



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME TEKNİKLERİ İLE BAZI BAĞ ZARARLILARININ
OLUŞTURDUĞU HASARIN BELİRLENMESİ**

DOKTORA TEZİ

Tahsin UYGUN

Birinci Danışman: Doç. Dr. Mehmet Metin ÖZGÜVEN

İkinci Danışman: Prof. Dr. Dürdane YANAR

TOKAT-2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Mehmet Metin ÖZGÜVEN danışmanlığında hazırlamış olduğum “Derin Öğrenme Teknikleri ile Bazı Bağ Zararlılarının Oluşturduğu Hasarın Belirlenmesi” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

29/01/2024

Tahsin UYGUN

JÜRİ KABUL VE ONAY



ÖNSÖZ

Lisans eğitimimden itibaren beni yönlendiren, bu tez konusunda ve çeşitli çalışmalarda iş birliği imkanı sağlayan, birlikte çalışmaktan büyük keyif aldığım, insani ve ahlaki değerleriyle örnek olan danışman hocam Sayın Doç. Dr. Mehmet Metin ÖZGÜVEN'e, entomoloji ve bitki koruma konusunda hem yüksek lisans çalışmamda hem de bu çalışmada rehberlik eden ikinci danışmanım Sayın Prof. Dr. Dürdane YANAR hocama,

Tez sürecinde değerli görüşleri ve düzeltmeleriyle katkı sağlayan Sayın Prof. Dr. Engin ÖZGÖZ ve Sayın Doç. Dr. Kemal ADEM hocalarıma,

Tez Değerlendirme Jüri üyeleri olarak destek veren Sayın Prof. Dr. Yusuf YANAR ve Sayın Dr. Öğr. Üyesi Serhat KILIÇARSLAN hocalarıma,

Manisa bağ arazi çalışmalarında uzmanlık ve deneyimleriyle yardımlarını esirgemeyen Sayın Dr. Nurdan GÜNGÖR SAVAŞ, Dr. Esra ALBAZ ve Ziraat Yük. Mühendisi Mustafa Sacit İNAN hocalarıma,

Çalışmalarım sırasında güler yüzleri ve yardımlarıyla destek olan meslektaşlarım Dr. Ziya ALTAŞ, Biyosistem Müh. Derya GÜVEN ve Biyosistem Müh. Arif ÇAM'a

Her zaman yanımda olan, hayatıma neşe katan, maddi ve manevi her konuda destekleyen, beni değerli hissettiren canım aileme en içten sevgi, saygı ve şükranlarımı sunarım.

Tahsin UYGUN

29 Ocak 2024

ÖZET

DOKTORA TEZİ

DERİN ÖĞRENME TEKNİKLERİ İLE BAZI BAĞ ZARARLILARININ OLUŞTURDUĞU HASARIN BELİRLENMESİ

Tahsin UYGUN

Biyosistem Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Mehmet Metin ÖZGÜVEN

İkinci Danışman: Prof. Dr. Dürdane YANAR

Ocak 2024, xii + 85 sayfa

İklim değişikliği kaynaklı küresel ısınma, tarımsal üretimde çeşitli zorluklara neden olmaktadır. Tarımsal üretimdeki zorluklardan biri, çeşitli zararlı popülasyonlarında artıştır. Popülasyondaki artış, tarım ürünlerini ciddi şekilde tehdit etmekte ve verimlilik ile kaliteyi önemli ölçüde olumsuz etkilemektedir. Çoğu zaman çiftçilerin zararlıları ve etkilerini tanımlamada güçlük çekmeleri, yanlış ve aşırı insektisit uygulamalarına neden olabilmektedir. Aşırı insektisit kullanımı hem insan sağlığını tehdit etmekte hem de çevresel kirliliğe yol açarken, üretim maliyetlerini artırarak çiftçiler üzerinde ekonomik baskı oluşturmaktadır. Bu nedenle, zararlıların ve bitkilere verdikleri hasarın erken tespiti, tarımsal sistemlerin sürdürülebilirliği açısından kritik bir öneme sahiptir. Bu çalışmada, derin öğrenme yöntemleri kullanılarak bağlarda salkım güvesi, trips, iki noktalı kırmızıörümcek ve bağ yaprak uyuzu gibi bazı önemli bağ zararlılarının hasarlarını tespit etmek için YOLOv8n tabanlı bir model geliştirilmiştir. Geliştirilen model AgDet-YOLO olarak adlandırılmıştır. Bu modelde, SPPF bloğu GSPPF bloğu ile, evrişim katmanındaki SiLU aktivasyon fonksiyonu ReLU ile ve modelin boyun ağındaki evrişim katmanları hayalet evrişim katmanı ile değiştirilmiştir. Ayrıca omurga ağına GSPPF bloğu öncesi Küresel Dikkat Mekanizması (GAM) modülü eklenmiştir. Kafa ağındaki katman bağlantıları değiştirilerek modelin toplam parametre sayısı 3.2M'den 2.9M'a indirilmiştir. Eğitim sürecinde, geliştirilen modelin genel sınıf başarısı standart modelde mAP@0.5 metriğinde 0.955 iken, geliştirilen modelde bu değer 0.963'e yükselmiştir. Ayrıca, geliştirilen model, YOLOv5n, YOLOv8n modelleri ve farklı tek aşamalı model olan MobileNetv2-SSD ile performans karşılaştırmaları yapılmıştır.

Anahtar Kelimeler: Yapay Zeka, Derin Öğrenme, Nesne Algılama, AgDet-YOLO, Bağ Zararlıları

ABSTRACT

DOCTORATE THESIS

DETERMINATION OF THE DAMAGE CAUSED BY SOME VINEYARD PESTS WITH DEEP LEARNING TECHNIQUES

Tahsin UYGUN

Department of Biosystems Engineering

Advisor: Assoc. Prof. Dr. Mehmet Metin ÖZGÜVEN

Second Advisor: Prof. Dr. Dürdane YANAR

January 2024, xii + 85 pages

Global warming caused by climate change causes various difficulties in agricultural production. One of the challenges in agricultural production is the increase in various pest populations. The increase in population seriously threatens agricultural products and significantly negatively affects productivity and quality. Most of the time, farmers have difficulty in identifying pests and their effects, which can lead to incorrect and excessive insecticide applications. Excessive use of insecticides threatens human health and causes environmental pollution, while increasing production costs and creating economic pressure on farmers. Therefore, early detection of pests and the damage they cause to plants is of critical importance for the sustainability of agricultural systems. In this study, a YOLOv8n-based model was improved to detect the damage of some important vineyard pests such as grapevine moth, thrips, two-spotted spider mite and vineyard leaf scab in vineyards using deep learning methods. The improved model is named AgDet-YOLO. In this model, the SPPF block is replaced by the GSPPF block, the SiLU activation function in the convolution layer is replaced by ReLU, and the convolution layers in the neck network of the model are replaced by the ghost convolution layer. Additionally, the Global Attention Mechanism (GAM) module was added to the backbone network before the GSPPF block. By changing the layer connections in the head network, the total number of parameters of the model was reduced from 3.2M to 2.9M. During the training process, while the overall class success of the improved model was 0.955 in the mAP@0.5 metric in the standard model, this value increased to 0.963 in the improved model. Additionally, performance comparisons were made with the improved model, YOLOv5n, YOLOv8n models and a different single-stage model, MobileNetv2-SSD.

Keywords: Artificial Intelligence, Deep Learning, Object Detection, AgDet-YOLO, Vineyard Pests

İÇİNDEKİLER

Sayfa

ETİK SÖZLEŞME.....	i
JÜRİ KABUL VE ONAY	ii
ÖNSÖZ	iii
ÖZET	iv
ABSTRACT.....	v
İÇİNDEKİLER	vi
ÇİZELGELER LİSTESİ.....	vii
ŞEKİLLER LİSTESİ	viii
KISALTMALAR VE SİMGELER LİSTESİ	xi
1. GİRİŞ	1
2. LİTERATÜR ÖZETLERİ	24
3. MATERYAL ve YÖNTEM	34
3.1. Materyal	34
3.1.1. Çalışmada değerlendirilen bağ zararlıları	34
3.1.2. Araştırma alanları.....	35
3.1.3. Çalışmada kullanılan cihazlar	37
3.1.4. YOLO (You Only Look Once)	39
3.1.5. Google Colab (Colaboratory).....	41
3.2. Yöntem.....	42
3.2.1. Görüntülerin edinimi.....	43
3.2.2. Veri setinin oluşturulması	43
3.2.3. Veri ön işleme ve etiketleme.....	44
3.2.4. AgDet-YOLO modelinin geliştirilmesi	49
3.2.5. Model değerlendirme göstergeleri	56
4. BULGULAR ve TARTIŞMA.....	60
4.1. Geliştirilen AgDet-YOLO Modelin Sonuçları.....	60
4.2. Standart YOLOv8n Modeli ile Karşılaştırılması	68
4.3. Farklı Tek Aşamalı Nesne Algılama Modeller ile Performans Karşılaştırılması	72
5. SONUÇ ve ÖNERİLER	75
6. KAYNAKLAR	77
7. ÖZGEÇMİŞ	83

ÇİZELGELER LİSTESİ

Sayfa

Çizelge 1. 2017-2022 yılları arası Türkiye bağ alanı ve üzüm üretimi	5
Çizelge 2. Veri setinin elde edilmesi ile ilgili bilgiler	37
Çizelge 3. Görüntü edinimi için kullanılan akıllı telefonun teknik özellikleri	37
Çizelge 4. Çalışmada kullanılan bilgisayarın teknik özellikleri	38
Çizelge 5. Çalışmada kullanılan sanal grafik işleme biriminin (GPU) teknik özellikleri	39
Çizelge 6. YOLOv8 modelleri için ölçekleme parametreleri	41
Çizelge 7. Çalışmada oluşturulan veri seti yapısı ve dağılımı	43
Çizelge 8. Modellerin standart eğitim hiper parametreleri	61
Çizelge 9. AgDet-YOLO modelinin farklı giriş görüntüsü boyutlarında oluşturduğu eğitim süresi ve GPU kullanım grafiği	64
Çizelge 10. Benzer modellerin kullanıldığı literatür çalışmaları ve karşılaştırmalar ..	74

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1. 2017-2021 yılları arası kıtalar bazında üzüm üretim miktarı dağılımı	3
Şekil 2. 2017-2021 yılları arası ülkeler bazında üzüm üretim miktarları	4
Şekil 3. 2017-2021 yılları arası Türkiye, hasat edilen üzüm üretim alanları-üzüm üretim miktarları	4
Şekil 4. Salkım güvesi; a) yaşam döngüsü, b) 1.döl zararı, c) 2. döl zararı ve d) 3.döl zararı.....	7
Şekil 5. Trips; a) yaşam döngüsü, b) asmadaki hasarı ve c) yapraktaki hasarı.....	8
Şekil 6. İki noktalı kırmızıörümcek, a) yaşam döngüsü ve b) yapraktaki hasarı.....	9
Şekil 7. a) Bağ yaprak uyuzu akarı ve b) yaprağın ön ve arka kısmında oluşturduğu hasar	10
Şekil 8. Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki ilişki.....	11
Şekil 9. Genel CNN mimarisi	13
Şekil 10. Ortalama, maksimum ve küresel ortalama havuzlama	15
Şekil 11. Düzleştirme katmanı.....	15
Şekil 12. Tam bağlantılı katman yapısı.....	16
Şekil 13. En yaygın kullanılan aktivasyon fonksiyonları	18
Şekil 14. Örnek bir doğruluk-eğitim devir sayısı grafiği.....	19
Şekil 15. Sınıflandırma ve nesne algılama karşılaştırması	21
Şekil 16. IoU hesaplama yöntemi	21
Şekil 17. Tek ve iki aşamalı nesne algılama yöntemlerinin karşılaştırması	22
Şekil 18. Çalışmada incelenen (a) Salkım Güvesi, (b) Trips yaprak, (c) Trips meyve, (d) Bağ yaprak uyuzu ve (e) İki noktalı kırmızıörümcek zararlılarının oluşturduğu hasar örnekleri.....	34
Şekil 19. İlçeleri ile araştırma alanları, a) Manisa ve b) Tokat.....	35
Şekil 20. Manisa Bağcılık Araştırma Enstitüsü Müdürlüğü Merkez bağ alanları	36
Şekil 21. Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi Çeltik bağ alanı 3 boyutlu ortomozaik haritası.....	36
Şekil 22. Çalışmada kullanılan sanal Nvidia A100 (40G) ekran kartı.....	38
Şekil 23. YOLO evrim süreci.	39
Şekil 24. YOLO nesne algılama yöntemi	40
Şekil 25. Google Colab (Colaboratory) Notebook örnek arayüz görseli.....	42

Şekil 26. Salkım güvesi hasar etiketi örneği.....	44
Şekil 27. Yaprakta trips hasar etiketi örneği.....	45
Şekil 28. Meyvede trips hasar etiketi örneği.....	45
Şekil 29. Bağ yaprak uyuzu hasar etiketi örneği.....	46
Şekil 30. İki noktalı kırmızıörümcek hasar etiketi örneği.....	46
Şekil 31. Oluşturulan veri seti etiketlerinin istatistiksel sonuçları; a) etiket sayıları, b) etiket boyutları, c) normalleştirilmiş hedef konum haritası ve d) normalleştirilmiş hedef boyut haritası	47
Şekil 32. Oluşturulan veri setindeki etiketlerin korelogram dağılım grafikleri	48
Şekil 33. a) Standart Conv ve b) ReLU + Conv katmanı	49
Şekil 34. a) Standart evrişim ve b) hayalet evrişim katmanı	50
Şekil 35. a) Standart SPPF ve b) GSPPF bloğu	51
Şekil 36. a) Uzamsal dikkat alt modülü (SAM), b) kanal dikkat alt modülü (CAM) ve c) küresel dikkat mekanizması (GAM) modülü	52
Şekil 37. a) AgDet-YOLO ve b) YOLOv8n modelin yamll dosya yapıları	53
Şekil 38. Geliştirilen AgDet-YOLO modelinin özeti	54
Şekil 39. Standart YOLOv8n model mimarisi; a) omurga, b) boyun ve c) kafa	55
Şekil 40. Geliştirilen AgDet-YOLO model mimarisi; a) omurga, b) boyun ve c) kafa	56
Şekil 41. F1 güven skoru eşiği eğrisi	58
Şekil 42. Karışıklık matrisi yapısı.....	59
Şekil 43. Çalışmanın genel akış şeması	59
Şekil 44. AgDet-YOLO modelinin farklı veri seti ile eğitim sonuçları.....	60
Şekil 45. AgDet-YOLO modelinin sınıf bazlı performans sonuçları	61
Şekil 46. AgDet-YOLO modelinin performans grafikleri	62
Şekil 47. Eğitim sonucunda oluşan F1 güven skoru eşiği eğrisi.....	63
Şekil 48. AgDet-YOLO modelinin karışıklık matrisi.....	64
Şekil 49. AgDet-YOLO modelinin farklı giriş boyutlarında gösterdiği genel sınıf performans sonuçları	65
Şekil 50. AgDet-YOLO modelinin farklı optimizasyon algoritmalarıyla gösterdiği genel sınıf performans sonuçları.....	66
Şekil 51. AgDet-YOLO modelinin farklı optimizasyon algoritmaları ile P-R grafikleri açısından karşılaştırılması.....	67

