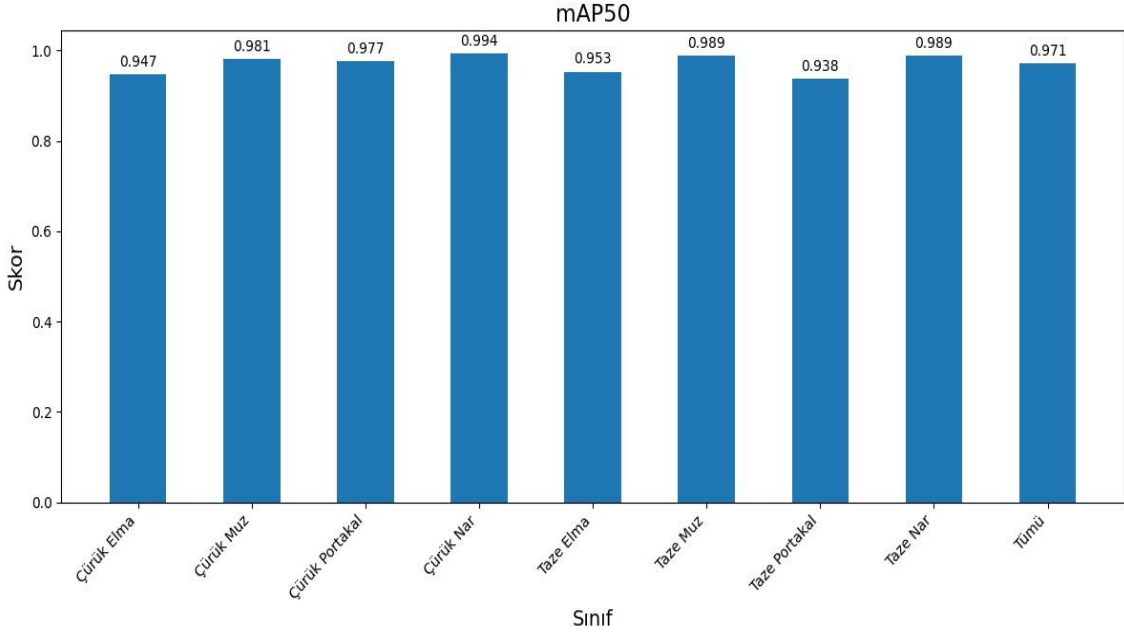
Tablo 4.1. YOLOv8 algoritmasının çıktularına dayanan değerlendirme sonuçları

Class	Kesinlik	Duyarlık	F1	Ort.Kesinlik 50
Çürük Elma	0,902	0,896	0,861	0,947
Çürük Muz	0,966	0,966	0,923	0,981
Çürük Portakal	0,933	0,945	0,909	0,977
Çürük Nar	0,978	0,993	0,923	0,994
Taze Elma	0,875	0,912	0,868	0,953
Taze Muz	0,966	0,965	0,902	0,989
Taze Portakal	0,923	0,845	0,858	0,938
Taze Nar	0,995	0,974	0,973	0,989
Tümü	0,942	0,937	0,941	0,971

Bu tablo, bir nesne algılama modelinin performansını değerlendiren metriklerini içermektedir. Çalışmada kullanılan modelin çürük ve taze meyve sınıflarındaki kesinlik, duyarlık, F1 skoru ve ortalamasını göstermektedir. Ayrıca, tüm sınıflar için ortalama kesinlik ve ortalama duyarlık değerleri sunulmuştur. tabloya göre, çürük ve taze meyve sınıfları için farklı performans ölçümleri elde edilmiştir. Çürük muz ve taze nar sınıfları, yüksek kesinlik (0,966 ve 0,995) ve duyarlık (0,966 ve 0,974) değerleri ile dikkat çekmektedir. Bu sınıfların F1 skorları da (0,923 ve 0,973) oldukça yüksektir, bu da modelin hem kesinlik hem de duyarlık açısından dengeli bir performans sergilediğini göstermektedir.

Öte yandan, taze portakal sınıfı için kesinlik (0,923) ve duyarlık (0,845) değerleri biraz daha düşüktür. Bu durum, modelin taze portakal meyvelerini diğer sınıflara göre daha az doğrulukla tanıma eğiliminde olduğunu gösterebilir. Bununla birlikte, tüm sınıflar için ortalama kesinlik (0,942) ve ortalama duyarlık (0,937) değerleri oldukça yüksektir, bu da genel olarak modelin iyi performans gösterdiğini işaret etmektedir.

Sonuç olarak, bu tablo, nesne algılama modelinin çeşitli meyve sınıflarını başarılı bir şekilde tanıma kabiliyetini ve performansını değerlendirmek için kullanılan kapsamlı metrikleri sunmaktadır. Modelin, özellikle çürük ve taze meyve sınıflarında yüksek doğrulukla çalıştığı görülmektedir, ancak tüm sınıflar için homojen bir performans sağlamak adına taze portakal gibi belirli sınıflar üzerinde iyileştirmeler yapılması gerekebilir.



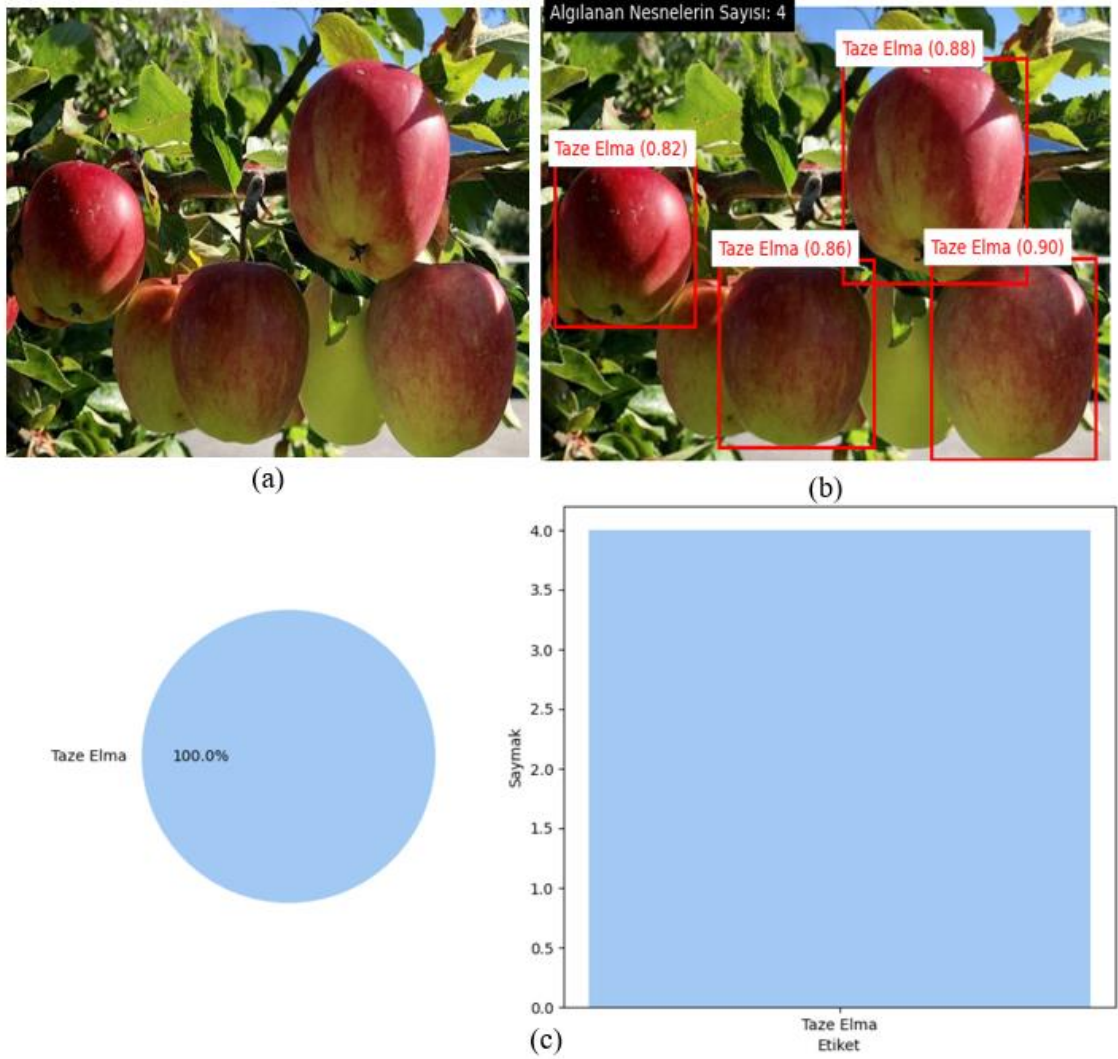
Şekil 4.6. YOLOv8 ile yapılan çalışmanın ortalama kesinlik sonuçlarının gösterimi

Tablo 4.1 ve Şekil 4.6'te YOLOv8 modelinin dört farklı meyve türü üzerinde gerçekleştirdiği detaylı incelemeyi içermektedir. Modelin performansı, zaman ve meyve tespiti üzerinde başarılı sonuçlar elde etmiştir. Özellikle, model olgunlaşmış ve çürük meyveleri yüksek F1 , duyarlılık ve kesinlik değerleriyle başarıyla tespit etmiştir. Bu başarı, modelin meyve sınıflarını doğru bir şekilde ayırt etme yeteneğini ve belirlenen eşik değerleri üzerinde yüksek kesinlikle tahminlerde bulunduğunu vurgulamaktadır. Algılama yeteneği ve sınıflandırma doğruluğunun yüksek olması, modelin meyve türleri arasındaki karmaşıklığı etkili bir şekilde yönetebildiğini gösterir.

4.1. Deneysel Uygulamalar

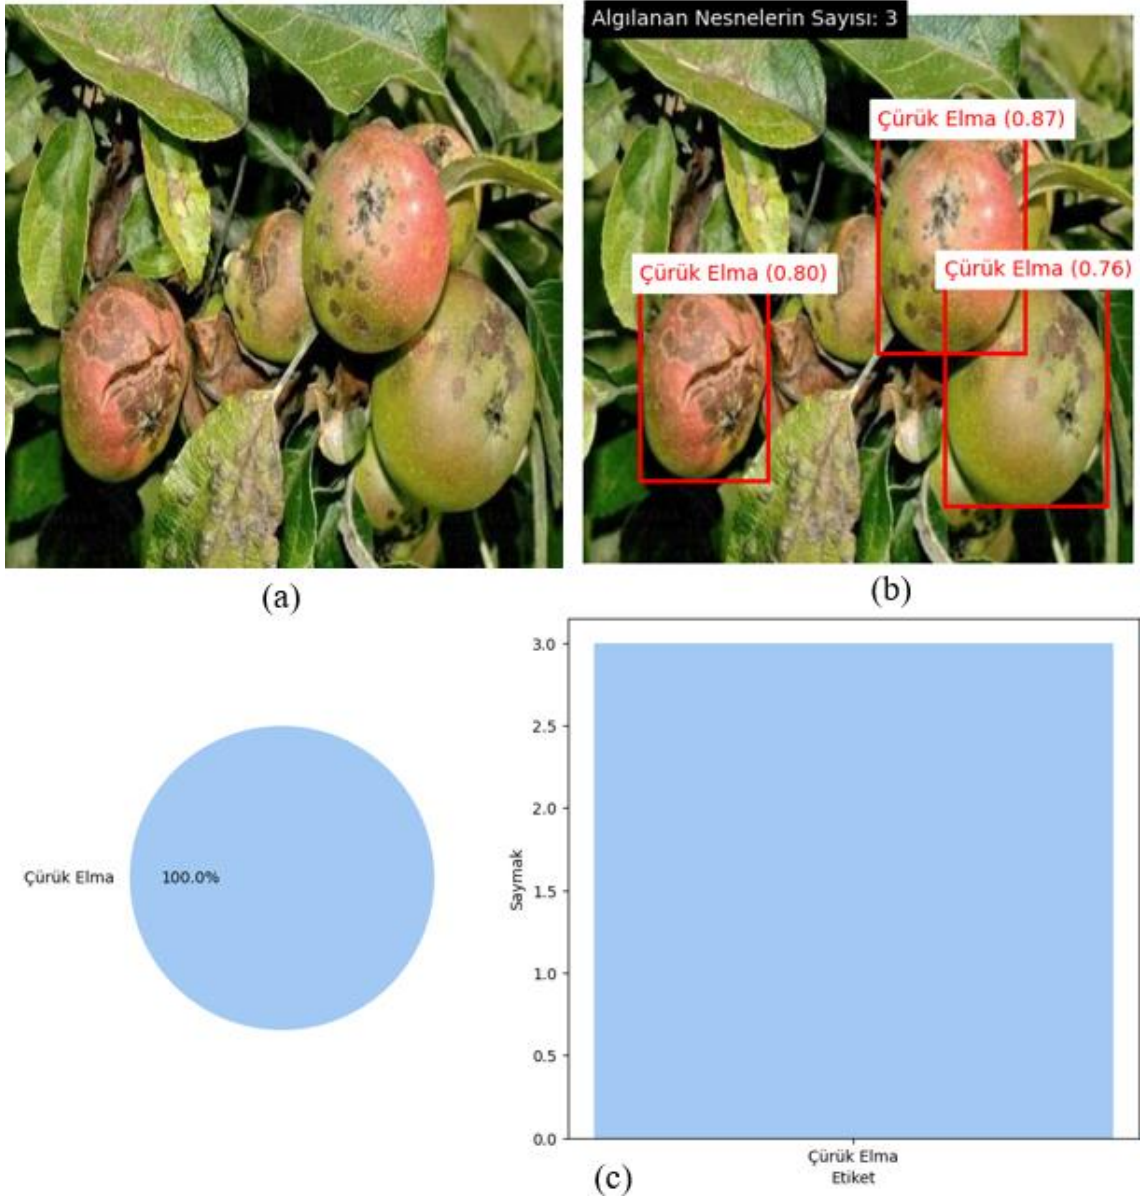
Geliştirdiğim YOLOv8 modeli, meyve tespiti, sınıflandırması ve teşhisi üzerine yoğunlaşan bir çalışma sunmaktadır. Bu çalışma, dört farklı meyve türü (elma, nar, portakal ve muz) üzerinde gerçekleştirilen detaylı bir incelemeyi içermektedir. Tez kapsamındaki bu araştırmalar, literatürde yaygın olarak karşılaşılan meyve tespiti ve sınıflandırması konularındaki diğer çalışmalarla karşılaştırılarak değerlendirilmiştir. Bu karşılaştırma, mevcut tezin ele aldığı meyve türleri üzerindeki özgün katkıları ve bu alandaki yenilikleri vurgulamayı amaçlamaktadır.