Şekil 52. Geliştirilen AgDet-YOLO modelinin farklı boyutlarda olan standart YOLOv8 modelleriyle parametre sayısı (M) karşılaştırması	68
Şekil 53. YOLOv8n ve AgDet-YOLO model performans karşılaştırması.....	69
Şekil 54. YOLOv8n ve AgDet-YOLO modellerinin sağlıklı sınıflara ait tespit örnek görüntüleri	70
Şekil 55. YOLOv8n ve AgDet-YOLO modellerinin zararlı hasarı sınıflarına ait tespit örnek görüntüleri.....	71
Şekil 56. AgDet-YOLO modelinin önceki YOLO modelleri ve farklı algoritmaya sahip model ile performans karşılaştırılması	72
Şekil 57. AgDet-YOLO modelinin farklı modeller ile P-R grafikleri açısından performans karşılaştırması.....	73



KISALTMALAR VE SİMGELER LİSTESİ

Adam: Uyarlanabilir Moment Tahmini

AgDet: Tarımsal Dedektör

CAM: Kanal Dikkat Alt Modülü

CNN: Evrişimli Sinir Ağı

ELAN: Verimli Katman Toplama Ağı

ELU: Üstel Lineer Birim

FAO: Gıda ve Tarım Örgütü

FC: Tam Bağlantı

FN: Yanlış Negatif

FP: Yanlış Pozitif

FPN: Özellik Piramit Ağı

GAM: Küresel Dikkat Mekanizması

GPU: Grafik İşlem Birimi

GSPPF: Hayalet Hızlı Uzamsal Piramit Havuzlama

IoU: Birleşme Üzerinde Kesişim

KNN: En Yakın Komşu

MLP: Çok Katmanlı Algılayıcı

PAN: Yol Toplama Ağı

ReLU: Düzleştirilmiş Doğrusal Birim

RGB: Kırmızı-Yeşil-Mavi

RoI: İlgi Bölgesi

RPN: Bölge Teklif Ağı

SAM: Uzamsal Dikkat Alt Modülü

SiLU: Sigmoid Doğrusal Birim

SPPF: Hızlı Uzamsal Piramit Havuzlama

SVM: Destek Vektör Makineleri

SSD: Tek Atış Çoklu Kutu Dedektörü

SGD: Stokastik Gradyan İnişi

TP: Doğru Pozitif

TN: Doğru Negatif

TÜİK: Türkiye İstatistik Kurumu

YOLO: Sadece Bir Kez Bak

1. GİRİŞ

Tarım, önemli ekonomik getirisi olmasının yanında hayatın devamlılığı için zorunlu ve stratejik bir faaliyettir. Tarımsal üretimde hedef; verimliliğin ve ürün kalitesinin artırılması, minimum girdi kullanımı, gıda güvenirliliği, doğal kaynakların ve çevrenin korunması ile ekonomik, sürdürülebilir ve üretken işletmeciliğin sağlanmasıdır (Özgüven, 2020). Aynı zamanda tarım, fiziksel, kimyasal ve biyolojik süreçlerin bir araya geldiği karmaşık bir faaliyet olarak önemli bir konumda bulunmaktadır. Son yıllarda, dünya genelinde iklim değişikliği, hastalık ve zararlılar ile çevresel kirlilik gibi olumsuz faktörler tarımsal üretimi önemli ölçüde etkilemiştir. Bu durum, dünya nüfusunun yeterli ve kaliteli gıda ile beslenmesi hedefini zorlaştırmaktadır (Ozguven, 2023; Blekos ve ark., 2023). Tarımsal üretime yönelik optimum koşulların sağlanması zor ve maliyetli olabilmektedir. Bu nedenle verimli bir tarım işletmesi için her bir bileşendeki değişimlerin doğru ve zamanında belirlenmesi ve olası etkileşimlerin dikkate alınarak uygulamalara karar verilmesi gerekmektedir (Ozguven, 2023).

Dünya genelinde hastalık ve zararlılar, tarımsal üretimde önemli ekonomik ve verim kayıplarına neden olmaktadır (Savary ve Willocquet, 2014; Avelino ve ark., 2015). İklim değişikliğinin bir sonucu olarak çeşitli bitki hastalıkları ve zararlı türlerinin sayısı artmakta ve kayıplar giderek ciddi seviyelere ulaşmaktadır. Kayıpların en aza indirilmesi için bitki hastalıkları ve zararlılarla etkin bir mücadele edilmesi gerekmektedir (Kang ve ark., 2023). Tarımsal zararlılar, Gıda ve Tarım Örgütü (FAO) tarafından bildirildiği üzere, her yıl küresel ürün üretiminde %20 ila %40 arasında kayba neden olmaktadır (Karar ve ark., 2021). Hastalık ve zararlıların hızlı ve doğru bir şekilde tanınması ve hastalık şiddetinin ve zararlı hasarının değerlendirilmesi, zamanında önleme ve yönetim stratejilerinin uygulanması için esastır. Bu nedenle hastalık ve zararlıların güvenilir ve zamanında tespiti tarımsal ürün kayıplarını önemli ölçüde azaltabilmektedir (Bock ve ark., 2010; Wang ve Qi, 2019). Tarımsal üretimde hastalık ve zararlı hasarlarını doğru ve hızlı bir şekilde tespit etmek, etkilenen alanları belirlemek hala zorlu bir süreçtir. Bu süreç genellikle zaman almakta ve tarım alanında uzmanlaşmış kişilerin deneyimi ve bilgisini gerektirmektedir (Gutiérrez ve ark., 2021; Wu ve ark., 2022).


Hastalık ve zararlılardan dolayı bitkide meydana gelen hasar şiddetinin ve gelişiminin hızlı bir şekilde tespit edilmesini sağlayan görüntü işleme ve derin öğrenme gibi teknolojik yöntemlerin geliştirilmesi, uzmanlar tarafından çıplak gözle yapılan değerlendirmelerde oluşabilecek iş gücü ve zaman kayıplarının önüne geçilebilmesi gibi avantajlar sunmaktadır (Uygun ve ark., 2020; Ozguven ve Altas, 2022; Ozguven ve Yanar, 2022; Dönmez ve ark., 2023, Yılmaz ve

ark., 2023). Bu nedenle bitki hastalıklarının insan hatalarından bağımsız ve otomatik olarak teşhis edilmesini sağlayan görüntü işleme ve derin öğrenme gibi teknikler yoğun bir şekilde araştırılmaktadır (Ozguven ve Altas, 2022). Bitkilerde hastalıkların teşhis edilmesi, bitkinin gövdelerinde, yapraklarında veya farklı organlarında ortaya çıkan farklı renkli lekeler, çizgiler veya noktalar gibi görsel belirtilerden yola çıkarak yapılabilmektedir. Bu belirtiler, görüntü işleme teknikleri kullanılarak analiz edilebilmekte ve bitki hastalıklarının türlerine göre ayırt edilebilmektedir. Derin öğrenme yöntemleri, bu görsel belirtileri tanımak ve bitki hastalıklarını teşhis etmek için kullanılan güçlü bir araçtır (Ozguven, 2020). Derin öğrenme yönteminin önemli bir avantajı, özellikleri kendi başına çıkarabilmesidir. Derin öğrenmede algoritmaya açık bir talimat verilmez. Bunun yerine verilerde otomatik olarak birbiriyle ilişkili özellikler aranmakta ve daha sonra bu ilişkili özellikleri birleştirerek daha hızlı öğrenmeyi kolaylaştırmaktadır (Adem ve Közkurt, 2019; Kiliçarslan ve ark., 2023; Közkurt ve ark., 2023). Büyük verileri işleme yeteneği nedeniyle derin öğrenme daha fazla veri ile daha iyi sonuçlar üretebilmekte ve daha karmaşık problemleri çözebilmektedir (Ahmed ve ark., 2023). Yapay zeka ve derin öğrenme tarımsal araştırmalarda önemli bir rol oynayarak bitkisel üretim planlamaları, bitki sınıflandırması, verim tahmini, hastalık ve zararlı tespiti, tarım robotlarının rotalarının belirlenmesi, sera koşullarının yönetimi, işletme kararları, sulama yönetimi, ürün rotasyonu, gübre ve ekipman seçimi, hayvan hastalıklarının teşhisi, yem rasyonlarının hazırlanması ve hayvan davranışlarının analizi gibi birçok alanda araştırmacıların ilgisini çekmekte ve bu konularda birçok çalışma bulunmaktadır (Terzi ve ark., 2019). Derin öğrenme yöntemleriyle bitki hastalık ve zararlılarının belirlenmesi için çeşitli teknikler ve algoritmalar geliştirilmiş olmasına rağmen, bitki hastalık ve zararlıların belirlenmesi konularında hala geliştirme fırsatları mevcuttur (Ozguven ve Adem, 2019).

Bağcılık


Bağcılık için dünyanın en uygun ve elverişli yetiştirme olanaklarına sahip olan ülkemiz, kültür asması (*Vitis vinifera* L.) ve bağcılık kültürünün anavatanı olması nedeniyle zengin bir gen potansiyeline ve asmanın heterozigotik yapısından dolayı çok geniş çeşit ve tip zenginliğine sahiptir. Türkiye’de bağcılık eski ve köklü bir kültüre sahip olmasından dolayı asma olarak isimlendirilen (*Vitis* sp.) bitki yetiştiriciliği yapılmaktadır. İklim ve toprak yönünden fazla seçici olmaması ve alternatif değerlendirme olanaklarına sahip olan asma, dünyada ve Türkiye’de yetişme şartlarının kolaylığı ve hemen hemen her bölgede üretiminin yapılabilmesi nedeniyle birçok üreticinin geçim kaynağını oluşturmaktadır (Karabat, 2014; Semerci ve ark., 2015).

2017-2021 FAO dünya üzüm üretimi verileri kıta bazında incelendiğinde (Şekil 1) Asya ve Avrupa, toplam üretimin üçte birinden fazlasını katkıda bulunan üzüm üretiminde önde gelen kıtalardır. Afrika, Amerika ve Okyanusya ise daha az paya sahiptir.




Şekil 1. 2017-2021 yılları arası kıtalar bazında üzüm üretim miktarı dağılımı (FAO, 2023)

FAO verilerine göre 2017 ile 2021 yılları arasında dünya genelindeki üzüm üretimi miktarları ülkeler bazında incelendiğinde (Şekil 2), öne çıkan en büyük beş üretici ülke Çin, İtalya, İspanya, ABD ve Fransa olduğu görülmektedir. Bu ülkeler yıllık üzüm üretimi açısından dünya genelinde en büyük paya sahiptir. Türkiye, dünya genelinde üzüm üretiminde ilk 10 ülke arasında 6. sırada yer almaktadır. Bu beş büyük üretici ülkenin hemen ardından gelen Türkiye, bu alanda dünya çapında önemli bir konumdadır. Türkiye'nin üzüm üretimindeki bu önemli konumu, ülkenin tarım potansiyeli, çeşitliliği, iklim koşulları ve tarım uygulamalarındaki gelişmelerle yakından ilişkilidir. Üzüm üretimi, Türkiye için hem iç tüketim hem de ihracat açısından büyük bir öneme sahiptir. Sofralık, kuru ve şaraplık üzüm üretimi yapan Türkiye, bu ürünleri iç ve dış pazarlara sunarak tarımsal ihracatta önemli bir rol üstlenmektedir. Bu durum, Türkiye'nin tarım sektöründe ve ekonomisinde üzümün kritik bir rol oynadığını ve üzüm üretiminin ülke ekonomisine ciddi bir katkı sağladığını göstermektedir.



Şekil 2. 2017-2021 yılları arası ülkeler bazında üzüm üretim miktarları (FAO, 2023)

FAO verilerine göre, 2017-2021 yılları arasında Türkiye’de üzüm hasat alanları ve üretim miktarları incelendiğinde, çeşitli yıllarda dalgalanmalar yaşandığı görülmektedir (Şekil 3). 2017 yılında hasat edilen alan 416 bin hektar olarak gerçekleşmiş ve üretim 4.2 milyon ton olmuştur. 2018 yılında hasat edilen alan neredeyse aynı kalmış ancak üretim 3.9 milyon tona düşmüştür. 2019 yılında hasat edilen alan biraz azalarak 405 bin hektara gerilemiş, fakat üretim miktarı 4.1 milyon tona yükselmiştir. 2020 yılında hasat edilen alan biraz daha azalmış, ancak üretim 4.2 milyon tona yükselmiştir. 2021 yılında ise hasat edilen alan daha da azalmış ve üretim miktarı 3.6 milyon tona gerilemiştir. Burada üzüm üretimi alanı ve verim arasında oluşan ters ilişkinin nedenleri; iklim koşulları, hastalık ve zararlı baskısı, pazar talebi, fiyat değişimleri, destekleme politikaları, arazi mülkiyeti, işgücü maliyeti, rekabet gücü gibi çevresel, ekonomik ve sosyal faktörlerden sayılabilmektedir.



Şekil 3. 2017-2021 yılları arası Türkiye, hasat edilen üzüm üretim alanları ve üzüm üretim miktarları (FAO, 2023)

TUİK verilerine göre ise 2017 ile 2022 yılları arasındaki altı yıllık bir dönemde Türkiye'nin bağ alanı ve üzüm üretim değerleri Çizelge 1'de sunulmuştur. Bu verilere göre, toplam bağ alanları dekar cinsinden 2017 yılında en yüksek seviyeye ulaşmış ve 2022 yılına kadar giderek azalmıştır. Üzüm üretimi açısından, en yüksek seviye 2017 yılında kaydedilmiştir. 2022 yılında, toplam bağ alanı 3.8 milyon dekara gerilemesine rağmen, 4.1 milyon tonluk üretim bir önceki yılı geride bırakmıştır. Ayrıca, 2022 yılında Türkiye'de üretilen toplam yaş üzümün %50.41'i sofralık, %40.37'si kurutmalık, %9.20'si ise şıralık-şaraplık gibi çeşitli gıda ürünlerinin elde edilmesi amacıyla kullanılmıştır. Üzüm, sirke, pekmez, sucuk, reçel, köfter (pekmez lokumu), pestil (bastık), samsa gibi ürünlerin yanı sıra son zamanlarda sanayide, ilaç ve kozmetik sektörlerinde kullanılan resveratrol gibi anti-kanserojen özelliklere sahip bir madde elde etmek için de kullanılmaktadır. Ayrıca, asma yaprağı salamura yapımında ve sarma gibi çeşitli yemeklerde değerlendirilmektedir. TUİK ve FAO verileri karşılaştırıldığında, üretim alanı ve verim rakamları aynı yıllarda birbiriyle uyumlu olduğu görülmektedir.

Çizelge 1. 2017-2022 yılları arası Türkiye bağ alanı ve üzüm üretimi (TUİK, 2023)

Yıllar	Alan (Dekar)	Toplam Üretim (Ton)	Toplam Sofralık Üretim (Ton)	Toplam Kurutmalık Üretim (Ton)	Toplam Şaraplık Üretim (Ton)
2017	4 169 068	4 200 000	2 109 000	1 603 000	488 000
2018	4 170 410	3 933 000	1 945 262	1 524 091	463 647
2019	4 054 387	4 100 000	2 050 000	1 599 000	451 000
2020	4 009 979	4 208 908	2 218 056	1 534 499	456 353
2021	3 902 211	3 670 000	1 856 929	1 430 160	382 911
2022	3 845 365	4 165 000	2 099 859	1 681 808	383 333

Türkiye’de en verimli bağlar Ege, Marmara ve Akdeniz bölgelerinde yer almaktadır. Bağcılık alanı ve üzüm üretimi yönünden ilk sıraları Ege, Akdeniz, Marmara ve Güneydoğu bölgesi almaktadır (Anonim, 2024a). 2022 üretim döneminde Türkiye genelinde yaklaşık 3.8 milyon dekarlık bir alanda üzüm yetiştirilmiştir. Bu bağ alanları içerisinde yaş üzüm, kuru üzüm ve şaraplık üzüm bulunmaktadır. Manisa, üzüm üretim alanı açısından %22.5’lik bir payla (866 bin dekar), Türkiye'deki en büyük üzüm üreticisi konumundadır. Manisa'yı sırasıyla Mardin (363 bin dekar) ve Denizli (341 bin dekar) illeri izlemektedir (TUİK, 2023). Genel olarak, Türkiye’nin üzüm üretimi, Manisa gibi önemli bölgelerde yoğunlaşmaktadır. Bağcılık sektörü, sahip olduğu bağ alanları ve yüksek üzüm üretimi ile Türkiye’nin bitkisel üretimi içerisinde önemli bir konuma sahiptir. Bu durum, üzüm tarımının ülke genelindeki ekonomik ve tarımsal önemini vurgulamaktadır.


Bağ Zararlıları

Bağ alanlarında farklı popülasyonlarda birçok zararlı türü bulunmaktadır. Bağ alanlarında görülen zararlılar yaprak, sürgün, çiçek, salkım ve kök gibi organlardan beslenerek, bitkinin zayıflamasına ciddi ürün kaybına ve ekonomik zarara neden olmaktadır. Önemli bazı bağ zararlıları, ana zararlıdan başlanarak şu şekilde sıralanabilmektedir.

Salkım güvesi [(*Lobesia botrana* Den.-Schiff.) (Lepidoptera: Tortricidae)]

Salkım güvesi bağ alanlarında ekonomik öneme sahip ana zararlı konumundadır. Erginler 10-15 mm kanat açıklığında kahverengi, zeytin kahvesi, siyahımsı ve mavimsi gri işaretlere sahip kremi beyaz ön kanatlara sahiptir (Şekil 4a). Dışınin arka kanatları koyu kahverengimsi gri iken, erkeğin arka kanatları beyazımsı gridir. Yumurtalar 0.7 x 0.6 mm boyutlarında olup ilk bırakıldıklarında sarımsıdırlar ve daha sonra grimsi bir renk almaktadır. Larvalar genellikle 11 mm uzunluğundadır. Larva vücutları grimsi yeşil veya sarımsı yeşil ile kahverengi tonları arasında değişmektedir. Genellikle yarı saydam bir yapıya sahip olup başları sarımsı kahverengidir. Pupa evresindeki bireyler 5-7 mm uzunluğunda olup renkleri sarımsı kahverengi ile koyu kahverengi arasında değişiklik göstermektedir. Salkım güvesi kışı asma kabukları altında ya da korunaklı yerlerde pupa halinde geçirmektedir. Erginler genellikle Nisan sonları veya Mayıs başlarında görülmektedir. Yumurtalar genellikle çiçek tomurcuklarına bırakılmakta ve yaklaşık bir hafta içinde çatlamaktadır. Larvalar daha sonra çiçek tomurcuklarına saldırmakta ve gelişmekte olan çiçek durumlarının içinde ipeksi ağlar örmektedir. Bir sonraki neslin güveleri yaklaşık bir hafta sonra ortaya çıkmaktadır. İkinci nesil larvaları, büyümekte olan üzüm salkımlarını tüketmektedir. Koşullar elverişli olduğunda, gelişimleri son derece hızlı olabilmekte ve aynı mevsim içinde 1-2 nesil daha tamamlanabilmektedir. Ülkemizde genellikle 3 döl vermektedir. Orta Anadolu'nun bazı bağ alanlarında ise 2 döl vermektedir. Salkım güvesinin 1. döl larvaları tomurcuk ve çiçeklerde zarar yapmaktadır. Zarara uğrayan tomurcuk ve çiçekler dökülmektedir. Zarar seviyesine göre ilerde çok seyrek veya az seyrek taneli salkımlar oluşmaktadır. Bağlarda 2. döl üzümün koruk döneminde, 3. döl ise olgun üzüm tanelerine zarar vermektedir. Tomurcuk ve çiçek aşamalarında, larvalar tomurcukların ve çiçeklerin içinde beslenirken, ördükleri ipliklerle bunları birbirine bağlayarak küme haline getirmektedir (Şekil 4b). Bu beslenme süreci zararlılar tarafından etkilenen tomurcuk ve çiçeklerin dökülmesine neden olmaktadır. Bu durum, ileri aşamalarda salkımların seyrekleşmesine veya az meyve vermesine yol açabilmektedir. Koruk ve olgun tanedeki zarar ise, tane içinde beslenmesi suretiyle

gerçekleşmektedir (Şekil 4c). Bu beslenme süreci, bir tane içinde olmayıp, birden fazla tanede larvanın arasında hareket ederek meydana gelmektedir. Larvaların olgun üzüm tanelerinde beslenme ve yer değiştirme sıklığı daha fazla olduğundan, meydana gelen zarar kolaylıkla görülmektedir. Ayrıca, bu olgun tanelerden akan şekerli su, fungusların (mantarların) çoğalmasına neden olarak meydana geldiği zararı daha belirgin hale getirmektedir (Şekil 4d) (Anonim, 2017).



Şekil 4. Salkım güvesi; a) yaşam döngüsü, b) 1.döl zararı, c) 2. döl zararı ve d) 3. döl zararı

Bağ Tripsi (*Thysanoptera: Thripidae*)

Rubiothrips vitis (Priesner)

Mycterothrips albidicornis Kenchtel,

Mycterothrips tschirkunae (Jachontov)


Frankliniella occidentalis (Pergande)

Drepanothrips reuteri Uzel

Thrips tabaci Lindeman

Bağ tripsi erginleri küçük boyda (0,6-1,5 mm) ve silindir yapılı vücuda sahiptir. Ön ve arka kanatların etrafında saçak şeklinde kıllar bulunmaktadır. Larva ve erginlerin ağız yapıları sokucu emici şeklindedir. Yumurtalar gözle görülemeyecek kadar küçük olup, bitki dokusu içine bırakılmaktadır. Yumurtadan çıkan bireyler, iki larva döneminden sonra pupa öncesi dönem ve pupa dönemlerini de geçirerek ergin olmaktadır. Erginler, kışı asmanın kavlamış kabukları altında, toprakta ve yabancı otlarda geçirmektedir (Şekil 5a) (Anonim, 2017).

Tripsler, bağlarda genç sürgünler, yapraklar, tomurcuklar ve çiçekler gibi hassas dokulara yumurta bırakarak ve özellikle bu bölgelerden beslenerek zarar vermektedir. Uyanmış gözlerle birlikte sürgünlere giren ergin tripsler, genellikle genç yaprakların alt yüzeyinde beslenmektedir. Bu sırada epidermis hücrelerinin suyunu emmekte ve boşaltmaktadır. Tripslerin emdiği bölgeler öncelikle beyaz görünmekte ve zamanla koyulaşarak esmer bir renk almaktadır (Şekil 5c). Bu emilen bölgeler zamanla kurumakta ve yaprak büyüdükçe yırtılmaktadır. Sonuç olarak yapraklar delinmekte ve dökülmektedir. Ayrıca, çiçek tomurcuklarının saplarını da emerek çiçeklerin dökülmesine sebep olabilmektedirler. Taneler belirli bir büyüklüğe ulaştığında beslenmeye devam ederlerse, ilerleyen dönemlerde kabukta deformasyonlara neden olabilmektedir (Şekil 5b). Bu durum ürünün pazar değerini düşürmektedir (Anonim, 2011).




Şekil 5. Trips; a) yaşam döngüsü, b) asmadaki hasarı ve c) yapraktaki hasarı

İki noktalı kırmızıörümcek [(*Tetranychus urticae* Koch.) (Acarina: Tetranychidae)]

İki noktalı kırmızıörümcek (*Tetranychus urticae* Koch.), ekonomik değeri olan genellikle 150'den fazla bitki türüne zarar veren ve yaygın görülen bir akardır (Cazaux ve ark., 2014). Yumurtaları genellikle yuvarlak ve yarı saydam bir yapıda olmaktadır (Şekil 6a). Nimf dönemlerinde ve erginler genellikle yeşil renkte olup, sırt bölgelerinde iki siyah leke

bulunmaktadır. Dişiler sonbaharda kışa girmeden önce kiremit kırmızısına dönebilmektedir (Anonim, 2017; Bartel ve Bennison, 2023). İki noktalı kırmızıörümcek, bitki dokusuna iğne benzeri emici-sokucu ağız yapılarıyla nüfuz etmekte ve genellikle yaprakların alt kısımlarında bulunmaktadır. Bu akarlar konukçu bitkide ince ağlar örmekte, yumurta ve genç evreleri bu ağlar arasında bulunmaktadır. İki noktalı kırmızıörümcek akarları, özsuyu emdiklerinde beslenme bölgesinde mezofil dokusunun çökmesine yol açarak küçük klorotik (soluk renkli) noktalar oluşturmaktadır. (Şekil 6b). Bu beslenme sürecinde dakikada 18 ila 22 hücrenin tahrip edildiği tahmin edilmektedir. Akarların kontrol altına alınmadığı durumlarda, yapraklarda ciddi zararlar meydana gelebilmekte ve bazen yaprakların tamamen dökülmesine kadar varan hasarlara sebep olunabilmektedir (Fasulo ve Denmark, 2003).




Şekil 6. İki noktalı kırmızıörümcek, a) yaşam döngüsü ve b) yapraktaki hasarı

Bağ yaprak uyuzu [(*Colomerus vitis* Pgst.) (Acarina: Eriophyidae)]

Bağ yaprak uyuzu, mikroskopla bile zor görülebilecek kadar küçük olan bir zararlıdır (Şekil 7a). Bu nedenle sadece yaprağın üst ve alt yüzeyinde oluşturduğu hasar belirtileriyle tanınabilmektedir. Dişisi yaklaşık olarak 0.16 mm, erkeği ise 0.14 mm büyüklüğündedir. Vücudu oldukça uzun ve yaklaşık 80 halkadan oluşmaktadır. Bu halkalar arasındaki boğumlar ince ve noktalı yapıdadır. Vücudu üzerinde seyrek olarak sert kıllar bulunmakta ve abdomenin


sonunda iki uzun kıl bulunmaktadır. İki çift bacağı vardır. Zararlı, kış mevsimini gözlerdeki tüyler arasında ve ince dalların çatlaklarında ergin olarak geçirmektedir. Baharın gelmesiyle birlikte, bu zararlı yeni oluşan yapraklara geçerek beslenmeye başlamaktadır. Erginler, yumurtalarını yaprağın alt yüzeyinde beslendikleri yerlerde oluşan tüyler arasına bırakmaktadır. Yumurtalardan çıkan nimfler, beslenerek ergin hale gelmekte ve yılda 7-8 döl verebilmektedir. Zararlı, asma yapraklarının alt yüzeyinden beslenerek özsuyu emmektedir. Bu beslenme sonucunda, emilen bölgelerde öncelikle beyaz renkli alanlar oluşmakta ve daha sonra yaprağın üst yüzeyinde kabartılar meydana gelmektedir. Yapragın altındaki beyaz ve çukur bölgelerde ise tüyler oluşmaktadır. Bu tüylü alanlar daha sonra kahverengi bir renk almaktadır (Şekil 7b). Zararlı genellikle asmanın yapraklarında, çiçek tomurcuklarında ve çiçeklerinde beslenmektedir. Yapraktaki beslenme ilkbaharda gözler açılırken başlamakta ve geç sonbahara kadar devam etmektedir. Zarar gören yapraklar, tam anlamıyla fotosentez yapamamakta ve bu durum yoğunluğa bağlı olarak üründe önemli kayıplara neden olmaktadır (Anonim, 2017).



Şekil 7. a) Bağ yaprak uyuzu akarı ve b) yaprağın ön ve arka kısmında oluşturduğu hasar

Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme

Yapay zeka terimi, 1950'lerde bilgisayarların düşünebilme yeteneğiyle ilgili bir soruyla ortaya çıkmıştır. Şekil 8'de gösterildiği gibi, geniş bir perspektifle bakıldığında, yapay zeka genel olarak makine öğrenmesi ve derin öğrenmeyi içeren bir alanı kapsamaktadır (Campesato, 2020). Yapay zeka, insan zekasının öğrenme, algılama, geçmiş deneyimleri kullanma ve yeni durumlara karar verme yeteneklerini bilgisayar, makine veya sistemlere aktararak, tahmin edilebilen veya edilemeyen yeni durumlar ile karşılaşıldığında karar vermenin sağlanması ve gerekli işlemleri yapabilme sürecidir. İnsan zekası tarafından bir konu hakkında değerlendirme yapılırken hangi parametreler incelenip değerlendiriliyorsa yapay zekaya da bu değişkenler öğretilmekte ve insan zihninin benzer yorumlama yeteneklerine sahip bilgisayar modelleri aracılığıyla karar verme için formüller oluşturulmaktadır. Bu sayede, insan düşünme yapısına benzeyen, bilgisayar yazılımlarıyla bir düşünme ve karar verme modeli geliştirilmektedir (Özgüven, 2019).