Geliştirilen modelin ve İHA ile elde edilen fotoğrafların, deneysel uygulamaların görsel bir temsilini sunmaktadır. Bu görseller, modelin gerçek dünya şartlarında meyve tespiti ve sınıflandırması konusundaki etkinliğini ve uygulanabilirliğini göstermektedir. Tezdeki deneysel sonuçlar, geliştirilen YOLOv8 modelinin başarılı performansını ve özgün katkılarını desteklemektedir.



Şekil 4.7. Elma meyvesi dalda iken deneysel uygulamaları (a) Elma görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.7'de modelin elma tespiti performansını görsel olarak sergilemektedir. İncelemede İHA tarafından sağlanan görüntülerin YOLOv8 modeli ile başarılı bir şekilde analiz edildiğini ve elma nesnelerinin doğru bir biçimde tespit edildiğini göstermektedir. Model, elma tespiti sırasında sayı ve sınıflandırma (meyvenin olgunlaşmış olduğunu) etkili bir performans sergilemiştir.



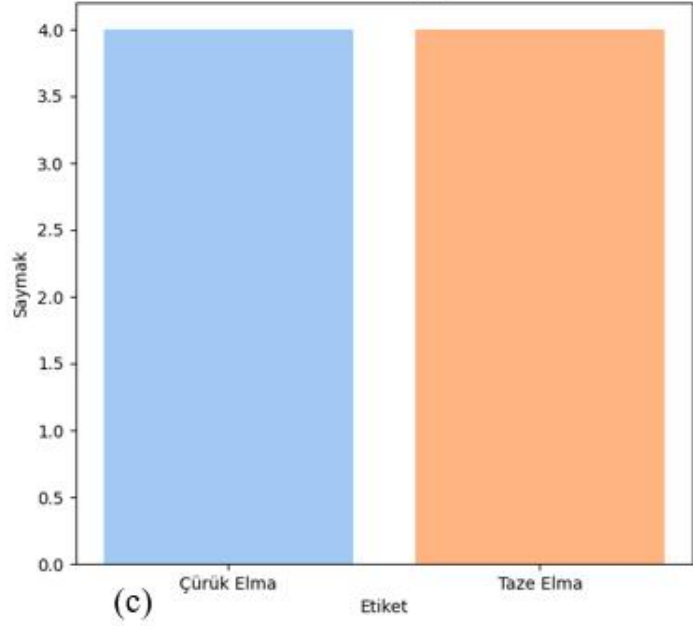

Şekil 4.8. Elma meyvesi dalda iken deneysel uygulamaları (a) Elma görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.8'de görüntülerin YOLOv8 modeli ile başarılı bir şekilde analiz edildiğini ve elma nesnelere doğru bir şekilde tespit edildiğini göstermektedir. Model, elma tespiti sayı ve sınıflandırma (elmayı çürümüş) etkili bir performans sergilemiştir.



(a)

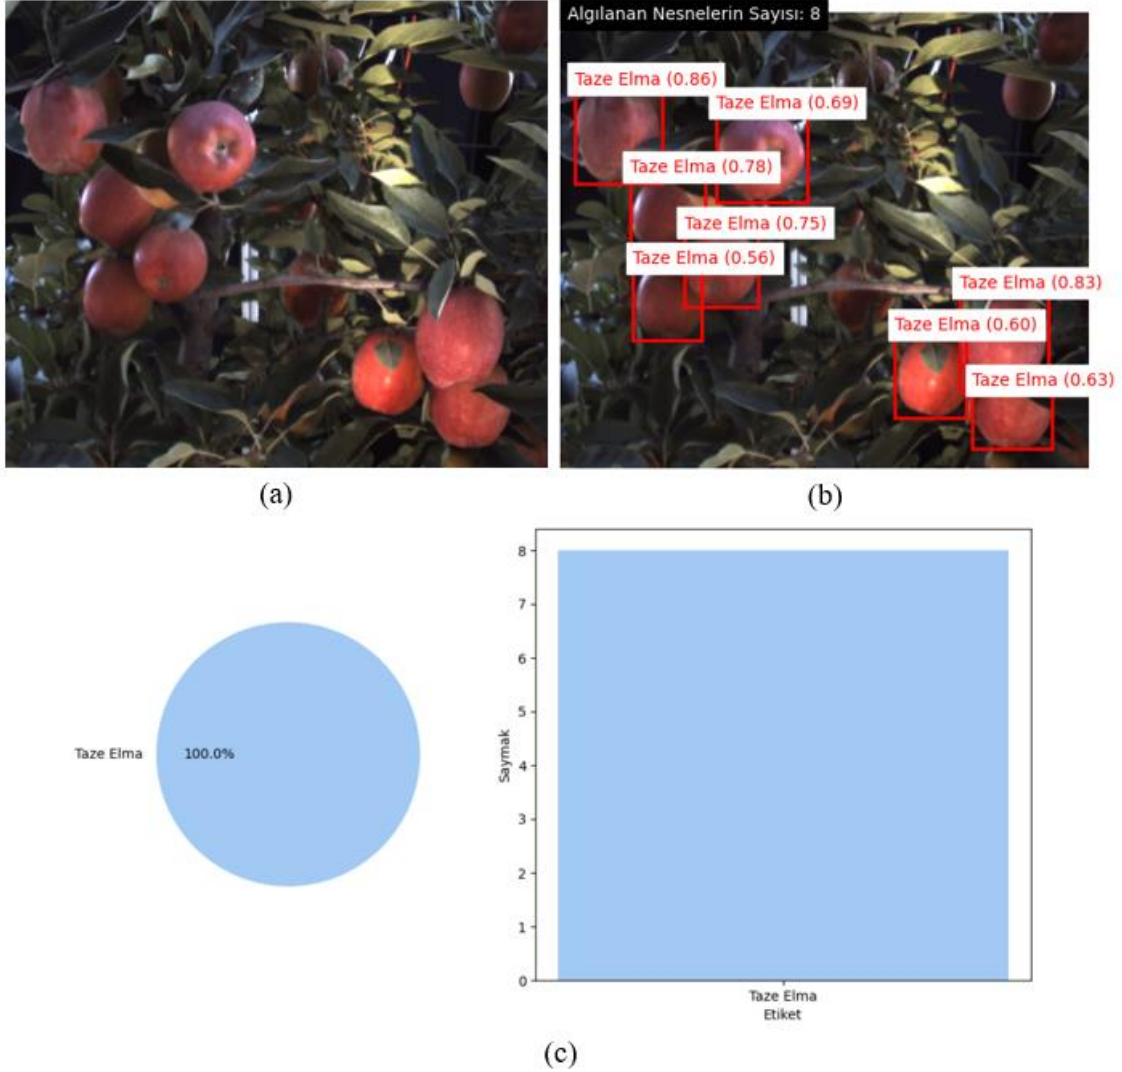
(b)



Şekil 4.9. Elma meyvesi deneysel uygulamaları (a) Elma görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

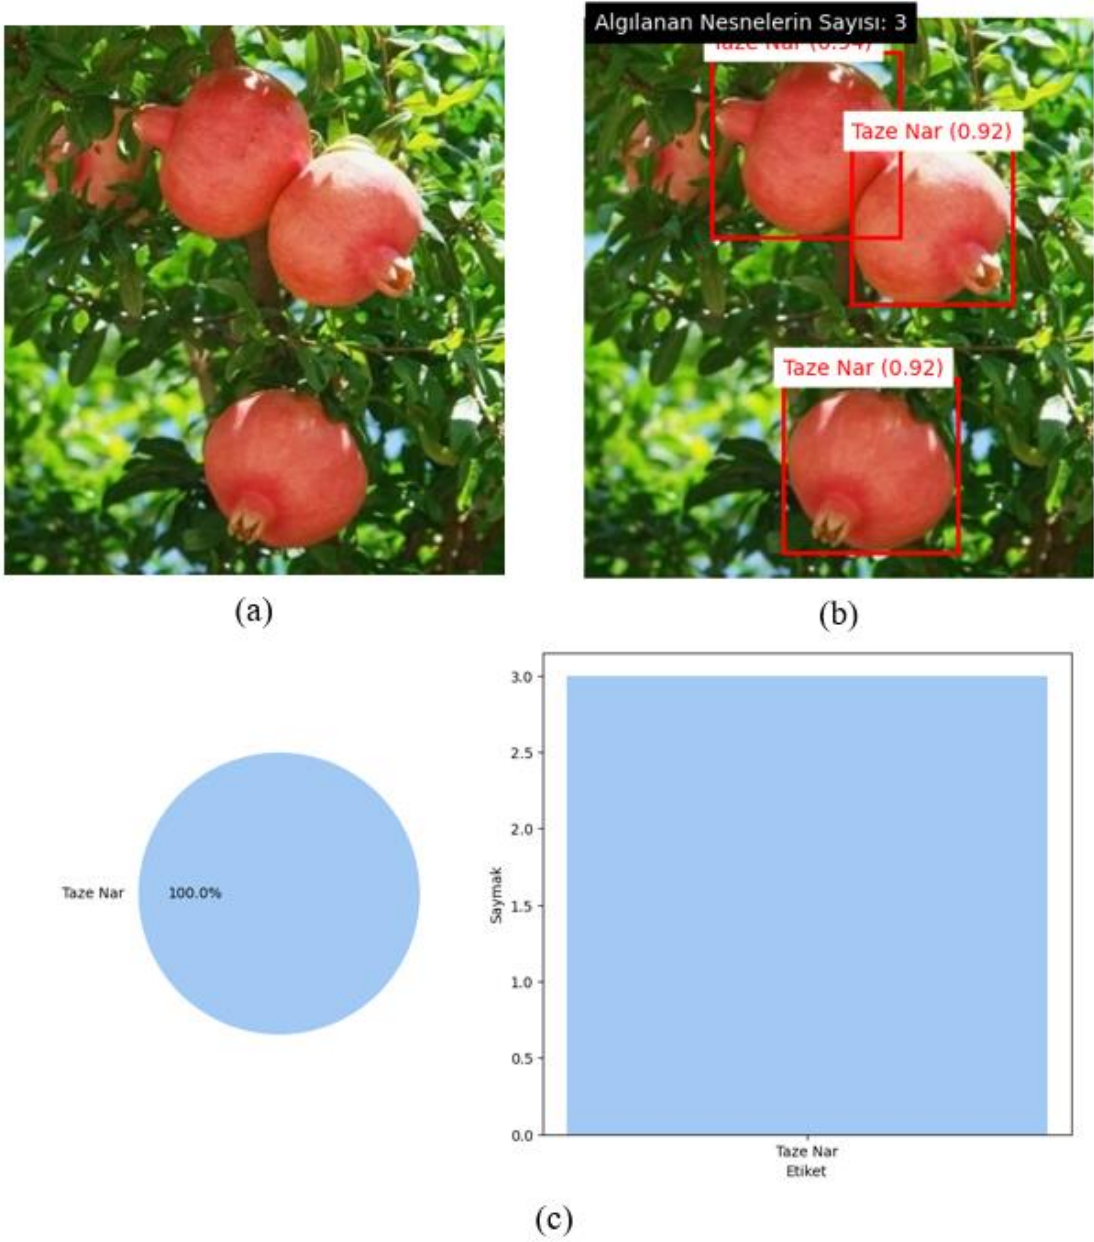
Şekil 4.9'da yer alan görsellerin, YOLOv8 modeli tarafından başarılı bir şekilde analiz edildiğini ve elma nesnelerinin doğru bir şekilde tespit edildiğini ifade etmektedir. Elma tespiti, özellikle karışım bir görüntü içerisinde (olgunlaşmış ve çürümüş elmaların ayrımı dahil olmak üzere) doğru bir şekilde gerçekleştirilmiş ve bu tespitler, toplam elma sayılarını, sadece olgunlaşmış elmaların sayısını ve çürümüş elmaların sayısını içeren bir grafikte gösterilmiştir. görsel analiz sonuçları, YOLOv8 modelinin karmaşık sahnelerdeki elma nesnelerini doğru bir biçimde sınıflandırabildiğini ve tespit

edebildiğini göstermektedir. Ayrıca, olgunlaşmış ve çürümüş elmalar arasındaki ayrımın başarılı bir şekilde gerçekleştirilmesi, modelin sınıflandırma doğruluğunun yüksek olduğunu işaret etmektedir.