Şekil 8. Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki ilişki

Makine öğrenmesi, yapay zekanın bir alt dalıdır. Öncelikle, çeşitli algoritmalar ve teknikler kullanılarak geçmiş verilere bakılmakta ve veriler arasındaki karmaşık desenleri belirleyecek matematiksel modeller oluşturulmaktadır. Daha sonra bu modeller, belirli bir hedef üzerine tahmin yapmak için kullanılmaktadır. Makine öğrenmesi yöntemleri arasında k-en yakın komşu (KNN) algoritması, basit (naive) Bayes sınıflandırıcısı, karar ağaçları, lojistik regresyon


analizi, k-ortalamlar algoritması, destek vektör makineleri ve yapay sinir ağı gibi yöntemler bulunmaktadır. Bu yaklaşımların bazıları tahmin ve kestirim yapabilirken, bazıları veri kümeleme ve sınıflandırma gibi yeteneklere sahiptir (Özguven, 2019). Makine öğrenmesinin amacı, önceden görülmemiş bir girdi için doğru tahminler yapmak veya kararlar vermek ve bu süreçleri otomatikleştiren verimli algoritmaların geliştirilmesidir. Algoritmalar geliştirilirken, bir uzmanın bir karar verirken nelere dikkat ettiğiyle ilgili kriterler göz önünde bulundurulmalıdır. Makine öğrenmesi yöntemlerinin uygulanmasında hesaplama, eğitim ve eğitilmiş algoritmanın uygulanması gibi karmaşıklıklar bulunmaktadır. Bir algoritmanın performansı genellikle test hatasıyla değerlendirilmektedir. Ayrıca, bir algoritma çalışırken, birçok test noktası bulunabilmekte ve bu noktalarda hızlı kararlar alınması gerekmektedir. Bu nedenle, test işleminin düşük hesaplama yüküne sahip olması önemlidir (Ozguven, 2023).

Derin öğrenme ise insan beyninin nöronlarından esinlenen bir makine öğrenmesi alt dalıdır. Bu tür öğrenme, görme, işitme, basınç gibi duyuşal bilgileri işleyen nöronlar gibi daha düşük seviyeli özelliklerden, daha yüksek seviyeli özellikleri belirlemek için bir hiyerarşi oluşturmaktadır. Bu hiyerarşideki her bir nöron, alt seviyedeki diğer nöronların çıkışlarından gelen giriş sinyallerinin ağırlıklı ortalamasını hesaplayarak çalışmaktadır. Derin öğrenme sürecindeki ağırlıklar, geriye yayılma gibi algoritmalarla hesaplanmaktadır. Evrişimli Sinir Ağı'nda (CNN) bir nöronun çıkışı, sadece kendisine komşu olan diğer nöronlardan gelen girdilere dayanmaktadır. Ancak, yapay sinir ağı durumunda girdiler, tüm nöronların çıkışlarından gelmektedir. Bu algoritmalar, bir nesnenin hangi sınıfa ait olduğunu belirleyen ağırlıkları, sınıflar arasındaki hatayı belirli bir değere indirgeyerek eğitmektedir. Bu yakınsanmış ağırlıklar, veri setinin soyut ve karmaşık bir temsilini oluşturmaktadır. Derin sinir ağı eğitildikten sonra, girdiler üzerinde karar verme aşamasında yalnızca bu yakınsanmış ağırlıklar kullanılmaktadır. Yapay sinir ağı, daha az katman içeren bir yapıya sahipken, derin öğrenme ağı yüzlerce veya binlerce katmana sahip olabilmektedir. Bu fark, yapay sinir ağı ile derin öğrenme arasındaki ana ayrımı oluşturmaktadır (Deng ve Yu, 2014). Derin öğrenmede, CNN modelleri, ön işleme adımlarına ihtiyaç duyulmadan oluşturulabilmektedir. Bu modeller, diğer makine öğrenimi yöntemlerine kıyasla, sınıflandırma işlemlerini daha hızlı ve doğru bir şekilde gerçekleştirebilmektedir (Adem, 2018; Adem ve Közkurt, 2019).

Evrişimli Sinir Ağı (CNN)

CNN, özellikle görüntü işleme ve tanıma görevleri için tasarlanmış derin öğrenme algoritmasıdır. CNN alternatif sınıflandırma modelleriyle karşılaştırıldığında, ham girdi

görüntülerinden hiyerarşik özellik temsillerini otomatik olarak öğrenebildikleri için daha az ön işleme gerektirmektedir. CNN modellerindeki bağlantı şekli, nöronların görsel uzaydaki belirli bölgelere veya alıcı alanlara yanıt verdiği insan beynindeki görsel korteksten ilham almaktadır. Bu mimari, CNN modelinin görüntülerdeki mekansal ilişkileri ve desenleri etkili bir şekilde yakalamasını sağlamaktadır (Bhatt ve ark., 2021). Çok katmanlı algılayıcıya benzeyen bir CNN türü, birçok evrişim katmanı, havuzlama katmanı ve son olarak tam bağlantılı katmanlardan oluşmaktadır. Şekil 9'da verilen genel CNN mimarisi incelendiğinde, giriş katmanı ağın girdi olarak aldığı görüntü verisidir. Evrişim katmanı, girdiyi işleyerek kenar, doku gibi özellikleri çıkartmaktadır. Havuzlama katmanı, boyutluluk ve hesaplama karmaşıklığını azaltmak için özellik haritalarını küçültmektedir. Düzleştirme katmanı, 2 boyutlu özellik haritalarını 1 boyutlu vektöre dönüştürerek tam bağlantılı katmanlara beslemektedir. Tam bağlantılı katman çıkarılan özelliklere dayanarak tahmin veya sınıflandırma yapmaktadır. Son olarak softmax katmanı ise ham skorları her sınıf için olasılıklara dönüştürmektedir. (Alzubaidi ve ark., 2021).



Şekil 9. Genel CNN mimarisi

Giriş Katmanı

CNN mimarisindeki ilk katman, modelin eğitimi için kullanılan her örneğin girişini almaktadır. Giriş verisi, modelin performansını önemli ölçüde etkileyen bir faktördür. Veri setinin boyutu, modelin eğitim süresi üzerinde önemli bir etkiye sahiptir. Büyük veri setleri, daha genel ve doğru bir model oluşturmak için daha fazla örüntüyü öğrenmeye olanak tanırken, eğitim süresini ve bellek ihtiyacını artırabilmektedir. Bununla birlikte, küçük veri setleri, modelin daha hızlı eğitilmesini sağlayabilmektedir. Ancak genellikle daha az genellemeye sahip


olabilmektedir. Bu nedenle, veri seti seçimi ve boyutu, CNN modeli oluşturulurken dikkat edilmesi gereken önemli bir karar noktasıdır.

Evrişim Katmanı

Evrişim katmanı ağıın esas yapı taşı olup, büyük ölçüde hesaplamaların gerçekleştirildiği yerdir. Giriş verilerine filtreler uygulayarak özellikler belirlenmektedir. Bu filtreler "özellik dedektörü" denilmekte ve belirli özelliklerin algılaması için görüntü girişinin belirli bir alanı kontrol edilmektedir. Bu sürece "evrişim" denir. Filtre, iki boyutlu bir ağırlık dizisi olup, genellikle iki boyutlu bir görüntünün bir kısmını temsil etmektedir. Filtre genellikle 3x3 boyutunda bir matristir. Ancak farklı boyutlarda filtreler de kullanılabilir. Filtre, giriş görüntüsündeki bir bölgeye uygulanmakta ve pikseller arasında nokta çarpımı yaparak çıktı dizisine beslenmektedir. Filtre daha sonra kaydırılmakta ve işlem görüntünün tamamını kapsayacak şekilde tekrarlanmaktadır. Tüm filtre işlemlerinin son çıktısına "özellik haritası" denilmektedir. CNN genellikle, her evrişimden sonra her özellik haritasına ReLU (Düzeltilmiş Doğrusal Birim) dönüşümü uygulayarak, modelin doğrusal olmayan özellikler kazanmasını sağlamaktadır. Bir evrişim katmanının genellikle bir havuzlama katmanı takip etmektedir.

Havuzlama (Maxpooling) katmanı


Havuzlama (Maxpooling) katmanının temel görevi, özellik haritalarının alt örneklenmesi işlemidir. Bu haritalar, evrişim işlemlerini takiben oluşturulmaktadır. Diğer bir deyişle, bu yaklaşım büyük boyutlu özellik haritalarını, küçük özellik haritaları oluşturacak şekilde daraltmaktadır. Aynı anda havuzlama aşamasının her adımında belirgin bilgilerin (veya özelliklerin) çoğu da korunmaktadır. Evrişim işlemine benzer şekilde, havuzlama işleminden önce adım ve çekirdek boyutu başlangıçta belirlenmektedir. Çeşitli havuzlama katmanlarında kullanılmak üzere birkaç tür havuzlama yöntemi bulunmaktadır. Şekil 10'da en çok kullanılan havuzlama yöntemleri maksimum, minimum ve küresel ortalama havuzlama işlemleri gösterilmektedir (Alzubaidi ve ark., 2021).



Şekil 10. Ortalama, maksimum ve küresel ortalama havuzlama (Alzubaidi ve ark., 2021)

Düzleştirme Katmanı


Özellik haritaları, görüntünün farklı özelliklerini yakalamak için evrişim ve havuzlama katmanları tarafından oluşturulan 2 boyutlu matrislerdir. Bu matrisler, görüntünün yüksek seviyeli bir temsilini sağlamaktadır. Ancak matrisler tam bağlantılı katmanlara girmeden önce, düzleştirme katmanı tarafından işlenmeleri gerekmektedir. Düzleştirme katmanı, 2 boyutlu matrisleri tek boyutlu bir vektöre dönüştürmekte ve bu vektörü tam bağlantılı katmanlara göndermektedir. (Şekil 11).



Şekil 11. Düzleştirme katmanı

Tam Bağlantılı (Full-Connected) Katman

Geleneksel bir CNN’de, evrişim ve havuzlama işlemlerinin ardından genellikle tam bağlantılı bir katman bulunmaktadır. Tam bağlantılı katman, adından da anlaşılacağı gibi bir önceki katmanın tamamıyla bağlantılıdır. Bu katmanda gerçekleştirilen işlem, önceki katmandan gelen verilerle ağırlık değerlerinin çarpılması ve ardından bir sapma (bias) değerinin eklenmesidir. Bu işlem, her bir önceki katman düğümünün, sonraki katmana tamamen bağlanması anlamına gelmektedir. Bu katman, öz nitelikleri düzleştirerek ve tam bağlantılı bir yapıya dönüştürerek gelen öz nitelikleri birbirine bağlamaktadır. Şekil 12’de örnek bir tam bağlantılı katman yapısı görseli verilmiştir.



Şekil 12. Tam bağlantılı katman yapısı

Sınıflandırma (Softmax) Katmanı

Sınıflandırma (Softmax) Katmanı, sinir ağı modelinin son katmanı olarak kullanılan bir yapıdır. Bu katman, sinir ağından gelen gerçek değerli çıktıları sınıflar arasında olasılıkları temsil eden bir dağılıma dönüştürmektedir. Yani, sınıflandırma katmanı, sinir ağının çıktılarını 0 ile 1 arasında ve toplamı 1 olacak şekilde normalize etmektedir. Özellikle çok sınıflı sınıflandırma problemlerinde kullanılan sınıflandırma katmanı, her bir sınıf için bir olasılık değeri sağlamaktadır. Bu sayede, sinir ağının çıktıları doğrudan hangi sınıfa ait olduğunu gösteren olasılık değerlerine dönüştürülmektedir. Sınıflandırma katmanı, modelin sonucunu daha anlaşılır ve yorumlanabilir hale getirmektedir. Aynı zamanda diğer sistemlere giriş olarak da kullanılabilir. Bu nedenle, genellikle sinir ağlarının son katmanında sınıflandırma katmanı kullanılmaktadır (Philips, 2023).

Derin Öğrenme Uygulamalarında Hiper parametreler

CNN mimarisinde katmanlarının yanı sıra ideal hiper parametrelerin kullanımı da büyük önem taşımaktadır. Bu hiper parametreler modelin performansı, eğitim süresi ve başarı oranı gibi ölçütleri etkilemektedir. Kullanım yöntemleri ve değerleri, kullanıcı tarafından tercih edilen ve veri setinin türü ve boyutuna bağlı olarak değişkenlik göstermektedir. En etkili sonuçların elde edilmesi için uygun hiper parametre kombinasyonunu bulmak oldukça önemlidir. Hiper parametreler genellikle iki ana grupta incelenmektedir: ağ yapısını belirleyenler ve eğitimi yönlendirenler. Ağ yapısını belirleyen hiper parametreler arasında filtre boyutu, tipi, adım büyüklüğü (stride), kenar dolgusu (padding), gizli katman sayısı ve aktivasyon fonksiyonları gibi öğeler bulunurken, eğitimi etkileyen parametreler arasında öğrenme oranı, eğitim devir sayısı (epoch), veri yığın boyutu (batch size) ve momentum yer almaktadır (Aszemi ve Dominic, 2019).

Veri Setinin Boyutu

Derin öğrenme çalışmalarında, veri setinin boyutu ve içeriği önemli bir ölçüttür. Genellikle daha fazla örnekle başarıya olumlu katkıda bulunurken, daha az örnek içeren veri setleri eğitimi olumsuz yönde etkileyebilmektedir. Bu nedenle, veri artırma teknikleri sıklıkla kullanılmaktadır. Başarı oranı genellikle veri setinin büyüklüğüyle ilişkilidir. Ancak büyük bir veri setiyle çalışmak model başarısı için her zaman yeterli değildir. Ayrıca, veri çeşitliliği, veri setindeki örneklerin sınıflandırma açısından benzerlik gösterip göstermemesi veya verinin gürültülü olup olmaması gibi faktörler modelin başarısını etkileyebilmektedir.


Aktivasyon Fonksiyonları

CNN'in mimari yapısında kullanılan aktivasyon fonksiyonları, model geliştirme sürecinde önemli bir rol oynamaktadır. Aktivasyon fonksiyonları, sinir ağlarında nöronların çıktısına doğrusal olmayan özellikler eklemek için önemlidir. Aktivasyon fonksiyonu olmadan, bir sinir ağı sadece karmaşık veri özelliklerini temsil edemeyen bir doğrusal regresyon modeli olmaktadır. Aktivasyon fonksiyonları, ağırlıkların gradyanlarını hesaplamak ve geri yayılımı gerçekleştirmek için türevleri alınabilir olmalıdır (Walia, 2017). En popüler ve yaygın kullanılan aktivasyon fonksiyonları arasında sigmoid, hiperbolik tanjant (tanh), doğrultulmuş doğrusal birim (ReLU) (Nair ve Hinton, 2010), Leaky ReLU, Maxout (Goodfellow ve ark., 2013), üstel lineer birim (ELU) (Clevert ve ark., 2016) bulunmaktadır (Şekil 13). Doğru

aktivasyon fonksiyonlarını bulmak için otomatik arama teknikleri, fonksiyon yapıları ve ilgili hiper parametreleri içeren araştırmalar yapılmıştır (Ramachandran ve ark., 2017).


Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$




Leaky ReLU

$$\max(0.1x, x)$$



tanh

$$\tanh(x)$$




Maxout

$$\max(w_1^T x + b_1, w_2^T x + b_2)$$


ReLU

$$\max(0, x)$$



ELU


$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases}$$



Şekil 13. En yaygın kullanılan aktivasyon fonksiyonları (Jadon, 2018)

Eğitim Devir (Epoch) Sayısı

Model eğitimi sırasında verilerin tamamı aynı anda kullanılmamaktadır. Bunun yerine belirli sayıda modül halinde eğitime dahil edilmektedir. İlk modül veri eğitilerek modelin performansı test edilmekte ve bu performansa göre geriye yayılım (backpropagation) ile ağırlıklar güncellenmektedir. Ardından, yeni veri parçaları kullanılarak model yeniden eğitilmekte ve ağırlıklar güncellenmektedir. Bu süreç, her eğitim adımında tekrarlanmakta ve en uygun ağırlık değerleri model için hesaplanmaya çalışılmaktadır. Her bir eğitim adımı, "epoch" olarak adlandırılmaktadır. Derin öğrenmede, en uygun ağırlık değerleri adım adım hesaplandığı için başlangıçtaki eğitim devir sayısında başarı düşük olabilmektedir. Ancak eğitim devir sayısı arttıkça genellikle başarı da artmaktadır. Belli bir noktadan sonra modelin öğrenme kabiliyeti azalabilmektedir. Yani, eğitim adımları her eğitim devir sayısında modelin ağırlıklarını geliştirmeye yönelik olup başlangıçta performans düşük olabilirken, eğitim devir sayısı arttıkça genellikle performans iyileşmektedir. Ancak model, belli bir aşamadan sonra yeni bilgileri öğrenme konusunda daha da zorlanabilmektedir. Bu nedenle, eğitim devir sayısının uygun bir seviyede tutulması ve aşırıya kaçılmaması önemlidir (Çarkacı, 2018). Şekil 14'de örnek bir doğruluk ve eğitim devir sayısı grafiğinin görseli verilmiştir.



Şekil 14. Örnek bir doğruluk-eğitim devir sayısı grafiği (Anonim, 2024b)

Veri Yığın (Batch) Boyutu

Eğitim sürecinde, her iterasyonda geriye yayılım ve ağırlık güncellemesi işlemleri yapılarak bir zaman ve bellek maliyeti oluşmaktadır. Hesaplama maliyetini azaltmak için veri seti genellikle küçük gruplara bölünmektedir (Çarkacı, 2018). Veri setinin, ağırlık güncellemesi sonrasında sinir ağına verilen alt örneklerin sayısı olarak ifade edilen "veri yığın boyutu" ya da "batch size" değeri, algoritmanın eğitimi için önemli bir parametredir (Gaspar ve ark., 2021). Model eğitimi, veri setinin bu veri yığın değerine göre parçalara ayrılarak gerçekleştirilmektedir. Veri yığın boyutu değerinin yüksek veya düşük olması, özellik çıkarımında farklı sonuçlara neden olabilmektedir. Yüksek veri yığın boyutu seçimi, daha genel özelliklerin algoritmanın daha hızlı çalışmasını sağlayabilirken, detaylı bir çıkarım yapılmasını da engelleyebilmektedir. Benzer şekilde, modelin etkili bir şekilde öğrenmesi için çok düşük veri yığın boyutu seçimi de tavsiye edilmemektedir. Veri yığın boyutu değeri genellikle grafik işleme birimi (GPU) belleğine uyum sağlamak adına 2'nin katları şeklinde belirlenmektedir (2, 4, 8, 16, 32, ..., 512) (Çarkacı, 2018). Literatürde yapılan çalışmalarda, veri yığın boyutunun genellikle 64 ile 1024 arasında değerlerde olduğu belirtilmektedir (Ruder, 2016).

Öğrenme Oranı (Learning Rate) ve Momentum Katsayısı (Momentum)

Derin öğrenme modellerinde, parametrelerin güncellenmesi geriye yayılım adı verilen bir süreçle gerçekleşmektedir. Geriye yayılım, zincir kuralı (chain rule) kullanılarak, ağırlık


çıktılarının ve gerçek değerlerin farkının alınmasıyla başlamaktadır. Bu fark, öğrenme oranı (learning rate) parametresiyle çarpılarak ağırlık katmanları boyunca geriye doğru türev alınarak ağırlıkların güncellenmesi ile sağlanmaktadır. Bu süreçte kullanılan öğrenme oranı parametresi, sabit bir değer olabilmekte veya eğitim adımları ilerledikçe artan bir değer alabilmektedir (örneğin, belirli bir eğitim adımından sonra 0.001'den 0.01'e çıkabilmektedir). Ayrıca, momentum değeri veya adaptif optimizasyon algoritmalarıyla da öğrenme oranı süreci dinamik olarak ayarlanabilmektedir. Stokastik gradyan inişi gibi salınım ve gürültü oluşturan yöntemlerin etkilerini azaltmak için üssel ağırlık ortalaması (exponential weight average) gibi teknikler kullanılmaktadır. Bu teknikler, salınım ve gürültüyü azaltmak için momentum beta katsayılarıyla normalizasyon işlemi gerçekleştirmektedir. Yani, yeni hesaplanan değeri doğrudan almak yerine, bu değeri bir önceki değerle belirli bir oranda (beta katsayısıyla) birleştirilerek yeni değer elde edilmektedir. Bu yöntem, gürültüyü ve salınımı azaltarak daha istikrarlı ve hızlı bir optimizasyon süreci sağlamaktadır (Çarkacı, 2018).

Optimizasyon Algoritmaları

Optimizasyon algoritmaları derin öğrenme modellerinin eğitim süreçlerinde önemli bir rol oynamaktadır. Optimizasyon algoritmaları modelin eğitim hızını, doğruluğunu ve genelleme yeteneğini önemli ölçüde etkilediğinden en doğru seçimin yapılması gerekmektedir. Bu bağlamda, optimizasyon algoritmalarıyla ilişkili hiper parametrelerin doğru bir şekilde ayarlanması kritiktir (Yu ve Zhu, 2020). Her bir optimizasyon algoritması, farklı veri setleri veya model yapıları için daha uygun olabilmektedir. Hangi algoritmanın hangi durumda daha etkili olduğunu belirlemek için genellikle deneysel olarak test edilmeleri gerekmektedir. Yaygın olarak kullanılan en güncel optimizasyon algoritmaları, Stokastik Gradyan İnişi (SGD), Uyarlanabilir Moment Tahmini (Adam), Adamax, AdamW, NAdam, RAdam ve RMSProp şeklindedir.

Derin Öğrenmede Nesne Algılama


Nesne algılamanın bilgisayarlı görü alanında temel hedeflerinden biri, bir görüntü içerisinde yer alan nesneleri hem sınıflandırmak hem de onların doğru konumlarını belirlemektir. Nesne algılama, genellikle algılanan nesnelerin bulunduğu alanları dikdörtgen kutularla çevreleyerek ilgili nesneleri tanımlamaktadır. Nesne algılama süreci, bilgisayarın görüntüdeki nesneleri sınıflandırma ve konumlarını belirleme yeteneğini içermektedir. Sınıflandırma, nesnelerin hangi kategorilere ait olduğunu belirlerken, konum belirleme, nesnelerin tam olarak nerede olduğunu ve hangi alanı kapladıklarını tanımlamaktadır (Şekil 15).



Şekil 15. Sınıflandırma ve nesne algılama karşılaştırması

Nesne Algılamada Performans Metrikleri

Nesne algılama modellerinin performansını değerlendirmek için kullanılan metrikler, genellikle modelin doğruluğunu, kesinliğini ve tam olarak nesneleri tespit edebilme yeteneğini ölçmek amacıyla kullanılmaktadır. Metrikler, genellikle gerçek nesnelerin yerini ve boyutunu tahmin eden modelin çıktıları karşılaştırarak çalışmaktadır. Birleşim Üzerinde Kesişim (IoU) metriği, model tarafından tespit edilen nesne kutularının gerçek nesne kutularıyla ne kadar örtüştüğünü ölçmekte ve genellikle % olarak ifade edilmektedir. IoU Şekil 16’da gösterildiği gibi hesaplanmaktadır.




Şekil 16. IoU hesaplama yöntemi

Ortalama Kesinliklerin Ortalaması (mAP- Mean Average Precision) metriği ise farklı nesne sınıfları için ayrı ayrı hesaplanmakta ve nesne sınıflarının hassaslık oranlarının ortalaması alınarak performansın genel bir ölçüsü elde edilmektedir. Bu metrik, tüm sınıfların hassaslık performanslarını dikkate alarak modelin genel başarısı değerlendirilmektedir. Bu metrikler, modelin ne kadar doğru ve hassas olduğunu, kaç nesne tespit edildiğini ve gerçek nesnelerle ne kadar uyumlu olduğunu ölçmek için kullanılmaktadır. Yüksek IoU ve yüksek mAP değerleri, modelin daha doğru ve güvenilir olduğunu gösterirken, düşük değerler ise modelin iyileştirilmesi gerektiğini işaret edebilmektedir. Bu değerler, farklı modellerin ve yöntemlerin karşılaştırılmasında ve modelin performansının iyileştirilmesinde kullanılmaktadır.

Nesne Algılama Yöntemleri

Nesne algılama yöntemleri, öncelikle CNN kullanarak 2 aşamalı yöntemler ve tek aşamalı yöntemler olmak üzere 2 ana kategoriye ayrılmaktadır (Şekil 17). İki aşamalı yöntemler, tek aşamalı yöntemlere kıyasla, daha yüksek bir tespit doğruluğuna sahip olsa da nispeten daha yavaş bir tespit hızına sahiptir. Tek aşamalı yöntemler ise çok daha hızlı bir tespit hızına sahiptir. Ancak bu durum bazı doğruluk kısımlarını azaltabilmektedir. Belirli bir nesne algılama yöntemi kullanmadan önce, her yöntemin avantaj ve dezavantajlarını değerlendirmek ve modeli buna göre ayarlamak önemlidir.



Şekil 17. Tek ve iki aşamalı nesne algılama yöntemlerinin karşılaştırması

İki Aşamalı Yöntemler

İki aşamalı yöntemler, nesne tespitini bir bölge önerisi aşaması ve bir nesne tespit aşaması olmak üzere çok aşamalı bir süreç olarak ele almaktadır. Temel fikir, başlangıçta bölge önerisi

algoritmasını kullanarak aday nesne önerileri kümesi oluşturmak ve daha sonra ayrı bir nesne tespit ağı kullanarak bu önerileri sınıflandırmak ve düzeltmektir. İki aşamalı bir yöntem kullanmak, sınıflandırıcıda kullanılan potansiyel olarak büyük sayıdaki önerileri azaltma ve oluşturulan önerilerin arka plandan minimum etki ile sınıflandırma görevine odaklanmasını sağlama gibi avantajlar sağlamaktadır. En yaygın olarak kullanılan iki aşamalı yöntemler R-CNN, Fast R-CNN ve Faster R-CNN modelleridir.

Tek Aşamalı Yöntemler

İki aşamalı yöntemlerden farklı olarak, tek aşamalı yöntemler nesnenin konumunu ve sınıfını aynı anda tahmin etmeye odaklanmaktadır. İki aşamalı yöntemlerin aksine, tek aşamalı yöntemler daha hızlı ve daha yüksek bir tespit doğruluğunu elde edebilmektedirler. En yaygın kullanılan tek aşamalı yöntemler SSD, RetinaNet ve YOLO şeklinde sıralanabilir.

Ülkemizde önemli bir yere sahip bağcılık sektöründe ortaya çıkan ve ciddi ürün kayıplarına neden olan salkım güvesi, trips, bağ yaprak uyuzu ve iki noktalı kırmızıörümcek gibi zararlıların neden olduğu hasarların tespit edilebilmesi amacıyla yapılan bu tez çalışmasında, gerçek bağ arazi koşullarından elde edilen yaprak ve meyve görüntülerini içeren özgün bir veri seti oluşturulmuştur. Ayrıca çalışmada, zararlı hasarlarının daha hızlı, hassas ve etkili tespitinin gerçekleştirilmesi için çeşitli modifikasyonlarla özelleştirilmiş daha az parametreye sahip ve hesaplama açısından daha az karmaşık bir tek aşamalı nesne algılama modeli geliştirilmiştir. Geliştirilen model, farklı optimizasyon algoritmaları ve giriş boyutlarıyla test edilmiştir. Ayrıca çalışmada geliştirilen model, performans bakımından değerlendirilmesi için farklı modellerle karşılaştırılmıştır.

2. LİTERATÜR ÖZETLERİ

Liu ve Wang (2020), domates bitkisinde hasara neden olan erken yanıklık, geç yanıklık, sarı yaprak kıvrılma virüsü, kahverengi leke, gri küf, yaprak küfü, yaprak kıvrırma hastalığı, mozaik virüsü, yaprak güvesi ve beyazsinek gibi bazı hastalık ve zararlıların tespit edilmesi amacıyla yaptıkları çalışmada geliştirilen YOLOv3 modelini önermişlerdir. Bu amaç doğrultusunda çalışmada, 15 000 görüntüden oluşan PlantVillage veri seti kullanılmıştır. Çalışmada geliştirilen modelde, özellik haritalarının sayısını artırmak için özellik füzyonu yöntemi kullanılmıştır. Ayrıca çalışmada geliştirilen YOLOv3 modeli, SSD, Faster R-CNN ve YOLOv3 modelleri ile karşılaştırılmıştır. Yapılan karşılaştırmalar sonucunda, geliştirilen YOLOv3 modeli ile %92.39 doğruluk değeri elde edildiği ve diğer modellere kıyasla daha iyi bir performans gösterdiği raporlanmıştır.

Lee ve ark. (2020) çalışmalarında, çay yapraklarındaki görülen üç hastalık (kahverengi leke, kabarcık lekesi, alg lekesi) ve dört zararlı türünün (yaprak güvesi, çay tripsi, çay yaprak kıvrıcısı, çay sivrisineği) neden olduğu hasarların tespit edilmesi amacıyla Faster R-CNN modelini önermişlerdir. Bu amaçla 1 822 görüntüden oluşturulan veri seti, %80'i eğitim ve %20'si test şeklinde bölünmüştür. Çalışma sonunda Faster R-CNN modeli ile %77.5 kesinlik, %70.6 duyarlılık, %73.91 F1 skoru, %66.02 ortalama kesinlik ve %89.4'lük bir genel doğruluk elde edildiği bildirilmiştir. Ek olarak araştırmacılar eğitilen Faster R-CNN modelinin çay yapraklarındaki hastalık ve zararlı belirtilerinin nedenlerini gerçek zamanlı olarak belirlemede yardımcı olabileceğini vurgulamışlardır.