Şekil 4.10. Elma meyvesi dalda iken deneysel uygulamaları (a) Elma görşeli, (b) Görşelin analizi, (c) Analiz görşelin grafiđi

Şekil 4.10'da yer alan görşeller, akşam saatlerinde çekilmiş olmalarına rağmen, çeşitli ışık ve görüntüleme koşullarına maruz kaldıkları durumda bile YOLOv8 modelinin elma tespiti ve sınıflandırma gerçekleştirdiğini göstermektedir. Bu durum, modelin dayanıklılığı ve genelleme yeteneđi açısından önemli bir gözlemi ortaya koymaktadır.




Şekil 4.11. Nar meyvesi dalda iken deneysel uygulamaları (a) Nar görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

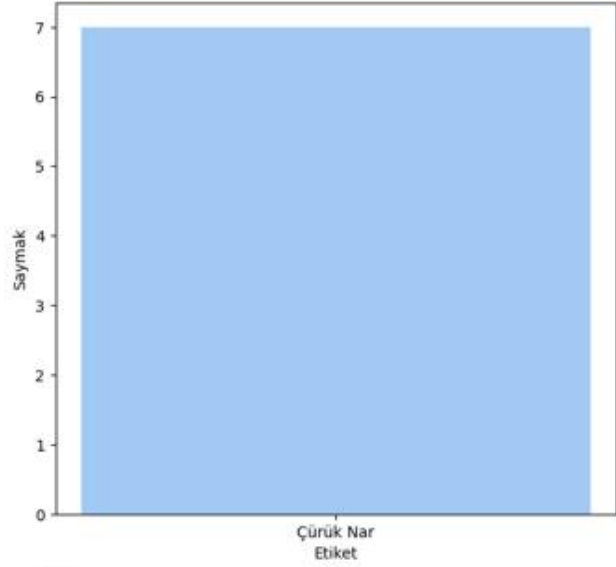

Şekil 4.11'de İHA tarafından sağlanan görüntüler, detaylı bir inceleme sonucunda YOLOv8 modeli tarafından başarılı bir şekilde analiz edilmiş ve nar nesnelere doğru bir biçimde tespit edilmiştir. Model, özellikle nar tespiti sürecinde sayı ve sınıflandırma (meyvenin olgunlaşmış olduğu) konularında etkili bir performans göstermektedir .



(a)



(b)



(c)

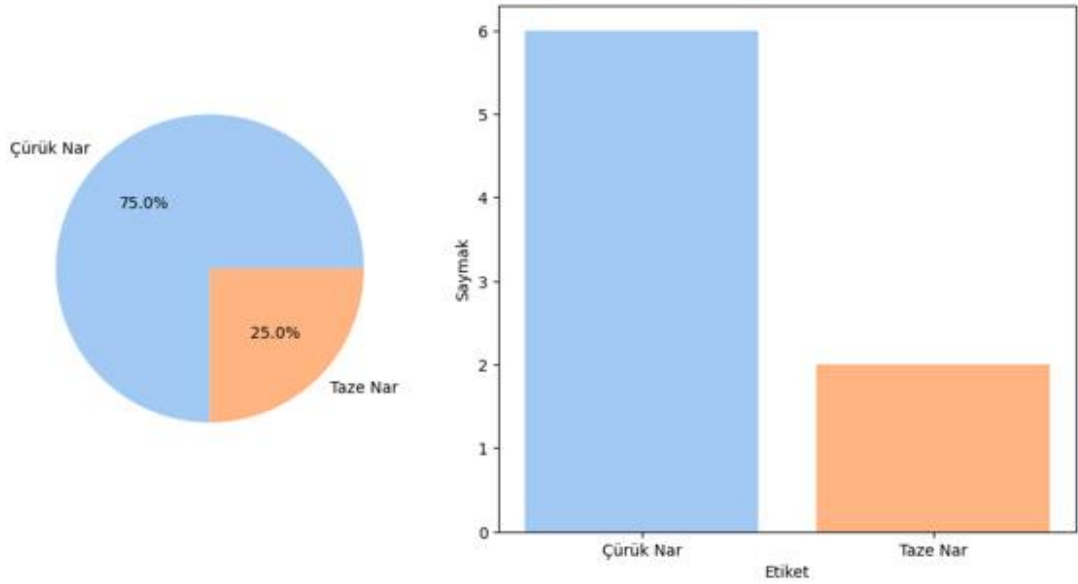
Şekil 4.12. Nar meyvesi deneysel uygulamaları (a) Nar görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.12'de görüntülerin YOLOv8 modeli ile başarılı bir şekilde analiz edildiğini ve nar nesnelerinin doğru bir şekilde tespit edildiğini göstermektedir. Model, nar tespiti sayı ve sınıflandırma (nar çürük olduğu) etkili bir performans gösterilmiştir.



(a)

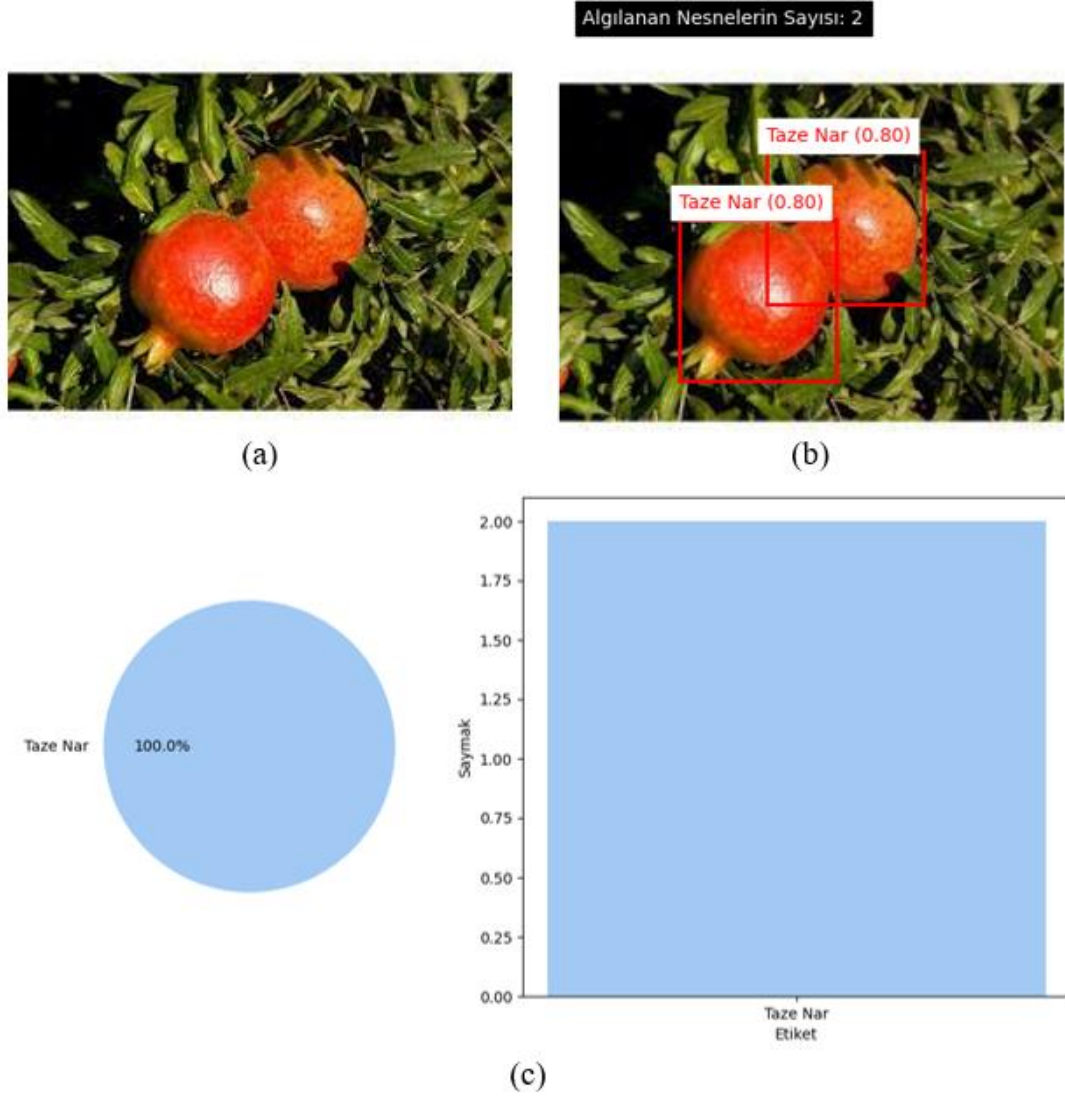
(b)



(c)

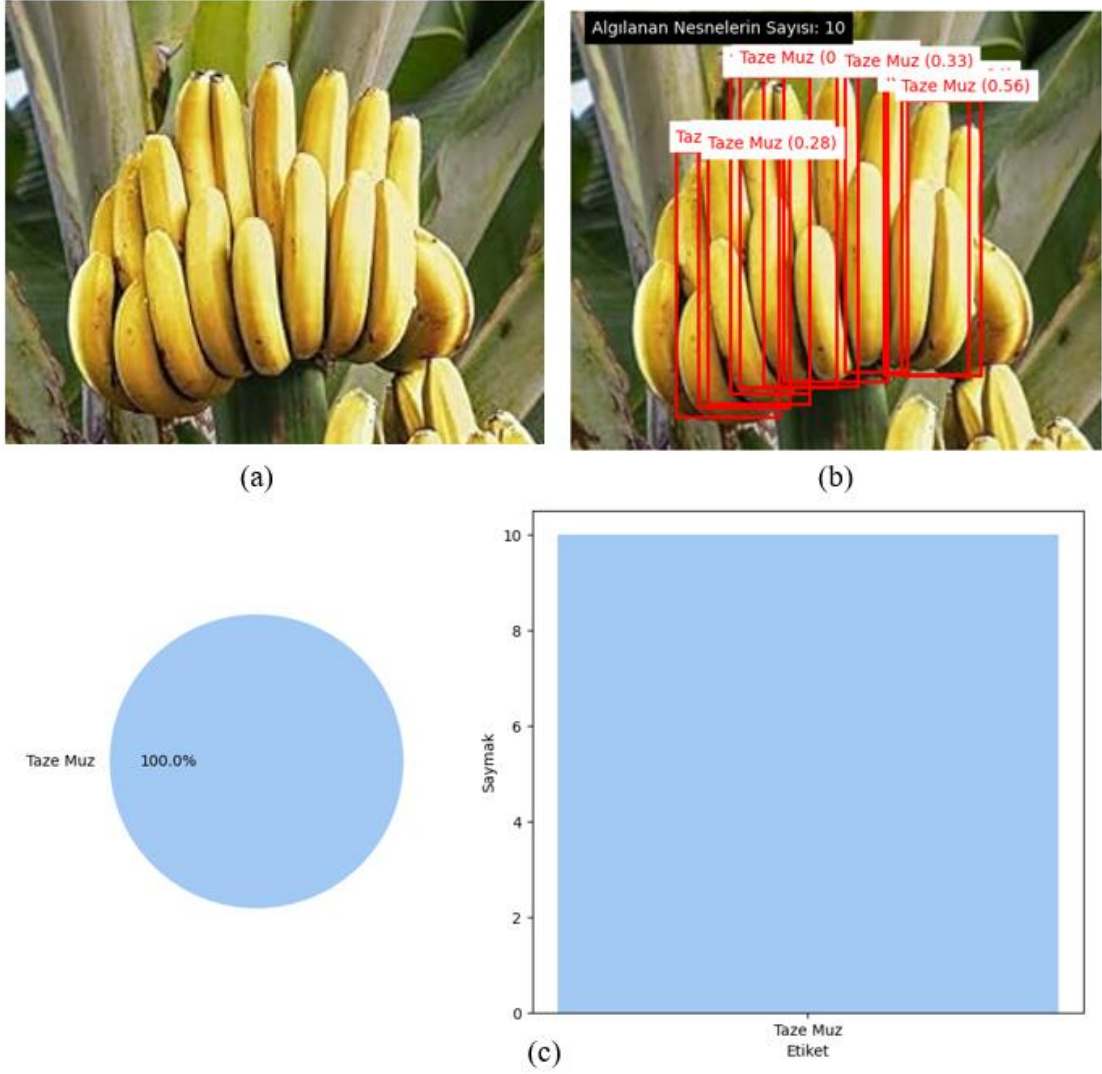
Şekil 4.13. Nar meyvesi deneysel uygulamaları (a) Nar görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.13'teki görseller, YOLOv8 modelinin başarılı bir şekilde analiz edildiğini ve nar nesnelerinin doğru bir şekilde tespit edildiğini göstermektedir. Özellikle karışık bir görüntü içinde, örneğin olgunlaşmış ve çürümüş narları ayırt etme becerisiyle birlikte, nar tespiti doğru bir şekilde gerçekleştirilmiştir. Bu tespitler, toplam nar sayılarını, sadece olgunlaşmış narların sayısını ve çürümüş narların sayısını içeren bir grafikte görsel analiz sonuçlarına yansıtılmıştır.