Kerkech ve ark. (2020) çalışmalarında, bağlarda mildiyö hastalığını drone kullanarak tespit edilmesi amacıyla SegNet modelini önermişlerdir. Araştırmacılar çalışmada insansız hava aracı ile elde ettikleri görüntüleri derin öğrenme segmentasyon yaklaşımı ile birleştirmişlerdir. Çalışmadaki verilerin, iki farklı sensörden elde edilen görünür ve kızılötesi görüntülerin birleştirilmesine dayandığı belirtilmiştir. Çalışmada 17 640 görüntü ile veri seti oluşturulmuştur. Veri seti, %80 eğitim ve %20 test olacak şekilde bölünmüştür. Çalışma sonunda, asmada %92 ve yaprakta %87 doğruluk tespit elde edildiği bildirilmiştir. Önerilen yöntemin bağlarda bilgisayar destekli hastalık tespiti için umut vaat eden perspektifler sunduğu belirtilmiştir.

Lin ve ark. (2020), biber bitkisinde kırımızı örümcek, trips, beyaz sinek zararlılarının oluşturdukları hasarların tespit edilmesi amacıyla yaptıkları çalışmada, Faster R-CNN ve Mask R-CNN modellerini önermişlerdir. Çalışmada 3 sınıf ve 1 239 görüntüden oluşturulan veri seti

%70 eğitim, %15 doğrulama ve %15 test şeklinde bölünmüştür. Çalışmada bir nesne algılama ve segmentasyon karşılaştırması yapılmıştır. Faster R-CNN modelinin hasar belirtilerini tespit etmede, Mask R-CNN modelinden daha iyi performans gösterdiği belirtilmiştir. Çalışma sonunda, Faster R-CNN modeli ile %89 ve Mask R-CNN modeli ile %81 doğruluk edildiği raporlanmıştır.

Mkonyi ve ark. (2020) çalışmalarında, domates bitkisinde domates güvesinin oluşturduğu hasarın tespit edilmesi amacıyla VGG16, VGG19 ve ResNet50 modelleri ile tespit performansı karşılaştırmaları yapmışlardır. Önerilen modellerin, görüntülerden uygun özellikleri çıkarması için veri kümesi ön işleme tabi tutulduğu belirtilmiştir. Çalışmada sağlıklı ve hasarlı domates yaprakları içeren 2 145 görüntüden oluşturulan veri seti eğitim-test; %75-25, %80-20 ve %85-15 gibi farklı şekillerde bölünmüştür. Deneysel sonuçların F1 skoru metriğinde VGG16 modeli için, 0.919, VGG19 modeli için, 0.839 ve ResNet50 modeli için 0.868 bulunduğu bildirilmiştir.

Saleem ve ark. (2020), elma, kiraz, mısır, bağ, turunçgil, şeftali, biber, patates, böğürtlen, fasulye, çilek ve domates bitkilerindeki siyah çürüklük, erken yanıklık, geç yanıklık, mildiyö, bakteriyel leke, yaprak küfü, septoria yaprak lekesi, hedef nokta, mozaik virüsü, yaprak kıvrılması virüsü hastalıkları ile iki noktalı kırmızıörümcek zararlı hasarlarının tespit edilmesi amacıyla yaptıkları çalışmada SSD, R-CNN ve RFCN modellerini önermişlerdir. Çalışmada 54 306 görüntüden oluşan PlantVillage veri seti kullanılmıştır. Veri seti %70 eğitim, %20 doğrulama ve %10 test şeklinde bölünmüştür. Ayrıca çalışmada, farklı optimizasyon algoritmaları kullanılarak performans değerlendirmeleri yapıldığı ve en iyi performansı Adam algoritmasının gösterdiği belirtilmiştir. Çalışma sonunda, en yüksek performansı Adam optimizasyon algoritması ve eğitilen SSD modeli ile %73.07'lik ortalama kesinliklerin ortalaması (mAP) skoru elde edildiği bildirilmiştir.

Xie ve ark. (2020), bağ yapraklarında meydana gelen siyah çürüklük, siyah kızamık ve yaprak yanıklığı hastalıkları ile iki noktalı kırmızıörümcek akarının oluşturduğu hasarın tespit edilmesini amaçladıkları çalışmada 62 286 bağ yaprağı görüntüsü içeren veri seti (UYHV) oluşturulmuştur. Veri seti %60 eğitim, %20 doğrulama ve %20 test şeklinde bölünmüştür. Çalışmada, UYHV ve Faster R-CNN tespit algoritması temel alınarak, Inception-v1 modülü, Inception-ResNet-v2 modülü ve SE-blokları tanıtılarak daha yüksek özellik çıkarma yeteneğine sahip bir derin öğrenme tabanlı Faster DR-IACNN modeli önerilmiştir. Çalışmanın değerlendirme sonucunda %81.1 mAP değeri elde edildiği raporlanmıştır.

Alguliyev ve ark. (2021) çalışmalarında, üzüm, soya fasulyesi, yaban mersini, kiraz, portakal, şeftali, dolmalık biber, patates, ahududu, kabak, elma, çilek ve domates gibi bitkilerde zarar oluşturan bakteriyel leke, erken yanıklık, geç yanıklık, yaprak küfü, isariopsis yaprak lekesi septoria yaprak lekesi, hedef nokta, mozaik virüsü, sarı yaprak kıvrılması virüsü hastalıkları ile iki noktalı kırmızıörümcek akarı hasarlarının tespit edilmesi amacıyla CNN+ GRU, ResNet-20 ve VGGNet-16 modellerini önermişlerdir. Araştırmacılar, CNN modelinin sınıflandırma performansının iyileştirmesi için 3 katmanlı GRU modeli ile birleştirilmesi yapıldığını belirtmişlerdir. Çalışmada, 87 867 görüntüden oluşan PlantVillage veri seti kullanılmıştır. Veri seti, %80 eğitim ve %20 test şeklinde bölünmüştür. Çalışma sonucunda CNN + GRU modeli ile doğruluk %91.19, ResNet-20 modeli ile %85.32 doğruluk, VGGNet-16 modeli ile %88.78 elde edildiği bildirilmiştir.

Altuntaş ve Kocamaz (2021), domates bitkisinde bakteriyel leke, erken yanıklık, geç yanıklık, yaprak küfü, septoria yaprak lekesi, hedef nokta, mozaik virüsü, sarı yaprak kıvrılması virüsü hastalıkları ile iki noktalı kırmızıörümcek akarı hasarlarının tespit edilmesini amaçladıkları çalışmada önceden eğitilmiş yaygın bir derin öğrenme modeli olan AlexNet, GoogLeNet ve ResNet-50 gibi evrişimli sinir ağı (CNN) modelleri, özellik çıkarıcılar olarak kullanmışlardır. Araştırmacılar, 3 CNN modelinden çıkarılan derin özelliklerin birleştirildiği derin öğrenme modeli önermişlerdir. Ayrıca çalışmada elde edilen derin özelliklerin, destek vektör makinesi sınıflandırıcısını eğitmek için kullanıldığı belirtilmiştir. Çalışmada, 18 835 görüntüden oluşan PlantVillage veri seti kullanılmıştır. Veri seti, %80 eğitim ve %20 test olacak şekilde bölünmüştür. Çalışma sonunda %96.99 genel doğruluk elde edildiği bildirilmiştir.

Zhu ve ark. (2021), bağ yapraklarında ortaya çıkan siyah çürüklük hastalığının tespit edilmesi amacıyla gerçekleştirdikleri çalışmada geliştirilen YOLOv3-SPP modelini önermişlerdir. Çalışmada standart YOLOv3 ağına Birleşme Üzerine Kesişim (IOU) yerine, Genelleştirilmiş Birleşme Üzerine Kesişim (GIOU) kullanıldığı belirtilmiştir. Geliştirilen model ağının tespit performansını artırmak için Uzamsal Piramit Havuzlama (SPP) modülü eklendiği bildirilmiştir. Ayrıca geliştirilen modelde, hızlı yakınsama için standart YOLOv3 modelinin önceden eğitilmiş ağırlıkları kullanıldığı belirtilmiştir. Çalışmada 1 180 bağ yaprağı görüntüsünden oluşturulan veri seti, %90 eğitim ve %10 test şeklinde bölünmüştür. Çalışma sonunda %95.79 mAP değeri edildiği raporlanmıştır.

Gutiérrez ve ark. (2021) çalışmalarında, bağ yapraklarında ortaya çıkan mildiyö hastalığı ve iki noktalı kırmızıörümcek zararlısı hasarlarının tespit edilmesi amacıyla geliştirilen CNN

modelini önermişlerdir. Araştırmacılar, gerçek arazi koşullarından elde ettikleri görüntüler üzerinde arka plan kaldırma gibi ön işlemler ve veri artırımı yapıldığını belirtmişlerdir. Çalışmada modelin, HSV ve H gibi farklı renk uzaylarına sahip görüntüler ile eğitildiği bildirilmiştir. Ayrıca çalışmada 841 bağ yaprağı görüntüsünden oluşturulan veri seti, %75 eğitim ve %25 test şeklinde bölünmüştür. Çalışma sonunda, F1 skoru metriği 0.94 elde edildiği bildirilmiştir.

Chen ve ark. (2022) çalışmalarında, kauçuk ağacında antraknoz ve külleme hastalıklarının tespit edilmesi amacıyla geliştirilen YOLOv5 modelini önermişlerdir. Çalışmada 2 375 görüntüden oluşturulan veri seti %40 eğitim, %40 eğitim, %10 doğrulama ve %10 test şeklinde bölünmüştür. Çalışmadaki model gelişiminde ilk olarak, parametre ve hesaplama karmaşıklığının azaltılması için InvolutionBottleneck modülü kullanılmıştır. Araştırmacılar, model gelişiminde ikinci olarak, modelin kanal özelliklerine duyarlılığını artırmak amacıyla bir SE modülünün eklenmiş olduğunu belirtmişlerdir. Çalışmada model üzerinde yapılan son değişikliğin ise kayıp fonksiyonunun güncellenmesiyle gerçekleştirildiği ifade edilmiştir. Çalışma sonunda geliştirilen model ile antraknoz ve külleme hastalıklarının tespitinde kesinlik değerleri sırasıyla %86.5 ve %86.8 elde edildiği bildirilmiştir. Ek olarak, geliştirilen YOLOv5 modelinin, orijinal YOLOv5 ve YOLOX_nano modelleriyle karşılaştırıldığında genel algılama performansının önemli ölçüde daha iyi olduğu raporlanmıştır.

Lu ve ark. (2022), bağlarda besin eksikliği, tüylü küf, kahverengi nokta, külleme hastalıkları ile bağ yaprak uyuzu ve yaprak biti zararlı hasarlarının tespit edilmesini amaçladıkları çalışmada hayalet evrişim ağlarına dayanan Transformer (GeT) modelini önermişlerdir. Çalışmada modelin eğitimi için 12 615 görüntüden oluşturulan GLDP12k veri seti %70 eğitim, %20 doğrulama ve %10 test şeklinde bölünmüştür. Araştırmacılar çalışmada, beş hiper parametrenin analiz edilmesinin ardından geliştirilen GeT modelinin, %4.3 daha yüksek doğruluk sağlayan ImageNet'ten transfer öğrenme yapıldığını belirtmişlerdir. Çalışma sonucunda %98.14 doğruluk elde edildiği bildirilmiştir.

Zhang ve ark. (2022) çalışmalarında, bağ yapraklarında hasar meydana getiren mildiyö hastalığının tespit edilmesi amacıyla geliştirilen YOLOv5 tabanlı YOLOv5-CA modelini önermişlerdir. Araştırmacılar standart YOLOv5 modeli üzerinde yapılan değişiklik olarak, Kanal Dikkat (CA) modülünü eklediklerini belirtmişlerdir. Çalışmada modelin eğitimi için 820 bağ yaprağı görüntüsünden oluşturulan GDM veri seti, %60 eğitim ve %40 test şeklinde

bölünmüştür. Çalışma sonucunda %85.59 kesinlik, %83.70 duyarlılık, ve %89.55 mAP@0.5 değerleri elde edildiği raporlanmıştır.

Adem ve ark. (2022) çalışmalarında, şeker pancarı bitkisinde görülen yaprak lekesi hastalığını tespit edilmesi amacıyla YOLOv4+görüntü işleme hibrit model önermişlerdir. Çalışmada 1 040 görüntüden oluşturulmuş veri seti %70 eğitim ve %30 test şeklinde bölünmüştür. Çalışmada ayrıca YOLOv4+görüntü işleme hibrit modeli Faster R-CNN, SSD ve VGG16 gibi modeller ile performans karşılaştırmaları yapılmıştır. Çalışmadaki önerilen yöntemde görüntü işleme ve derin öğrenme modelinin birleşimiyle elde edilen sonuçların modelin tespit performansını iyileştirdiği belirtilmiştir. Araştırmacılar, en yüksek doğruluk sonucunu YOLOv4+görüntü işleme hibrit modelinde %96.47 olarak elde ettiklerini raporlamışlardır.

Dananjayan ve ark. (2022), narenciye bitkilerinde görülen kömürleşme hastalığı, melanoz ve bakteriyel kahverengi leke yaprak hastalıklarının tespit edilmesi amacıyla yaptıkları çalışmada Res2Net 101 DCN-BiFPN ve YOLOv4 P7 modellerini önermişlerdir. Çalışmada 2 684 görüntüden veri seti oluşturulmuştur. Araştırmacılar, elde ettikleri sonuçlarda YOLOv4 P7 modelinin hastalıkların hızlı ve erken tahminini sağladığını, aynı zamanda Res2Net 101 DCN-BiFPN'li CenterNet2 modelinin diğer yeni ve etkili tespit modellerine göre narenciye yaprağı hastalıklarının erken aşamasını yüksek bir doğrulukla tahmin ettiğini belirtmişlerdir. Çalışma sonuçlarına göre, mAP metriğinde YOLOv4 P7 modelinin 0.893, Res2Net 101 DCN-BiFPN modelinin ise 0.914 elde edildiği raporlanmıştır.

Guo ve ark. (2022) çalışmalarında, bağda külleme, antraknoz, kahverengi leke, kurşuni küf, siyah leke ve mildiyö gibi hastalıklarının tespit edilmesi amacıyla Faster R-CNN, SSD ve Yolox modellerini önermişlerdir. Araştırmacılar çalışmada, önerilen modellerin tespit hassasiyetini artırmak amacıyla Sıkıştırma ve Uyarım Ağı (SE), Verimli Kanal Dikkati (ECA) ve Evrişim Blok Dikkat Modülü (CBAM) mekanizmalarını modellerin içine entegre ettiklerini belirtmişlerdir. Çalışmada modellerin eğitimi için 2 300 görüntüden oluşturulanan veri seti %90'ı eğitim ve %10 doğrulama şeklinden bölünmüştür. Çalışma sonunda Faster R-CNN %79.12, Yolox %83.22 ve SSD %76.23 doğruluk elde edildiği bildirilmiştir.