Şekil 4.14. Nar meyvesi deneysel uygulamaları (a) Nar görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.14'teki görseller, akşam saatlerinde çekilmiş olmalarına rağmen, çeşitli ışık ve görüntüleme koşullarına maruz kaldıkları durumda dahi YOLOv8 modelinin başarılı bir şekilde nar tespiti, sayımı ve sınıflandırma gerçekleştirdiğini vurgulamaktadır.

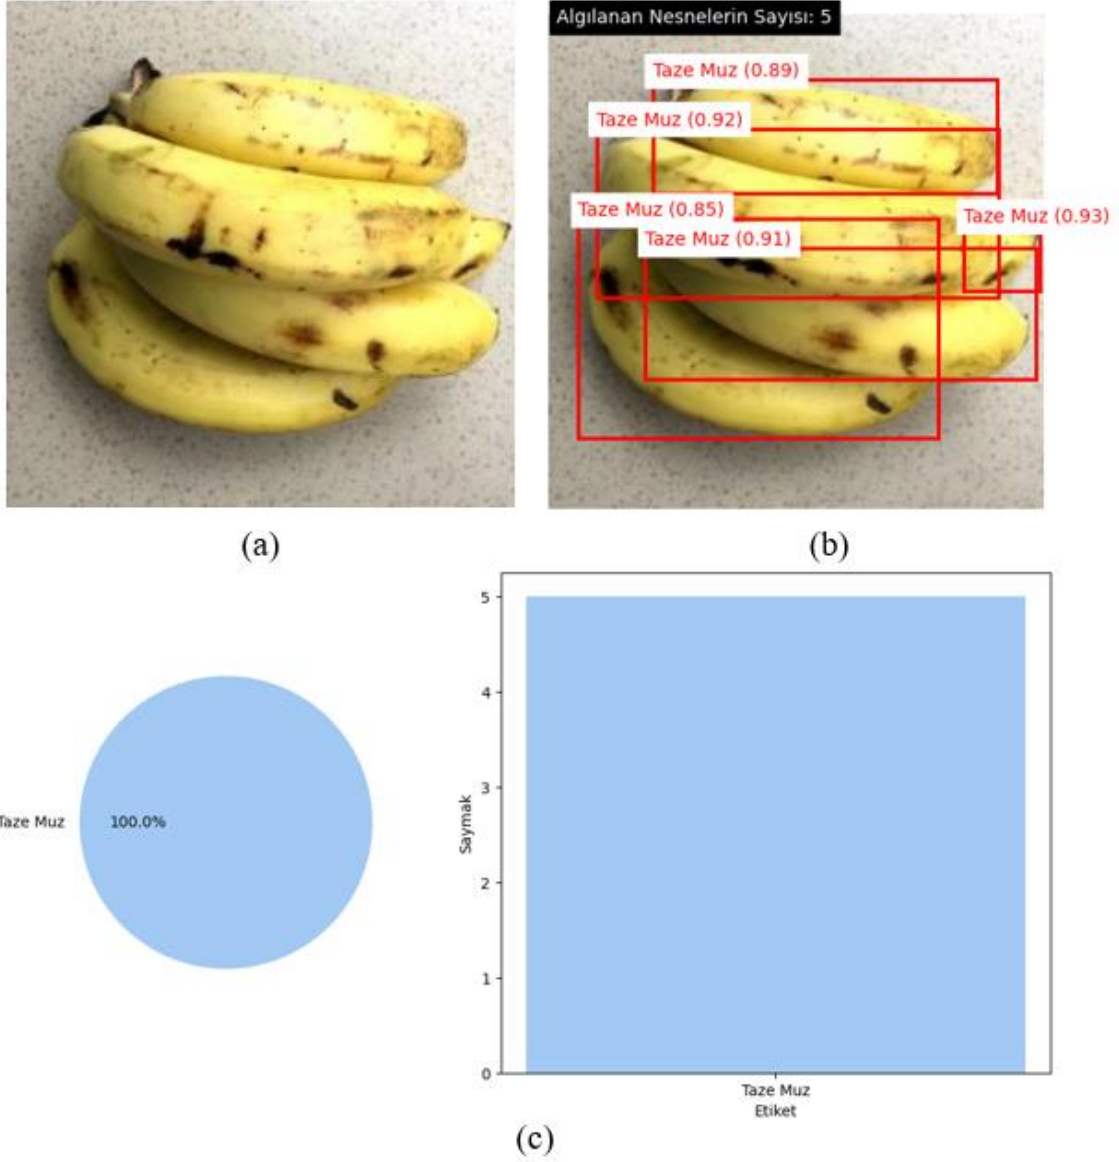


Şekil 4.15. Muz meyvesi deneysel uygulamaları (a) Muz görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.15'teki görüntüler, muzların ağaçta bulunduğu anlarda çekilmiş olup, YOLOv8 modeli tarafından detaylı bir inceleme sonucunda başarılı bir şekilde analiz edilmiş ve muz nesnelerinin doğru bir biçimde tespit edildiğini göstermektedir. Model, özellikle muzların yan yana olduğu ve birleştirme şeklinde bulunduğu durumlarda dahi tespit sürecinde sayı ve sınıflandırma (meyvenin olgunlaşmış olduğu) konularında etkili bir performans sergilemektedir.

Bu durum, YOLOv8 modelinin meyve nesnelerini karmaşık durumlarda dahi doğru bir şekilde sınıflandırma ve tespit etme yeteneğini yansıtmaktadır. Özellikle, muzların birbirine yakın olduğu ve birleşik durumda bulunduğu durumlarda dahi modelin

başarılı sonuçlar elde etmesi, algoritmanın geniş bir uygulama yelpazesine sahip olabileceğini göstermektedir.

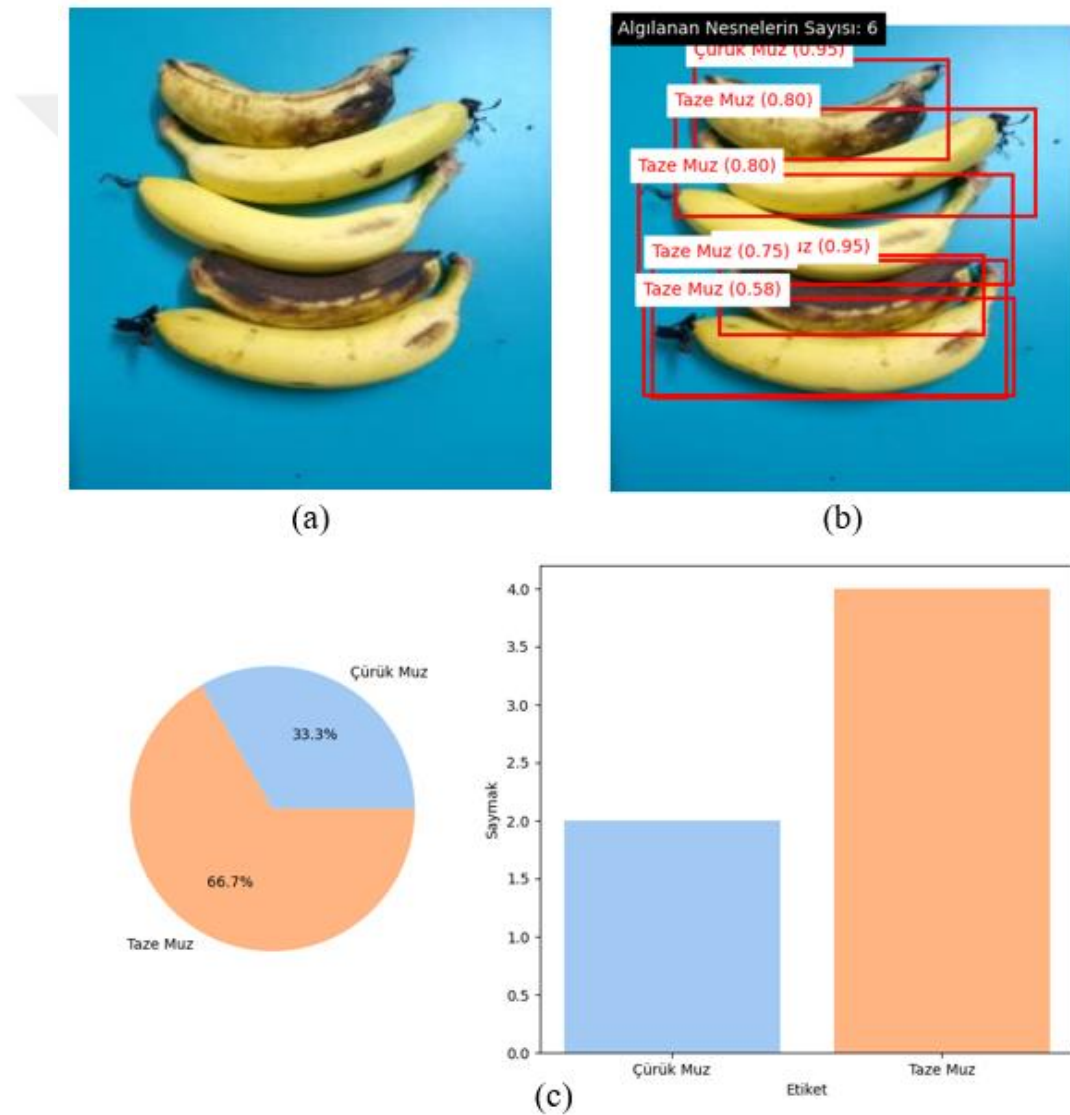


Şekil 4.16. Muz meyvesi deneysel uygulamaları (a) Muz görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.16'daki görüntüler, detaylı bir inceleme sonucunda YOLOv8 modeli tarafından başarılı bir şekilde analiz edilmiş ve muz nesnelerinin doğru bir biçimde tespit edildiğini göstermektedir. Model, özellikle muzların yan yana olduğu ve birleştirme

şeklinde bulunduğu durumlarda dahi tespit sürecinde sayı ve sınıflandırma (meyvenin olgunlaşmış olduğu) konularında etkili bir performans sergilemektedir.