Wang ve ark. (2022) çalışmalarında, bitki hastalıklarının ve zararlıların tespit edilmesi amacıyla geliştirilen YOLOv5 modelini önermişlerdir. Çalışmada modelin eğitimi ve testi için PlantVillage, PlantDoc, Peanut Brown Spot ve Peanut Rust 10 türde 61 kategoriden oluşan farklı veri setleri birleştirilerek 48 001 görüntüden oluşturulan veri seti %80 eğitim, %10 doğrulama ve %10 test şeklinde bölünmüştür. Araştırmacılar, geliştirilen modelin, orijinal

modele kıyasla eğitim süresi açısından %11.8 ve doğruluk bakımından %3.98 daha iyi performans gösterdiğini belirtmişlerdir. Çalışma sonucunda F1 skor metriğinde orijinal model %90.68, geliştirilen YOLOv5 ise %92.97 elde edildiği raporlanmıştır.

Rashid ve ark. (2023), guava meyvesinde oluşan antraknoz hastalığı, zararlı hasarı, besin eksikliği ve solgunluğun tespit edilmesi amacıyla yaptıkları çalışmada Modifiye edilmiş MobileNetV2 ve U-Net (GIP-MU-NET) modelini önermişlerdir. Araştırmacılar, önerilen modelin bir kodlayıcı olarak modifiye edilen MobileNetv2 modelini ve bir dekode olarak U-Net modelinin katmanlarını içerdiğini belirtmişlerdir. Çalışmada 1 196 görüntüden oluşan Guava Patches Dataset (GPD) veri seti kullanılmıştır. Model eğitimi için veri seti %80 eğitim, %10 doğrulama ve %10 test şeklinde bölünmüştür. Araştırmacılar, MobileNetv2 ve U-Net modelleri birleştirilerek geliştirilen GIP-MU-Net modelinin ortalama olarak %92.41 doğruluk elde ettiğini bildirmişlerdir.

Fenu ve Mallocci (2023) çalışmalarında, armut bitkisinde görülen yaprak lekesi, yaprak kıvrılma hastalıkları ve sülük zararlısı etkilerini tespiti amacıyla EfficientNetB0, InceptionV3 ve MobileNetV2 modellerini önermişlerdir. Araştırmacılar, güçlü bir ağ oluşturmak için birleşik öğrenme paradigmaları incelediklerini belirtmişlerdir. Çalışmada 3 505 görüntüden oluşturulan veri seti %60 eğitim, %20 test ve %20 doğrulama şeklinde bölünmüştür. Araştırmacılar, yaptıkları testler sonucunda EfficientNetB0 ile InceptionV3'ün modellerinin birleşimiyle %91.14, InceptionV3 ile MobileNetV2 modellerinin birleşimiyle %85.35 ve EfficientNetB0 ile MobileNetV2 modellerinin birleşimiyle %86.21 doğruluk elde ettiklerini rapor etmişlerdir.

Mahesh ve Mathew (2023) çalışmalarında, biber bitkisinde bakteriyel leke hastalığını tespit edilmesi amacıyla standart YOLOv3 modelini önermişlerdir. Çalışmada, 6 000 görüntüden oluşan Kaggle veri setini kullanmışlardır. Modelin eğitimi için veri seti %75 eğitim ve %25 test şeklinde bölünmüştür. Araştırmacılar modelin eğitimi için görüntü giriş boyutunu, 416x416 olarak güncellemişlerdir. Çalışma sonunda bakteriyel leke hastalığının tespitinde %90 mAP elde edildiği bildirilmiştir.

Ma ve ark. (2023), mısır bitkisinde mısır pası, gri yaprak lekesi ve yaprak yanığı hastalıklarının tespit edilmesi amacıyla yaptıkları çalışmada geliştirilen YOLOv5n modelini önermişlerdir. Geliştirilen YOLOv5n modeli üzerinde koordinat dikkat mekanizması ve STR (Swin Transformer) tespit başı dahil edildiği belirtilmiştir. Çalışmada 4 353 görüntüden veri seti oluşturulmuştur. Modelin eğitimi için veri seti %60 eğitim, %20 doğrulama ve %20 test şeklinde bölünmüştür. Çalışma sonunda hastalıkların tespiti için %95.2 mAP elde edildiği

raporlanmıştır. Önerilen yöntemin yaygın olarak kullanılan SE, CBAM ve ECA gibi dikkat modülleri ile karşılaştırıldığında, daha yüksek tespit performansı gösterdiği bildirilmiştir.

Xue ve ark. (2023) çalışmalarında, çay bitkisinde yaprak yanıklığı hastalığı ve yeşil mirid böceği zararlı hasarının tespit edilmesi amacıyla geliştirilen YOLOv5 tabanlı YOLO-Tea modelini önermişlerdir. Çalışmada model gelişimi aşamasında ilk olarak, Evrişim Blok Dikkat Modülü (CBAM) YOLOv5 modeline entegre edildiği belirtilmiştir. Araştırmacılar, modelin özellik çıkarma yeteneğini artırmak için yapılan ikinci geliştirmenin ise standart YOLOv5 modelindeki Hızlı Uzamsal Piramit Havuzlama (SPPF) modülünü, Alıcı Alan Bloğu (RFB) modülü ile değiştirerek gerçekleştirdiklerini bildirmişlerdir. Ayrıca araştırmacılar, modeldeki son geliştirmenin küresel bağlam ağı (GCNet) entegre edilerek tamamlandığını belirtmişlerdir. Çalışmada, 3 849 çay bitkisi görüntüsünden veri seti oluşturulmuştur. Veri seti modelin eğitimi için %80 eğitim, %10 doğrulama ve %10 test şeklinde bölünmüştür. Çalışma sonunda, ortalama kesinlik (AP) değerinin %82.6 elde edildiği bildirilmiştir.

Bhandari ve ark. (2023) çalışmalarında, domates bitkisinde bakteriyel leke, erken solgunluk, geç solgunluk, yaprak küfü, mozaik virüsü, Septoria yaprak lekesi, hedef leke ve sarı yaprak kıvrılma virüsü hastalıkları ile iki noktalı kırmızıörümcek akarının oluşturduğu zararın tespit edilmesi amacıyla EfficientNetB5 modelini önermişlerdir. Ayrıca çalışmada, modelin belirli bir sınıfı nasıl tahmin ettiğini görsel olarak açıklamak için gradyan-ağırlıklı sınıf aktivasyon haritalama (GradCAM) ve modelin bir tahmin için hangi özelliklere ve parametrelere dayandığını açıklamak için model-agnostik açıklamalar yöntemleri önerilmiştir. Çalışmada 11 000 görüntüden oluşan PlantVillage veri seti kullanılmıştır. Modelin eğitimi için veri seti %90 eğitim ve %10 test şeklinde bölünmüştür. Çalışma sonunda ortalama eğitim doğruluğunun %99.84, ortalama doğrulama doğruluğunun %98.28 ve ortalama test doğruluğunun %99.07 elde edildiği raporlanmıştır.

Li ve ark. (2023a) çalışmalarında, Çin lahanası bitkisindeki trikomların tespit edilmesi amacıyla geliştirilen YOLOv8 tabanlı TRI-YOLOv8 modelini önermişlerdir. Çalışmada 10 955 görüntü içeren veri seti oluşturulmuştur. Araştırmacılar, geliştirilen modeldeki iyileştirmeler arasında, RepVGG modülünün omurga olarak kullanılması, Boyun'a yeni bir algılama katmanı eklenmesi ve kayıp fonksiyonunun Normalleştirilmiş Gaussian Wasserstein mesafe kaybı ile değiştirilmesi yer aldığını belirtmişlerdir. Ayrıca araştırmacılar yapılan değişikliklerle, modelin küçük trikomlar için algılama performansını etkili bir şekilde geliştirildiğini belirtmişlerdir. Ek olarak araştırmacılar modelin bellek tüketimini azaltmak ve çıkarımı hızlandırmak için hayalet

evriřim kullandıklarını bildirmişlerdir. Çalışma sonunda TRI-YOLOv8 modelin diğerklasik tespit modellerine göre daha iyi performans sergilediğı ve AP50 metriğinde YOLOv8n modele kıyasla %3.8 daha yüksek başarı elde edildiğı belirtilmiştir.

Yang ve ark. (2023a) çalışmalarında, pirinç bitkisinde kın yanıklığı, pirinç patlaması mantarı ve keten lekesi hastalıkların tespit edilmesi amacıyla geliştirilen Tespit Transformatörü (DETR) algoritmasına entegre edilmiş Yoğun Yüksek Seviyeli Kompozisyon Özellik Piramit Ağı (DHLC-FPN) için DHLC-DETR modelini önermişlerdir. Yapılan çalışmalar sonucunda, IDADP veri setinde DHLC-DETR modelinin, veri geliştirme kullanılarak mAP değerinin DETR modeline kıyasla %17.3 artırdığı belirtilmiştir. Ayrıca çalışmada, küçük hedef tespiti için mAP %9.5 oranında iyileştirilmiş ve hiper parametrelerin büyüklüğünün 324.9 M azaltıldığı ifade edilmiştir. Çalışma sonunda genel doğruluğun %97.44 elde edildiğı raporlanmıştır.

Li ve ark. (2023b), kivi ve elma bitkilerinde leke, kahverengi leke, çiçek yaprağı, gri leke, pas, yaprak antraknozu ve yaprak solgunluğu hastalıklarının tespit edilmesi amacıyla yaptıkları çalışmalarında VLDNet modelini önermişlerdir. Bu amaçla, çalışmada 4 180 görüntüden oluşan PlantVillage veri seti kullanılmıştır. Modelin eğitimi için veri seti %70 eğitim, %20 doğrulama ve %10 test şeklinde bölünmüştür. Araştırmacılar çalışmalarında elde ettikleri sonuçlara göre, VLDNet modelinin Swin-Tiny ile eşdeğer performans sergilediğini ve kendi kendine oluşturulmuş ve genel veri kümelerindeki modellere göre gecikme-doğruluk dengesini elde ettiğini belirtmişlerdir. Ayrıca araştırmacılar, VLDNet modelinin 0.097 MB parametre boyutu ve 0.04 G kayan nokta işlemleri (FLOP'lar) ile Swin-Tiny modeline eşit performans gösterdiğini, aynı zamanda parametre boyutunu 297 kat ve FLOP'ları 111 kat azalttığını raporlamışlardır.

Yue ve ark. (2023) çalışmalarında, domates bitkisinde gri küf, göbek çürüklüğü, çatlak, bakteriyel kanser, geç yanıklık ve virüs hastalığı gibi hastalıkların tespit edilmesi amacıyla geliştirilen YOLOv8-Seg modelini önermişlerdir. Bu amaçla çalışmada dört farklı olgunluk aşamasındaki 1600 domates görüntüsünden oluşturulan veri seti %70 eğitim ve %30 test şeklinde bölünmüştür. Araştırmacılar YOLOv8-Seg algoritmasını geliştirirken, özellik füzyon yeteneğini artırmak için C2f modülünü RepBlock modülüyle değiştirerek RepConv tarafından istiflenmiş bir yapı oluşturmuş, özellik füzyon ağına iki üst örneklemeden önce SimConv evriřimini eklediklerini belirtmişlerdir. Ayrıca araştırmacılar, geleneksel evriřimi SimConv ile değiştirerek aktivasyon fonksiyonu olarak SiLU fonksiyonunun yerine ReLU fonksiyonunu

kullandıklarını bildirmişlerdir. Çalışma sonunda, F1 skoru metriği %88.7 elde edildiği raporlanmıştır. Ek olarak araştırmacılar, elde ettikleri sonuçların YOLOv8s-Seg algoritmasının, YOLOv5s-Seg algoritması, YOLOv7-Seg algoritması ve Mask RCNN algoritmasına kıyasla sırasıyla %1.0, %2.8, %0.8 ve %1.1 daha yüksek bir doğruluk elde ettiğini raporlamışlardır.

Yang ve ark. (2023b) çalışmalarında, olgunlaşmamış, olgunlaşmış ve hastalıklı domates meyvelerinin tespit edilmesi amacıyla geliştirilen YOLOv8 modelini önermişlerdir. Bu amaç doğrultusunda çalışmada 3 098 görüntü içeren veri seti oluşturulmuştur. Modelin eğitimi için veri seti %80 eğitim, %10 doğrulama ve %10 test şeklinde bölünmüştür. Araştırmacılar, geliştirilen YOLOv8 modelini, SSD, Faster R-CNN, YOLOv4, YOLOv5 ve YOLOv7 gibi karşılaştırarak önerdikleri modelin performansını kesinlik, duyarlılık oranı ve mAP metrikleri kullanarak değerlendirmişlerdir. Ayrıca araştırmacılar yapılan testler sonucunda, %93.4 mAP skoru elde edildiğini ve önceki YOLO versiyonlarına göre %1.5'lik bir performans artışı, kesinlik değerinde %2'lik ve duyarlılık değerinde %0.8'lik bir artış sağlandığını raporlamışlardır. Ek olarak geliştirilen modelin boyutu 22 M'dan 16 M'a düşürülerek gerçek zamanlı algılama için gereken 138.8 FPS'lik bir algılama hızına ulaştığı da bildirilmiştir.

Zhang ve ark. (2023) çalışmalarında, 102 çeşit tarımsal zararlıının tespit edilmesi amacıyla geliştirilen YOLOv8 tabanlı DCF-YOLOv8 modelini önermişlerdir. Bu amaç doğrultusunda çalışmada, IP102 veri seti kullanılmıştır. Araştırmacılar geliştirilen modelde DenseBlock'u esas alarak C2f modülünü özelleştirmişlerdir. Çalışmada geliştirilen modeldeki değişikliklerle, zararlıların ve hastalıkların kenar dokusu gibi düşük seviyeli özellikleri ayırt edilebilmesi için DCF (DenseBlock temelli C2f) adı verilen bir modül kullanıldığı belirtilmiştir. Çalışma sonunda, geliştirilen model ile mAP %60.8 elde edildiği bildirilmiştir. Ek olarak çalışmada geliştirilen DCF-YOLOv8 modeli ile standart YOLOv8 modeline kıyasla mAP@0.5, kesinlik ve duyarlılık metriklerinde sırasıyla %2, %1.3 ve %3.7 oranlarında iyileşme elde edildiği raporlanmıştır.

Kumar ve ark. (2023) çalışmalarında, pirinç yapraklarında meydana gelen bakteriyel yaprak yanıklığı, pirinç yanıklığı ve kahverengi leke hastalıklarının tespit edilmesi amacıyla YOLOv5 modelini önermişlerdir. Bu amaç doğrultusunda çalışmada Kaggle RLD veri seti kullanılmıştır. Geliştirilen modelin eğitimi için veri seti %75 eğitim ve %25 test şeklinde bölünmüştür. Çalışmada önerilen modelin geliştirilmesinde, DenseNet-201'in ana ağ olarak ve Çift Yönlü Özellik Dikkat Piramit Ağı (Bi-FAPN) kullanıldığı ve bu sayede modelde iyileştirmeler sağladığı belirtilmiştir. Araştırmacılar, elde ettikleri sonuçları %82.8 ortalama doğruluk, %94.87

doğruluk, %75.81 ortalama duyarlılık, 0.71 IoU, 0.017 çıkarım süresi ve %92.45 F1 skoru metrikleri ile raporlamışlardır.