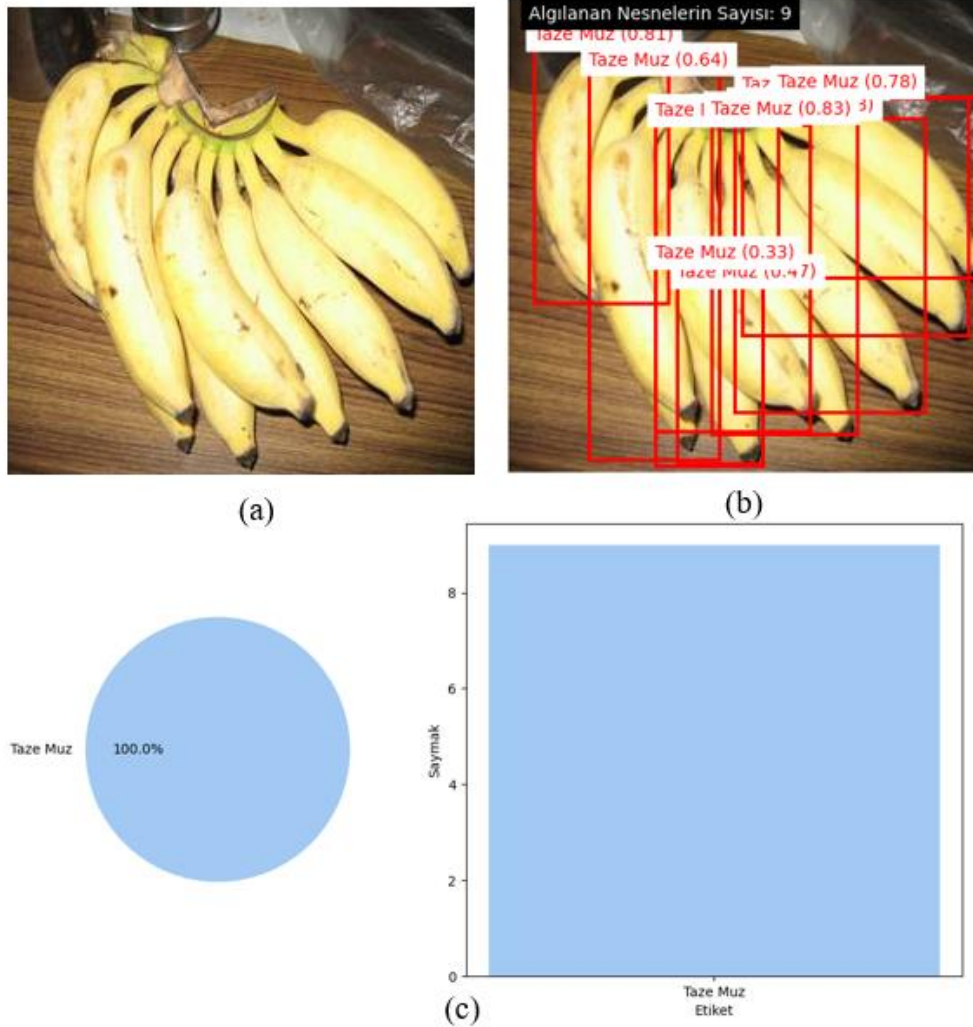
Bu durum, YOLOv8 modelinin meyve nesnelerini karmaşık durumlarda dahi doğru bir şekilde sınıflandırma ve tespit etme yeteneğini yansıtmaktadır. Özellikle, muzların birbirine yakın olduğu ve birleşik durumda bulunduğu durumlarda dahi modelin başarılı sonuçlar elde etmesi, algoritmanın geniş bir uygulama yelpazesine sahip olabileceğini göstermektedir.



Şekil 4.17. Muz meyvesi deneysel uygulamaları (a) Muz görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

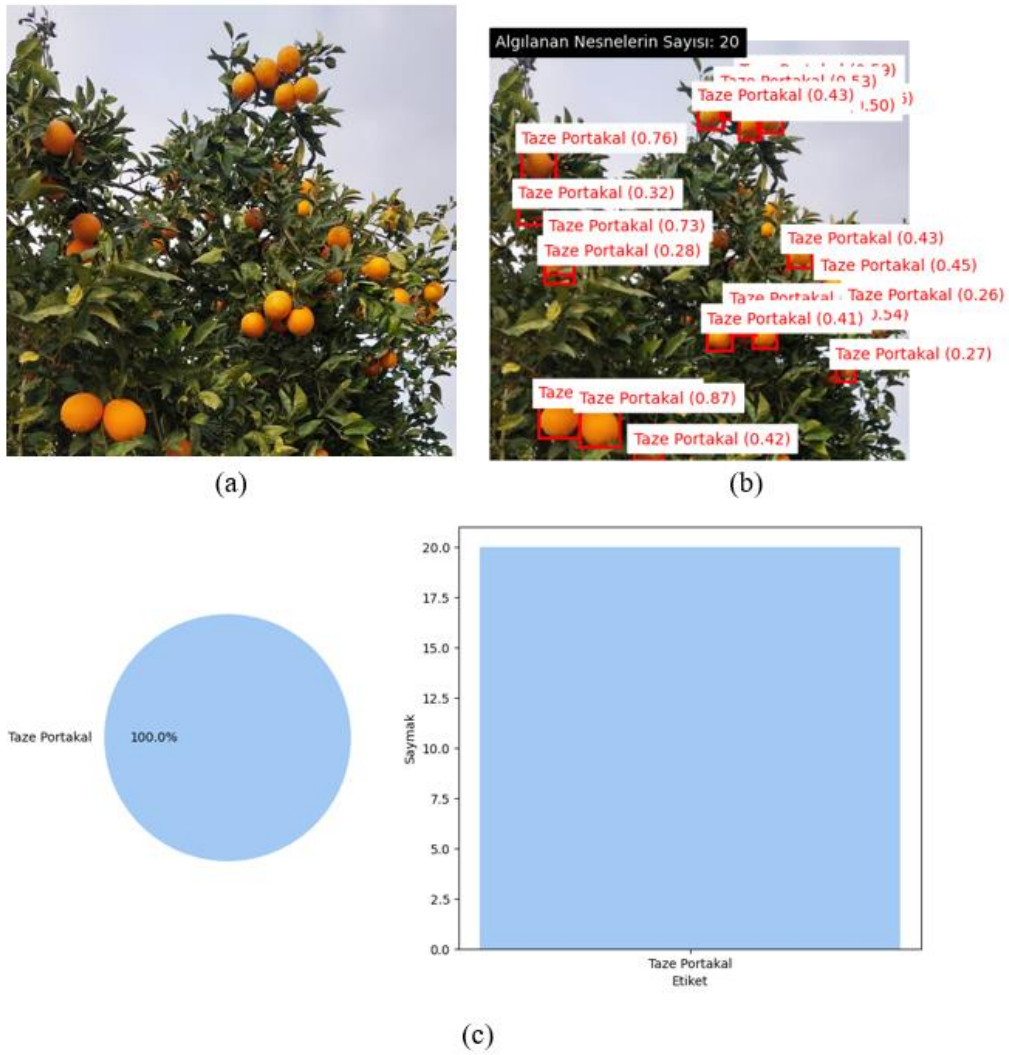
Şekil 4.17'deki karmaşık görüntüler hem taze muz hem de çürük muz içermekte olup, detaylı bir incelemenin ardından YOLOv8 modeli tarafından başarıyla analiz edilmiş ve muz nesnelerinin doğru bir şekilde tespit edildiğini göstermektedir. Model, çürük ve taze muzları doğru bir şekilde ayırt etme yeteneği göstererek sayı ve sınıflandırma açısından etkili bir performans sergilemektedir.

Ayrıca, çürük muzların ve taze muzların sayısını belirten grafiklerle birlikte modelin bu ayrımı başarılı bir şekilde gerçekleştirdiği görülmektedir. Bu grafikler, modelin sayı ve sınıflandırma konularında sağlam bir performans sergileyerek meyve tespiti ve çürük teşhisi alanında kullanışlı bir araç olabileceğini göstermektedir.



Şekil 4.18. Muz meyvesi deneysel uygulamaları (a) Muz görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

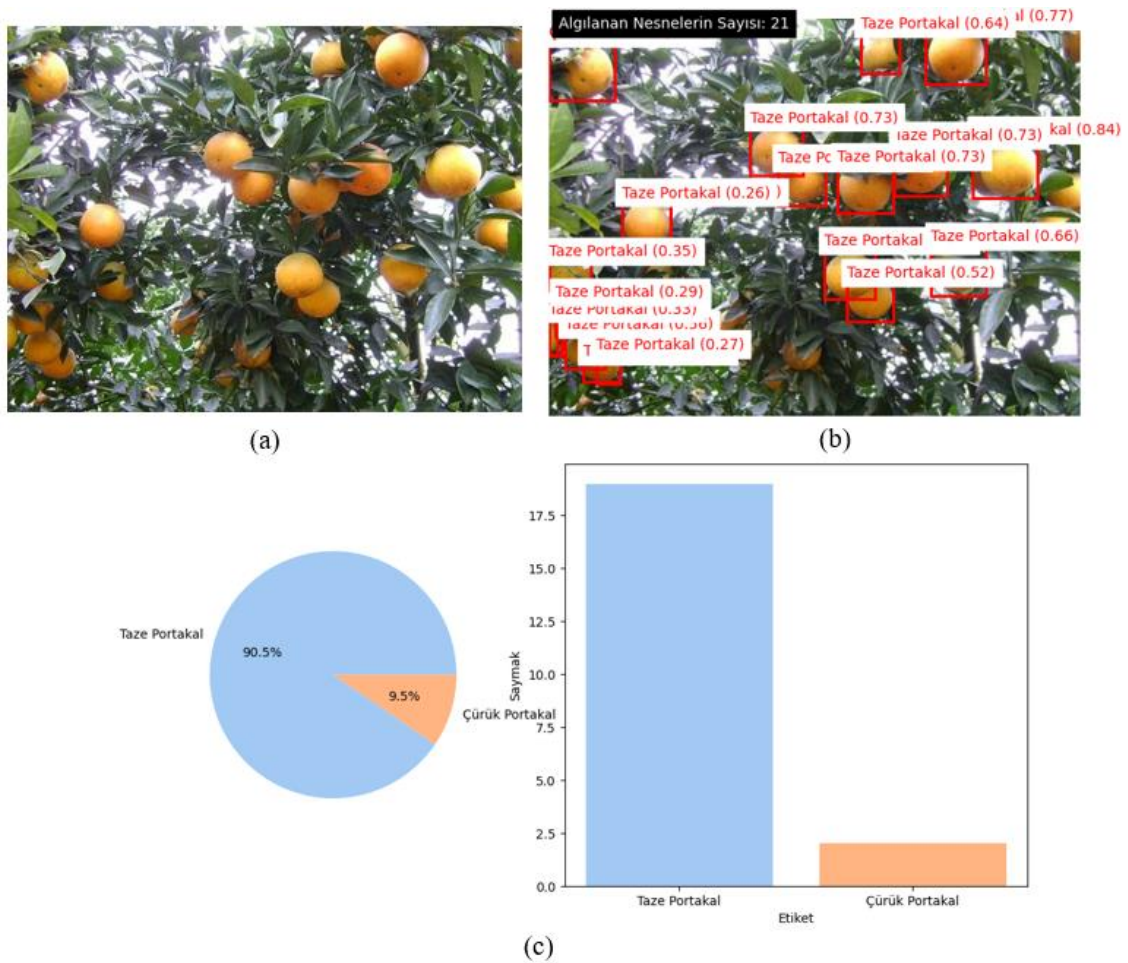
Şekil 4.18'deki görüntüler, akşam saatlerinde yüksek ışık altında çekilmiş olmalarına rağmen, YOLOv8 modelinin farklı ışık ve görüntüleme koşullarına maruz kaldığında dahi muzları başarılı bir şekilde tespit ettiğini, saydığını ve sınıflandırdığını doğrulamaktadır. Bu durum, modelin görüntüleme şartlarındaki değişkenliklere karşı dirençli olduğunu ve çeşitli çevresel faktörlere karşı güçlü bir performans sergilediğini göstermektedir. Bu sonuçlar, YOLOv8 modelinin pratik uygulamalarda çeşitli ışık koşullarında güvenilir bir şekilde kullanılabilirliğini işaret etmektedir.



Şekil 4.19. Portakal meyvesi deneysel uygulamaları (a) Portakal görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.19'da yer alan görüntüler, YOLOv8 modelinin portakalları ağaçtayken başarılı bir şekilde tespit ettiğini, saydığını ve sınıflandırdığını güçlü bir şekilde ortaya

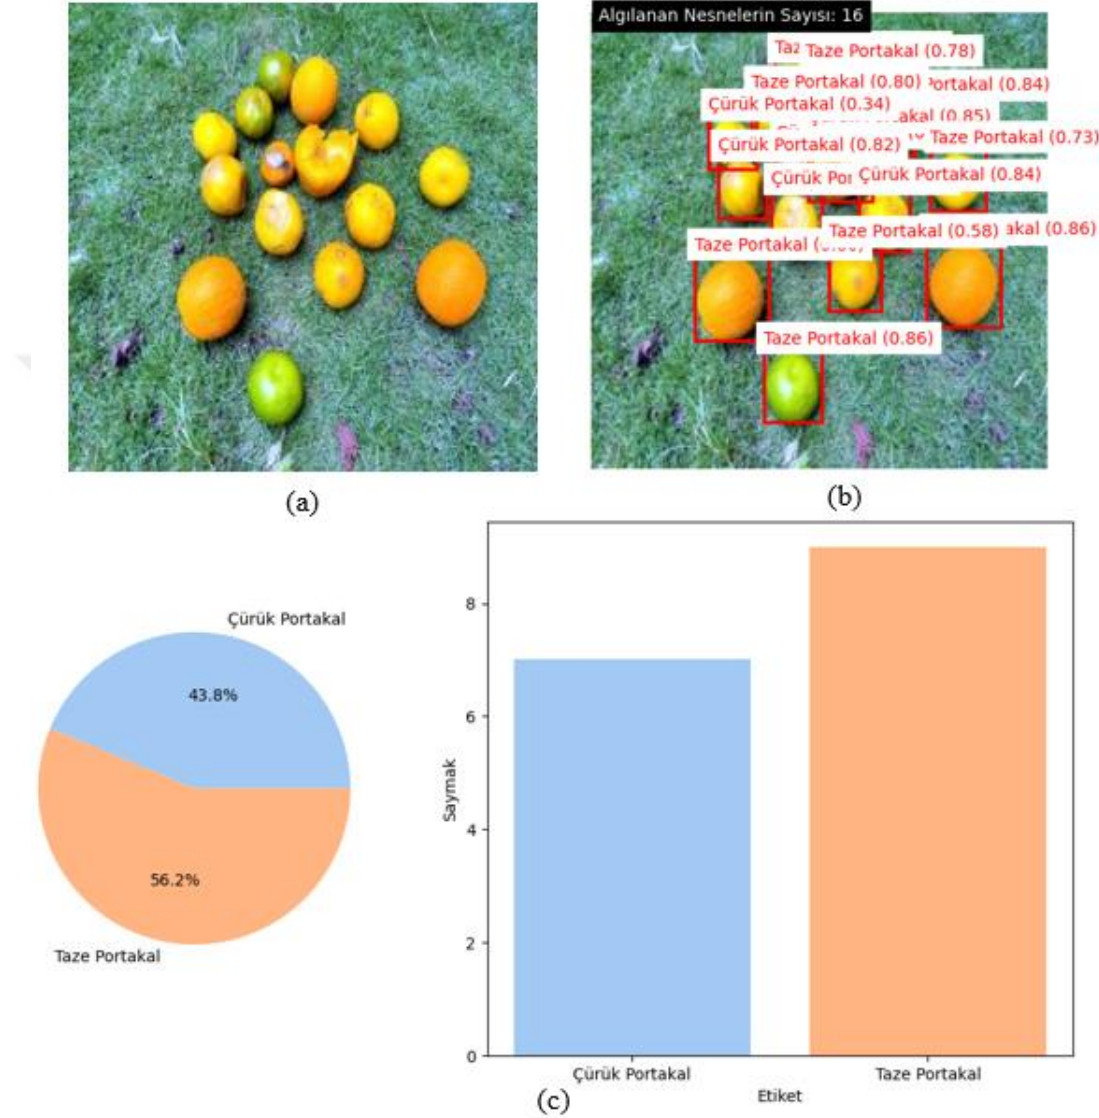
koymaktadır. Ayrıca, gözlemlenen portakalların bazılarının yapraklarla kısmen kaplı olmasına rağmen modelin bu durumu başarıyla ele alabildiği görülmüştür. Yani, yapraklarla kısmen örtülü portakalların tanınması ve sınıflandırılması konusundaki başarısı, YOLOv8 modelinin nesne tespiti konusundaki güçlü yeteneklerini vurgular. Bu durum, modelin nesnelerin yalnızca bir kısmının görülebildiği durumları dahi etkili bir şekilde işleyebildiğini göstererek, gerçek dünya uygulamalarında pratik bir çözüm sunabileceğini düşündürmektedir.



Şekil 4.20. Portakal meyvesi deneysel uygulamaları (a) Portakal görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.20'deki gözlemler, YOLOv8 modelinin portakalları ağaçtayken başarılı bir şekilde tespit etme, sayma ve sınıflandırma yeteneklerini güçlü bir biçimde sergilemektedir. Ek olarak, gözlemlenen portakalların bir kısmının çürük olabileceği durumlarına rağmen, modelin bu tür durumlarla başarılı bir şekilde başa çıktığı

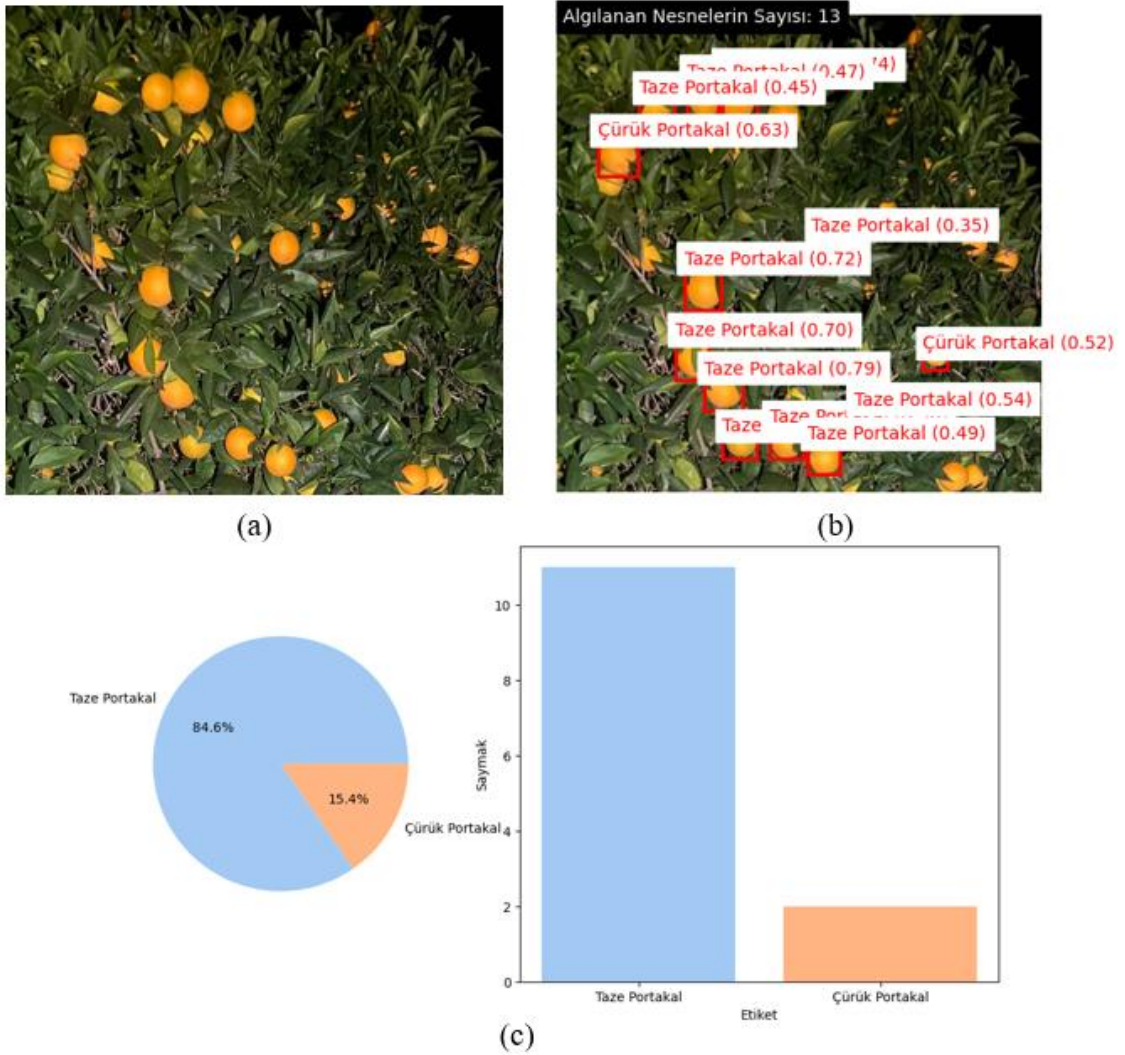
kaydedilmiştir. Bu bağlamda, çürük portakalları doğru bir şekilde tanımlama ve sınıflandırmadaki başarısı, YOLOv8 modelinin taze ve çürük portakalları ayırt etme konusundaki etkileyici yeteneklerini vurgulamaktadır.



Şekil 4.21. Portakal meyvesi deneysel uygulamaları (a) Portakal görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.21'deki görsellerin, YOLOv8 modeli tarafından başarılı bir şekilde analiz edildiği ve portakal nesnelere doğru bir şekilde tespit edildiğini ifade etmektedir. Portakal tespiti, özellikle karışım bir görüntü içerisinde (taze ve çürümüş portakalların ayrımı dahil olmak üzere) doğru bir şekilde gerçekleştirilmiş ve bu tespitler, toplam portakal sayılarını, sadece taze portakalların sayısını ve çürümüş portakalların sayısını içeren bir grafikte gösterilmiştir. Görsel analiz sonuçları, YOLOv8 modelinin karmaşık

sahnelerdeki portakal nesnelere doğru bir biçimde sınıflandırabildiğini ve tespit edebildiğini göstermektedir. Ayrıca, taze ve çürümüş portakallar arasındaki ayrımı başarılı bir şekilde gerçekleştirmesi, modelin sınıflandırma doğruluğunun yüksek olduğunu işaret etmektedir. Bu sonuçlar, YOLOv8 modelinin meyve tespiti ve sınıflandırma konusundaki güçlü yeteneklerini vurgulamaktadır. Karmaşık sahnelerdeki farklı portakal durumlarını başarıyla ayırt etme yeteneği, tarım uygulamalarında kalite kontrolü ve hasat süreçlerinde etkili bir şekilde kullanılabilirliğini artırmaktadır.



Şekil 4.22. Portakal meyvesi deneysel uygulamaları (a) Portakal görseli, (b) Görselin analizi, (c) Analiz görselin grafiği

Şekil 4.22'deki görüntüler, YOLOv8 modelinin akşam saatlerinde portakalları ağaçta başarılı bir şekilde tespit ettiğini, saydığını ve sınıflandırdığını güçlü bir şekilde ortaya koymaktadır. Modelin, portakalların ağaç üzerindeki dağılımını ve

konumunu doğru bir şekilde belirleyebilmesi, tarım alanlarında otomatik hasat ve kalite kontrol süreçlerinin etkin bir şekilde yönetilmesini sağlayabilir. Ayrıca, gözlemlenen portakalların bazılarının yapraklarla kısmen kaplı olmasına rağmen, modelin bu durumu başarıyla ele alabildiği görülmüştür. Yani, yapraklarla kısmen örtülü portakalların tanınması ve sınıflandırılması konusundaki başarısı, YOLOv8 modelinin nesne tespiti konusundaki güçlü yeteneklerini vurgular. Modelin, değişen ışık koşullarına maruz kaldığında bile güvenilir bir performans sergileyebilmesi, tarım uygulamalarında çeşitli hava ve aydınlatma koşullarında kullanılabilirliğini artırır. Bu özellikle, günün farklı saatlerinde çekilen görüntülerde bile modelin portakalları doğru bir şekilde algılayabildiğini gösterir. Bu durum, YOLOv8 modelinin pratik uygulamalarda çeşitli ortam koşullarında güçlü bir performans sergileyebilme kapasitesini yansıtmaktadır.

Deneysel sonuçların incelenmesi, YOLOv8 modelinin meyve tespiti konusundaki performansını değerlendirme açısından önemli bir aşamayı temsil eder. Şekil 4.22'de sunulan görüntüler, modelin portakalları akşam saatlerinde ağaçtayken başarıyla tespit etme ve sınıflandırma yeteneklerini göstermektedir. Bu bulgular, modelin değişen ışık koşullarında bile güvenilir bir şekilde çalışabildiğini ve yapraklarla kısmen kaplı olan portakalları doğru bir şekilde tanımlayabildiğini ortaya koymaktadır.

YOLOv8 modelinin sunduğu başarının temel faktörlerden biri, derin öğrenme tabanlı bir yaklaşımın benimsenmesi ve bu modelin özgün mimarisıyla meyve tespiti görevini gerçekleştirme yeteneğidir. Model, her bir nesne için ayrı ayrı sınırlayıcı kutular tahmin ederek ve her bir kutu için sınıf olasılıklarını hesaplayarak işlev görür. Bu sayede, farklı meyve türlerini ve farklı olgunluk seviyelerini hassas bir şekilde sınıflandırabilir. literatürdeki diğer nesne algılama yöntemleriyle karşılaştırıldığında, YOLOv8 modelinin sağladığı avantajlar belirgin hale gelmektedir. Özellikle, modelin eğitim sürecinde ve test aşamasında elde ettiği yüksek kesinlik ve duyarlılık değerleri, gerçek zamanlı uygulamalarda etkin bir şekilde kullanılabilirliğini sağlar. Ayrıca, modelin hızlı işleme kapasitesi, tarım alanlarında mobil cihazlar üzerinde çalışma yeteneğini artırır ve bu da saha koşullarında pratik kullanım için önemli bir avantaj sağlar.

Literatürdeki diğer nesne algılama yöntemleri genellikle farklı mimarilere, özellik çıkarım tekniklerine veya optimizasyon stratejilerine dayanır. Örneğin, Faster R-CNN, SSD gibi yöntemler, farklı ölçeklerde nesnelere tespit edebilir ancak YOLOv8'in sunduğu gerçek zamanlı performansı sağlayamayabilir. Bu nedenle, her bir yöntemin avantajları

ve sınırlamaları karşılaştırılarak, belirli bir uygulama senaryosunda en uygun seçimin yapılması gereklidir.

Bu çalışmada, YOLOv8 modelinin tarım alanındaki meyve tespiti örneğinde nasıl başarılı bir şekilde uygulandığı ve diğer yöntemlerle kıyaslandığında ne tür katkılar sunduğu detaylı bir şekilde incelenecektir. Bu analiz, nesne algılama teknolojilerinin evrimi ve tarımsal uygulamalardaki potansiyel etkileri hakkında kapsamlı bir anlayış sağlayacaktır.

4.2. YOLOv8 Modeli ve Literatürdeki Diğer Yaklaşımların Karşılaştırılması

Mo ve arkadaşlarının çalışmasında Faster R-CNN algoritması kullanılarak gerçekleştirilen obje algılaması, elma nesneleri üzerinde %94 algılama doğruluğu sağlamıştır. Bu çalışmada, YOLOv8 modeli kullanılarak geliştirilen sistem ise elmaların dal üzerindeki tespiti, farklı çevresel faktörlere karşı dayanıklılık ve genelleme yeteneği açısından değerlendirilmiştir. Elde edilen sonuçlara göre, YOLOv8 modeliyle gerçekleştirilen tez çalışmasında elma tespiti için %95,3 algılama doğruluğu elde edilmiştir.

Bu karşılaştırmadan çıkan önemli bir nokta, YOLOv8'in Faster R-CNN'e göre daha yüksek algılama doğruluğuna sahip olduğudur. Özellikle YOLOv8'in elma tespiti konusunda daha hassas ve genel bir başarı elde ettiği belirtilmektedir. Dayanıklılık, genelleme yeteneği ve özel uygulamalara yönelik daha iyi bir uyum, YOLOv8'in bu çalışmada başarılı sonuçlar elde etmesine katkıda bulunmuştur. Bu bulgular, tarımsal uygulamalarda YOLOv8 modelinin kullanımının daha etkili olabileceğini düşündürmektedir.

Kesler ve arkadaşlarının çalışmasında, muz meyvesinin yapay zekâ kullanılarak yedi farklı olgunlaşma evresinin tespitini hedefleyen bir yöntem benimsenmiştir. Sınıflandırma işlemi için AlexNet mimarisi gibi derin öğrenme yöntemleri kullanılarak elde edilen %96,63'lük doğruluk oranı, muz olgunlaşma evrelerini başarıyla sınıflandıran etkili bir modelin geliştirildiğini göstermektedir.

Tablo 4.2. Sunulan çalışmanın literatürdeki meyve tespiti ve sınıflandırma yaklaşımını karşılaştırılması

İsim,(Yıl)	Metot	Meyvenin adı ve kategori sayısı	Başarısı
Bargoti ve Underwood (2017)	Faster R-CNN	Elma (1)	%90
Mo ve ark. (2018)	Faster R-CNN	Elma – Portakal (1)	%94 ,%90
Wang ve ark (2019)	YOLO , Yolov2 , Yolov3,	Elma – portakal (2)	Elma için : %78,79 ,%90,67, %91,89. Portakal için ise %60,69 ,%87,67, %88,70 .
Li ve ark (2020)	CNN	Elma (1)	%92
Kantale ve Thakare (2020)	PSO	Nar (1)	%92,9
Saragih ve Emanuel (2021)	CNN	Muz (1)	%96,18
Kızılboğa (2021)	SVM ve K-NN	Elma ve ayva (2)	%88
Chu ve ark (2021)	R-CNN	Elma (2)	%90,5
Mirhaji ve ark (2021)	Yolov4	Portakal (2)	%90,8
Devanna ve ark (2022)	DeepLabv3+	Nar (2)	%97,94
Dulkadir ve Gültekin (2023)	YOLOv5s - YOLOv8	Muz (4)	%90 - %93
Jayanth ve ark (2023)	Yolo	Elma – Muz – Portakal (2)	%93,5 - %90,5 - %92,5
Kesler ve ark (2023)	AlexNet	Muz (1)	%96,63
Nergiz (2023)	Yolov7	Nar (1)	%94,3
Bu tez çalışması	YOLOv8	Elma – Muz – Portakal – Nar (2)	%95,3 - %98,9 - %93,8 - %98,8

Bu çalışmanın aksine, YOLOv8 modeli kullanılarak geliştirilen sistem, elmaların dal üzerindeki tespiti, farklı çevresel faktörlere karşı dayanıklılık ve genelleme yeteneği açısından değerlendirilmiştir. Elde edilen sonuçlara göre, YOLOv8 modeliyle gerçekleştirilen tez çalışmasında muz tespiti için %98,9'luk bir algılama doğruluğu elde edilmiştir. Bu durum, YOLOv8 modelinin muz tespiti görevinde daha üstün bir başarı elde ettiğini göstermektedir. %98,9'luk algılama doğruluğu, modelin muz olgunlaşma evrelerini tespit etme konusunda yüksek hassasiyet ve kesinlikle çalıştığını göstermektedir. Bu başarı, YOLOv8 modelinin muz meyvesinin algılanması konusundaki etkinliğini vurgular.

KJayanth ve ekibinin çalışması, bilgisayarlı görü ve derin öğrenme tekniklerini kullanarak meyve tespiti ve sınıflandırma üzerine bir analiz sunmaktadır. ResNet, VGG, GoogLeNet gibi çeşitli derin öğrenme yöntemleri kullanılarak oluşturulan bir model, dijital fotoğrafların görsel analizini gerçekleştirmektedir. İlgili konuda AlexNet temel alınan YOLO modeli ise portakal tespiti için %92,5 doğruluk oranına ulaşmıştır.

Ayrıca, tez çalışma kapsamında YOLOv8 modeli kullanılarak geliştirilen sistem, portakalların dal üzerindeki tespiti, çeşitli çevresel faktörlere karşı dayanıklılık ve genelleme yeteneği açısından detaylı bir değerlendirmeye tabi tutulmuştur. Yapılan testler sonucunda YOLOv8 modeli, portakal tespiti görevinde %93,8'lik bir algılama doğruluğu elde etmiştir. Bu çalışma, derin öğrenme yöntemlerinin meyve tespiti ve sınıflandırması üzerindeki etkinliğini vurgulamakta ve özellikle YOLOv8 modelinin portakal tespiti konusunda yüksek performans sergilediğini göstermektedir.

Devanna ve arkadaşlarının çalışması ile tez çalışması arasındaki karşılaştırmada, her iki çalışma da meyve tespiti konusunda önemli bilimsel katkılar sağlamıştır. İlk olarak, Devanna ve arkadaşlarının çalışması, görüşe dayalı algılama sistemlerinin kara araçları üzerine entegrasyonu ile meyve bahçelerinde hassas tarım uygulamalarını destekleyen bir çerçeve sunmaktadır. Kontrollü koşullardan başlayarak, karmaşık saha senaryolarında etkili bir şekilde meyve segmentasyonunu genişletilebilecek bir temel oluşturulmuştur. Deneysel testler, nar bahçesinde kullanılan DeepLabv3+ (Resnet18) mimarisi ile elde edilen %97,94'lük başarı oranını göstermektedir.

Diğer yandan, tez çalışması kapsamında kullanılan YOLOv8 modeli, narların dal üzerindeki tespiti üzerine odaklanmış ve çeşitli çevresel faktörlere karşı dayanıklılık ve

genelleme yeteneğini değerlendirmiştir. Yapılan testlerde YOLOv8 modelinin, nar tespiti görevinde %98,8'lik bir algılama doğruluğu elde ettiği belirtilmiştir.

Her iki çalışma da, farklı meyve türleri üzerinde yoğunlaşmış ve farklı derin öğrenme mimarilerini kullanarak benzer amaçlara hizmet etmiştir. Devanna ve arkadaşların çalışması, görüşe dayalı algılama sistemlerinin kontrollü ve karmaşık ortamlarda başarılı bir şekilde uygulanabilirliğini gösterirken, tez çalışması YOLOv8 modeli ile elde edilen yüksek algılama doğruluğu ile dikkat çekmektedir.

Dulkadir ve Gültekin (2023) tarafından gerçekleştirilen çalışmada, YOLOv5s ve YOLOv8 algoritmalarının muz tespiti üzerindeki başarı oranları sırasıyla %90 ve %93 olarak rapor edilmiştir. Ancak, bu sonuçlar çalışmamızla karşılaştırıldığında nispeten düşük kalmaktadır. Bu farkın temel nedeni, kategori sayısındaki farklılıktan kaynaklanmaktadır. Dulkadir ve Gültekin'in çalışmasında muz, dört farklı kategoriye ayrılmıştır. Buna karşılık, bizim çalışmamızda kategori sayısı iki ile sınırlıdır. Kategori sayısının artması, modelin her bir kategoriye odaklanmasını zorlaştırarak genel performansı düşürebilmektedir. Bu durum, Dulkadir ve Gültekin'in çalışmasındaki daha düşük başarı oranlarını açıklayabilir.

YOLOv8 modelinin meyve tespit görevindeki önemli başarısı, çeşitli faktörlerin entegrasyonu ile sağlanmıştır. Bu faktörler, modelin elma, muz, portakal ve nar tespit etme gibi özel görevlere adaptasyon yeteneğini artırabilir.

- **Görev Odaklı ve Özel Veri Seti:** YOLOv8, belirli meyve türlerini içeren geniş ve temsilci bir veri seti üzerinde eğitilmiştir. Bu model, spesifik meyve türlerinin daha kesin tanımlanması ve ayırt edilmesi için görev odaklı bir veri seti kullanımının etkilerini barındırmaktadır.

- **Özellik Çıkarımını İyileştirme:** Modelin CNN katmanları, elma, muz, portakal ve nar gibi meyve türlerinin belirli özelliklerini daha etkili bir şekilde çıkarmak üzere optimize edilmiştir. Bu, her bir meyve türü için daha hassas desen tespiti ve ayırt etme yeteneği sağlar.

- **Özel Eğitim Stratejileri:** YOLOv8 modeli, belirli görevler için özel eğitim stratejileri kullanmıştır. Örneğin, her meyve türü için özel ağırlıklandırma veya öğrenme

stratejileri, modelin her bir meyve türünü daha etkili bir şekilde tanımlamasına katkıda bulunabilir.

- **Çevresel Faktörlere Dayanıklılık:** Model, değişen çevresel koşullara karşı daha dirençli hale getirilmek üzere eğitilebilir. Işıktaki değişiklikler, günün farklı saatleri ve arka plan değişiklikleri gibi faktörlere karşı modelin dayanıklılığını artırarak pratik uygulamalarda güvenilir ve genelleştirilebilir sonuçlar elde etmesine olanak tanır.

- **Eğitim Süreci ve Parametre Ayarları:**

Eğitim sürecinde kullanılan optimizasyon stratejileri, öğrenme oranları ve diğer parametre ayarları, modelin elma, muz, portakal ve nar tespit görevindeki performansını belirleyebilir. Bu parametrelerin her meyve türü için özel olarak ayarlanması, modelin her bir meyve türünü daha etkili bir şekilde tanımlamasına yardımcı olabilir.

Bu faktörlerin bir araya gelmesiyle YOLOv8 modeli, elma, muz, portakal ve nar tespit görevinde önemli ve yüksek bir başarı elde etmiş olabilir.

5. SONUÇ VE ÖNERİLER

Bu tez çalışması, YOLOv8 derin öğrenme modelinin kullanılmasıyla elde edilen önemli başarılar sayesinde, elma, portakal, muz ve nar gibi dört farklı meyve türünün hasadının zaman alıcı işlemlerini kolaylaştırmaktadır. İnsansız Hava Aracı ile elde edilen görüntüler, çeşitli tarımsal uygulamalara yönelik olarak meyve türlerinin farklı konumlarındaki tespit, nitel analiz ve sayım konularında başarıyla kullanılmıştır.

YOLOv8 modelinin eğitimi sonucunda, meyvelerin dal üzerindeki tespiti ve modelin belirli aydınlatma koşullarına değil, aynı zamanda farklı çevresel faktörlere karşı da dayanıklılığını ve genelleme yeteneğini göstermesi önemli bir gözlem olarak ortaya çıkmıştır. Modelin performansının günün farklı saatlerinde ve çeşitli çekim koşullarında tutarlı bir şekilde etkili olduğu tespit edilmiştir.

Doğruluk değerleri açısından, eğitim sonucunda elde edilen oranlar şu şekildedir: Elma için %95,3, Portakal için %98,9, Muz için %93,8 ve Nar için %98,8. Ayrıca, eğitim sonucunda oluşturulan sınıfların ağaçlar üzerindeki tespit değerleri %97,1 olarak ölçülmüştür.

Bu bulgular, YOLOv8 modelinin elma, portakal, muz ve nar veri setlerinin eğitimi için başarılı bir şekilde kullanılabileceğini göstermektedir.

Çalışmanın pratik bağlamdaki önemi, tarım endüstrisinde çeşitli aşamalarda kullanılabilen bir meyve yönetim çözümü sunmasıdır. İHA ile toplanan veriler, tarım sahalarında meyve dağılımını ve olgunluk durumlarını belirleme konusunda değerli bilgiler sağlamaktadır. Bu, tarım işletmelerinin kaynaklarını daha etkin bir şekilde yönetmelerine ve hasat süreçlerini optimize etmelerine yardımcı olabilir.

- **Veri Seti Çeşitliliği ve Genişletilmesi:** Bu çalışmada kullanılan meyve türleri üzerindeki başarı, modelin genel geçerliliğini anlamamıza yardımcı olabilir. Ancak, gelecekteki çalışmalarda daha fazla meyve türü eklemek, modelin genel meyve tanıma yeteneklerini daha iyi değerlendirebilir.

- **Olgunlaşma ve Çürüme Durumlarının Daha Fazla Analizi:** Bu çalışmada modelin olgunlaşma ve çürüme durumlarını başarıyla tespit ettiğini göstermektedir. Ancak, gelecekteki çalışmalarda bu durumları daha ayrıntılı bir şekilde analiz etmek,

özellikle meyve kalitesini etkileyen faktörleri belirlemek ve meyve endüstrisine daha spesifik katkılarda bulunmak açısından önemli olabilir.

- **İHA ve Görüntü İşleme Tekniklerinin İyileştirilmesi:** İHA ile elde edilen görüntülerin kalitesini artırmak ve görüntü işleme tekniklerini daha etkili hale getirmek için gelecekteki çalışmalarda donanım ve yazılım iyileştirmeleri üzerine odaklanmak önemlidir.

- **Pratik Uygulama ve Endüstri Entegrasyonu:** Geliştirilen modelin ve analiz yöntemlerinin meyve endüstrisinde pratik uygulama için hazır hale getirilmesi ve endüstriyel süreçlere entegre edilmesi, tarım sektöründeki paydaşlarla iş birliğini güçlendirebilir.

- **Maliyet ve Verimlilik Analizi:** Yapılan çalışmaların maliyet etkinliği ve tarımsal verimlilik üzerindeki etkileri üzerine bir analiz yaparak, geliştirilen modelin ve uygulamaların tarım endüstrisine sağladığı ekonomik avantajları değerlendirmek önemlidir.

6. KAYNAKLAR

- Anonim., 2016. Meyve Hastalıkları [online], Tarım ve Orman Bakanlığı, <https://arastirma.tarimorman.gov.tr> [Ziyaret Tarihi:25 Ekim 2023].
- Akbudak, B., Özer, M.H., 2003. Farklı sıcaklıklarda muhafaza edilen turşuluk hıyarlarda meydana gelen fiziksel ve kimyasal değişimler, *Uludağ Üniversitesi Ziraat Fakültesi Dergisi*, 17 (1), 33-46.
- Asriny, D.M., Rani, S., Hidayatullah, A.F., 2020. Orange fruit images classification using convolutional neural networks, *Materials Science and Engineering*, 803, 12-20.
- Ayalew, A. and Pooja, D., 2019. A review on object detection from unmanned aerial vehicle using CNN, *International journal of advance research, ideas and innovations in technology*, 5, 241-243.
- Bargoti, S. and Underwood, J., 2017. Deep fruit detection in orchards, *international conference on robotics and automation*, 26-33.
- Chu, P., Li, Z., Lammers, K., Lu, R., Liu, X., 2021. Deep learning-based apple detection using a suppression mask R-CNN, *Pattern Recognition Letters*, 147, 206-211.
- Demir, Ü, Kula, N., Uğurlu, B., 2021. Tarımda yapay zekâ kullanımına yönelik karar destek modeli önerisi: domates zararlısı tespiti örneği, *Lâpseki Meslek Yüksekokulu Uygulamalı Araştırmalar Dergisi*, 2 (4), 91-108.
- Devanna, R.P., Milella, A., Marani, R., Garofalo, S. P., Vivaldi, G. A., Pascuzzi, S., Reina, G., 2022. In-field automatic identification of pomegranates using a farmer robot, *Sensors*, 22 (15), 58-21.
- Dewi, C., Arisoelaningsih, E., Mahmudy, W.F., 2022. Identifying of unripe Ambon and Hijau banana fruits using computer vision and extreme learning machine classifier, *Earth and Environmental Science*, 012-031.
- Dhakate, M. and Ingole, A. B., 2015. Diagnosis of pomegranate plant diseases using neural network. In *2015 fifth national conference on computer vision, pattern recognition, image processing and graphics*, Patna, India, 1-4.
- Dhall, R.K., Sharma, S.R., Mahajan, B.V.C., 2012. Effect of shrink wrap packaging for maintaining quality of cucumber during storage, *Journal of food science and technology*, 49, 495-499.
- Dulkadir, S. ve Gültekin, G. K., 2023. Tarımsal otomasyon sistemleri için muz olgunluk seviyelerinin derin öğrenme yöntemleri ile sınıflandırılması, *EMO Bilimsel Dergi*, 13(3), 27-34.
- Jayanth, J., Mahadevaswamy, M., Shivakumar, M., 2023. Fruit Quality Identification and Classification by Convolutional Neural Network, *SN Computer Science*, 4(3), 220.

- Kahveci, M. ve Can, N., 2017. İnsansız hava araçları: tarihçesi, tanımı, dünyada ve Türkiye'deki yasal durumu, *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 5(4), 511-535.
- Kantale, P. and Thakare, S., 2020. Pomegranate disease classification using Ada-Boost ensemble algorithm, *International Journal of Engineering Research & Technology*, 9, 612-620.
- Kesler, S., Karakan, A., Oğuz, Y., 2023. AlexNet mimarisi ile muz olgunlaşma evrelerinin sınıflandırılması, *Avrupa Bilim ve Teknoloji Dergisi*, 51, 135-141.
- Kestur, R., Meduri, A., Narasipura, O., 2019. MangoNet: A deep semantic segmentation architecture for a method to detect and count mangoes in an open orchard, *Engineering Applications of Artificial Intelligence*, 77, 59-69.
- Kızılböğü, A.Y., 2021. Yapay sinir ağları ve derin öğrenme teknikleri kullanılarak elma ve ayvada çeşitli hastalıkların tespit edilmesi, Yüksek Lisans Tezi, *Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü*, Kırıkkale, 18-19.
- Koç, İ., Mermer, Ö., Kırımca, N., Karaköse, M., 2023. Raylı sistemlerde peron ayırıcı kapı sistemi için yapay sinir ağı tabanlı hata teşhis yaklaşımı, *EMO Bilimsel Dergi*, 13(1), 13-22.
- Kumar R.A., Rajpurohit, V.S., Bidari, K.Y., 2019. Multi class grading and quality assessment of pomegranate fruits based on physical and visual parameters, *International Journal of Fruit Science*, 19 (4), 372-396.
- LeCun, Y., Bengio, Y., Hinton, G., 2015., Deep learning. *nature*, 521 (7553), 436-444.
- Lee, S.H., 2021. A Study on Fruit Quality Identification Using YOLO V2 Algorithm. *International Journal of Advanced Culture Technology*, 9 (1), 190-195.
- Li, J., Xie, S., Chen, Z., Liu, H., Kang, J., Fan, Z., Li, W., 2020. A shallow convolutional neural network for apple classification, *IEEE Access*, 8, 83-92.
- Li, X., Wang, W., Wu, L., Chen, S., Hu, X., Li, J., Yang, J., 2020. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection, *Advances in Neural Information Processing Systems*, 33, 21002-21012.
- Linker, R., Cohen, O., Naor, A., 2012. Determination of the number of green apples in RGB images recorded in orchards, *Computers and Electronics in Agriculture*, 81, 45-57.
- Mazen, F.M., Nashat, A.A., 2019. Ripeness classification of bananas using an artificial neural network, *Arabian Journal for Science and Engineering*, 44, 01-10.
- Mirhaji, H., Soleymani, M., Asakereh, A., Mehdizadeh, S. A., 2021. Fruit detection and load estimation of an orange orchard using the YOLO models through simple approaches in different imaging and illumination conditions, *Computers and Electronics in Agriculture*, 191, 06-33.

- Mo, X., Tao, K., Wang, Q., Wang, G., 2018. An efficient approach for polyps detection in endoscopic videos based on faster R-CNN, *24th international conference on pattern recognition*, Beijing, China, 29-34.
- Neamah, S.B. and Karim, A.A., 2023. Real-time traffic monitoring system based on deep learning and YOLOv8, *Aro-The Scientific Journal Of Koya University*, 11 (2), 137-150.
- Nergiz, M., 2023. YOLO-V7 Based detection and classification of pomegranate fruits in different growing stages, *Researchgate*, 5.
- Rajkumar, P., Wang, N., Raghavan, G.S.V., 2015. Classification of banana fruit maturity using zNose, *Agricultural Engineering International: CIGR Journal*, 17 (4), 389-396.
- Ranjan Sapkota, D.A., Karkee, M., 2023. Comparing YOLOv8 and Mask RCNN for object segmentation in complex orchard environments, *arXiv preprint*,10.
- Redmon, J., Farhadi, A., 2016. YOLO: Better, Faster, Stronger [Online], arxiv, Cornell University, <https://arxiv.org/abs/1612.08242> [Ziyart Tarihi: 15 Ekim 2022].
- Redmon, J., Divvala, S., Girshick, R., Farhadi, A., 2016. You only look once: Unified, real-time object detection, *IEEE*, 79-88.
- Reis, D., Kupec, J., Hong, J., Daoudi, A., 2023. Real-Time Flying Object Detection with YOLOv8, *arXiv preprint arXiv*, 60-72.
- Ren, S., He, K., Girshick, R., Sun, J., 2015. Faster r-cnn: Towards real-time object detection with region proposal networks, *Advances in Neural Information Processing Systems*, 28.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., McCool, C., 2016. Deepfruits: A fruit detection system using deep neural networks, *Sensors*, 16 (8), 1222.
- Saragih, R.E. and Emanuel, A.W., 2021. Banana ripeness classification based on deep learning using convolutional neural network, *3rd East Indonesia Conference on Computer and Information Technology*, Surabaya, Indonesia, 85-89.
- Soyhan, İ., Gurel, S., Tekin, S.A., 2021. Yapay Zeka Tabanlı Görüntü İşleme Tekniklerinin İnsansız Hava Araçları Üzerinde Uygulamaları, *Avrupa Bilim ve Teknoloji Dergisi*, (24), 469-473.
- Tan, F. G., Yüksel, A.S., Aydemir, E., Ersoy, M., 2021. Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme, *Avrupa Bilim ve Teknoloji Dergisi*, (25), 159-171.
- Türkseven, S., Kızmaz, M.Z., Tekin, A.B., Urkan, E., Serim, A.T., 2016. Tarımda dijital dönüşüm; insansız hava araçları kullanımı, *Tarım Makinaları Bilimi Dergisi*, 12 (4), 267-271.

- Viola, P. and Jones, M., 2001. Rapid object detection using a boosted cascade of simple features, *IEEE computer society conference on computer vision and pattern recognition*, Kauai, HI, USA, 1.
- Wang, Z., Walsh, K., Koirala, A., 2019. Mango fruit load estimation using a video based MangoYOLO Kalman filter hungarian algorithm method, *Sensors*, 19 (12), 27-42.
- Yang, C. and Lee, W. S., 2012. Blueberry fruit detection by Bayesian classifier and support vector machine based on visible to near-infrared multispectral imaging, *American Society of Agricultural and Biological Engineers*, 1.
- Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R., Ren, D., 2020. Distance-IoU loss: Faster and better learning for bounding box regression, In *Proceedings of the AAAI conference on Artificial Intelligence*, Tianjin, China, 34, 07, 12-13.
- Zhou, R., Damerow, L., Sun, Y., Blanke, M.M., 2012. Using colour features of cv. 'Gala' apple fruits in an orchard in image processing to predict yield, *Precision Agriculture*, 13 (5), 68-80.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı Abdurrahman YILDIRIM

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lisans Eğitimi	: Siirt Üniversitesi - Mühendislik Fakültesi Elektrik Elektronik Mühendisliği	2021

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2021 - 2024	Özel Siirt TeknoGenç Koleji	Öğretmen

YABANCI DİLLER

İngilizce , Arapça

YAYINLAR