Çalışmalar incelendiğinde; araştırmacıların çeşitli bitki hastalıkları ve zararlıları üzerine yaptıkları çalışmalarda PlantVillage, Kaggle ve PlantDoc gibi hazır veri setlerini sıkça tercih ettiği gözlemlenmiştir. Genellikle Faster R-CNN, Mask R-CNN, YOLOv3, YOLOv5, EfficientNet, VGGNet ve ResNet gibi çeşitli modellerin bitki hastalıkları, zararlılar ve zararlı hasarın tespiti amacıyla tercih edildiği görülmektedir. Çalışmalarda tercih edilen modeller, genellikle kesinlik, duyarlılık, F1 puanı ve mAP gibi metrikler kullanılarak değerlendirilmiştir. Literatürdeki örnek çalışmalarda, kullanılan modellerin çeşitli bitki hastalıkları, zararlılar ve zararlı hasarı %70 ile %98 arasında değişen doğruluk oranlarıyla tespit ettiği raporlanmıştır. Özellikle özelleştirilmiş modeller ve model birleştirmeleri kullanılarak daha yüksek doğruluklar elde edildiği ve bazı durumlarda model boyutu azaltılmasının performansı artırdığı gözlemlenmiştir. Bu tez çalışmasında ise gerçek arazi koşullarından edinilen bağ yaprak ve meyve hasarlarını içeren özgün bir veri seti oluşturulmuştur. Oluşturulan veri seti %70 eğitim, %10 doğrulama ve %20 test şeklinde bölünmüştür. Ayrıca çalışmada modifiye edilerek hafifletilmiş ve hesaplama karmaşıklığı azaltılmış tek aşamalı YOLOv8n tabanlı nesne algılama modeli geliştirilmiştir. Model eğitimlerde mAP@0.5, mAP@0.5:0.95, kesinlik (P), duyarlılık (R) ve F1 skoru performans metrikleri ile değerlendirilmiştir.

3. MATERYAL ve YÖNTEM

3.1. Materyal

3.1.1. Çalışmada değerlendirilen bağ zararlıları

Bağcılık sektöründe önemli ekonomik kayıplara yol açan birçok türde tarımsal zararlı bulunmaktadır. Bu çalışma, en önemli bağ zararlılarından ana zararlı salkım güvesi başta olmak üzere, trips, bağ yaprak uyuzu ve iki noktalı kırmızıörümcek zararlılarının neden olduğu hasarı belirlemeye yönelik olarak gerçekleştirilmiştir. Bu zararlılar bağda; yaprak, meyve, sürgün, tomurcuk ve çiçek gibi aksamalarda hasar oluşturmaktadır. Çalışmada, veri setini oluşturan salkım güvesi, trips yaprak, trips meyve, bağ yaprak uyuzu ve iki noktalı kırmızıörümcek hasar görüntüleri Şekil 18’de verilmiştir.




Şekil 18. Çalışmada incelenen (a) Salkım Güvesi, (b) Trips yaprak, (c) Trips meyve, (d) Bağ yaprak uyuzu ve (e) İki noktalı kırmızıörümcek zararlılarının oluşturduğu hasar örnekleri

3.1.2. Araştırma alanları

Çalışmada değerlendirilen bağ zararlı hasarları görüntülerinin elde edilmesi için Manisa ve Tokat illerindeki bağ alanları araştırılmıştır. Araştırılan bağ alanlarının bulunduğu, Manisa (Şekil 19a), ve Tokat (Şekil 19b), illerine bağlı ilçeleri göstermektedir. Bu ilçelere ait aşağıda sıralanan yerlerden zararlı hasarı görüntüleri alınmıştır.

- Manisa Bağcılık Araştırma Enstitüsü Müdürlüğü Merkez bağ alanları,
- Manisa Bağcılık Araştırma Enstitüsü Müdürlüğü Alaşehir bağ alanları,
- Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bağ alanları,
- Tokat Pazar ilçesi bağ alanları.



Şekil 19. İlçeleri ile araştırma alanları, a) Manisa ve b) Tokat

Şekil 20 ve Şekil 21’de verilerin elde edildiği Manisa Bağcılık Araştırma Enstitüsü Müdürlüğü Merkez bağ alanları ve Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi’ne ait bağ alanları görselleri verilmiştir. İlgili alanlarda veri edinimi döneminde ilaçlama yapılmamış olmasına dikkat edilerek kontrollü şartlarda veriler toplanmıştır.



řekil 20. Manisa Baęcılık Arařtırma Enstit¼s¼ M¼d¼rl¼ę¼ Merkez baę alanları



řekil 21. Tokat Gaziosmanpařa niversitesi Tarımsal Uygulama ve Arařtırma Merkezi
elttek baę alanı

Arařtırma kapsamında veriler sınıflarına ve mevcut oldukları lokasyonlara g¼re farklı tarihlerde edinilmiřtir. Verilerin toplandıęı arařtırma alanlarının, hangi veri sınıfına ait

oldukları ve görüntülerin hangi tarihlerde alındığı ile ilgili bilgiler, Çizelge 2’de ayrıntılı bir şekilde listelenmiştir.

Çizelge 2. Veri setinin elde edilmesi ile ilgili bilgiler

Araştırma alanı	Zararlı	Görüntüleme Tarihi
Tokat	Bağ yaprak uyuzu	6 Haziran 2022
Manisa	Salkım güvesi	2-3 Ağustos 2022 2 Ağustos 2023
Manisa	Trips (Yaprak ve Meyve)	15 Nisan 2022 19 Nisan 2023 10 Mayıs 2023 2 Ağustos 2023
Tokat	İki noktalı kırmızıörümcek	6 Eylül 2023

3.1.3. Çalışmada kullanılan cihazlar

Bağ zararlı hasarlarının görüntülerini elde edebilmek için iPhone XS marka model akıllı telefon kullanılmıştır. Çizelge 3’te kullanılan akıllı telefonun özellikleri verilmiştir.

Çizelge 3. Görüntü edinimi için kullanılan akıllı telefonun teknik özellikleri

Donanım	Teknik Özellik
İşletim Sistemi	IOS
İşlemci Türü	Apple A12 Bionic
İşlemci Hızı	2,5 GHz
İşlemci Çekirdek Sayısı	6
Ekran Çözünürlüğü	2436×1125
Etkin Piksel	12 MP
Video Çözünürlüğü	3 840x2 160
Video Çözünürlüğü	Ultra HD
Video Kare Hızı	60 fps
Sensör Formatı	1/2.55 inç
En Düşük ISO	100
En Yüksek ISO	12 800
Odak Uzaklığı	26 mm

Çalışma boyunca verilerin depolanması, düzenlenmesi, işlenmesi ve model algoritmalarının geliştirilmesi için Çizelge 4’de teknik özellikleri verilen Apple Macbook Air 2020 M1 marka model bilgisayar kullanılmıştır.

Çizelge 4. Çalışmada kullanılan bilgisayarın teknik özellikleri

Donanım	Teknik Özellik
Sistem Üreticisi	Apple
Model	Air 2020-13.3 inç
İşletim Sistemi	MacOS Sonoma
İşlemci (CPU)	Apple M1 Silikon
Ekran Kartı (GPU)	7 çekirdekli GPU
İşlemci Önbelleği	12 MB
Çekirdek Sayısı	8 CPU- 16 Neural Engine
İşlemci Tipi	M1 (8C-7G)
İşlemci Hızı	3.2 GHz
Bellek (RAM)	8 GB- LPDDR4X
Bellek Hızı	3733 Mhz-
SSD Kapasitesi	256 GB

Derin öğrenme işlemleri, büyük miktarda veri üzerinde karmaşık hesaplamalar yapılmasını gerektirdiğinden, bu süreçler için güçlü bir donanıma ihtiyaç duyulmaktadır. Özellikle, yüksek performanslı grafik işleme birimleri (GPU'lar), paralel işleme yetenekleri sayesinde derin öğrenme algoritmalarının hızlı ve verimli bir şekilde çalışmasını sağlamaktadır. Bu çalışmada, Şekil 22'de görseli bulunan sanal Nvidia A100 (40G) grafik kartı kullanılmıştır. Grafik biriminin detaylı teknik özellikleri ise Çizelge 5'te sunulmuştur.



Şekil 22. Çalışmada kullanılan sanal Nvidia A100 (40G) ekran kartı

Çizelge 5. Çalışmada kullanılan sanal grafik işleme biriminin (GPU) teknik özellikleri

Donanım	Teknik Özellikler
Sistem Üreticisi	Nvidia
GPU Belleği	40 gb
GPU Bellek Bant Genişliği	1555 gb/sn
GPU Mimarisi	Ampere
Üretim Hassasiyeti	7 nm
Transistör Sayısı	54 milyar
CUDA Çekirdek Sayısı	6912
Bellek Arabirimi	5120-bit
Sistem Üreticisi	Nvidia
GPU Belleği	40 gb

3.1.4. YOLO (You Only Look Once)

Joseph Redmon ve arkadaşları tarafından CVPR 2016'da yayınlanan YOLO, gerçek zamanlı nesne tespiti için uçtan uca bir yaklaşım sunan ilk sistem olma özelliğine sahiptir. YOLO'nun farklılık gösterdiği en önemli özellik, önceki yöntemlerin genellikle iki aşamalı bir süreci içermesine karşın, YOLO'nun bu görevi tek bir aşamada gerçekleştirmesidir. Genellikle her bir görüntü için yüzlerce veya binlerce kez çalıştırılması gereken kaydırma pencereleri veya ardışık adımlarla çalışan bir sınıflandırıcı yerine tek aşamalı bir yöntemi kullanmıştır. Bu işlem ile regresyona dayalı bir çıkış kullanarak sınıflandırma ve kutu koordinatları tahminini aynı anda gerçekleştirmektedir. Bu yaklaşım, diğer modellere kıyasla daha hızlı ve basit bir nesne tespiti sağlamaktadır (Terven ve ark., 2023).


2016 yılındaki başlangıcından günümüze (2024) kadar, YOLO ailesi hızlı bir şekilde evrim geçirmeye devam etmiştir. Şekil 23, YOLO'nun evrim sürecini göstermektedir.



Şekil 23. YOLO evrim süreci

YOLO (Redmon ve ark., 2015), gerçek zamanlı nesne tespiti için derin öğrenme tabanlı ilk YOLO ağıdır. Şekil 24'de gösterildiği gibi, YOLO nesne algılama sisteminde şu adımlar yer almaktadır:

- İlk adımda, algoritmanın giriş olarak aldığı görüntü, bir $S \times S$ ızgara hücrelerine bölünmektedir.
- Ağ, güven değerlerine dayanarak n adet sınırlayıcı kutu (bounding box) üretmekte ve aynı zamanda her ızgara hücresi için sınıf olasılığı değerlerini hesaplamaktadır.
- Ardından, sınırlayıcı kutu koordinatlarını içeren ızgara hücreleri, son adımda elde edilen olasılık değerleri eşiğinden büyük olanları aramaktadır.
- Nesnenin sınırlayıcı kutu için koordinatlar hesaplanmaktadır.



Şekil 24. YOLO nesne algılama yöntemi (Redmon ve ark., 2016)

YOLO ailesinin en güncel sürümü olan YOLOv8 (Jocher ve ark., 2023), nesnellik, sınıflandırma ve regresyon görevlerini bağımsız olarak işlemek için ayrıştırılmış kafa ağına sahip çapasız (anchor-free) bir model kullanmaktadır (Terven ve Cordova-Esparza, 2023). YOLOv8 ağı; omurga (backbone), boyun (neck) ve kafa (head) ağlarından oluşmaktadır. Omurga ağı, giriş görüntüsünden özellik haritalarını oluşturmak için kullanılmaktadır. YOLOv8, CSPDarknet53 olarak adlandırılan bir omurgayı kullanmaktadır. Bu omurga ağı, Evrişim Katmanı, C2f Katmanı ve Hızlı Uzamsal Piramit Havuzlama (SPPF) Katmanı gibi unsurları barındırmaktadır (Huang ve ark., 2023a). SPPF modülü, özellik haritalarının kapsama alanını artırmak ve çok ölçekli bilgiyi entegre etmek amacıyla uzamsal piramit havuzlamayı seri ve paralel olarak gerçekleştirmektedir. YOLOv8'in temel omurga ağ yapısı, YOLOv5 ile oldukça benzerdir; fakat C3 modülünün yerine C2f modülü entegre edilmiştir (Lou ve ark., 2023). C2f modülü, iki farklı gradyan akışını birleştirerek daha güçlü bir gradyan bilgi akışı

sağlamaktadır (Bai ve ark., 2023). Algılama doğruluğunu artırmak için C2f modülü, yüksek düzeydeki özellikleri bağlamsal bilgilerle birleştirmektedir (Terven ve Cordova-Esparza, 2023). Bu işlem, algılama performansını geliştirme amacıyla gerçekleştirilmektedir. Boyun ağı, çeşitli ölçeklerdeki özellikleri birleştiren bir bölümdür. YOLOv5 ve YOLOv7 modelleriyle karşılaştırıldığında, yol toplama ağı (PAN) yapısını benimseyerek, yukarı örnekleme sonrası evrişim işlemini ortadan kaldırarak orijinal performansı korurken daha hafif bir model elde etme yolunu seçmiştir (Wang ve ark., 2023). Kafa ağı ise her bir başlık için ayrı sınıflandırma, regresyon ve analiz görevleri atanan üç ayrı tespit başlığından oluşmaktadır. Bu yapı, nesne sınıflandırması ve tahmin edilen sınırlayıcı kutu regresyonu için iki ayrı dal kullanmakta ve bu iki görev için farklı kayıp fonksiyonları kullanmaktadır (Terven ve Cordova-Esparza, 2023). Beş farklı modele ayrılan YOLOv8 serisi, ölçekleme parametreleri Çizelge 6'da belirtilmiş olan YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x versiyonlarına sahiptir.

Çizelge 6. YOLOv8 modelleri için ölçekleme parametreleri (Wang ve ark., 2023)

	YOLOv8n	YOLOv8s	YOLOv8m	YOLOv8l	YOLOv8x
Depth_multiple	0,33	0,33	0,67	1,0	1,0
Width_multiple	0,25	0,50	0,75	1,0	1,25
C2f-n (Omurga)	1-2-2-1	1-2-2-1	2-4-4-2	3-6-6-3	3-6-6-3
C2f-n (Boyun)	1-1-1-1	1-1-1-1	2-2-2-2	3-3-3-3	3-3-3-3
Maksimum kanal sayısı	1024	1024	768	512	512


Çalışmada, YOLOv8n model mimarisi temel alınarak model üzerinde omurga, boyun ve kafa ağlarında çeşitli modifikasyonlar yapılarak, parametre sayısının azaltılarak hesaplama karmaşıklığının azaltılması ve mevcut modelin nesne algılama performansı ve verimliliği artırılmaya çalışılarak yeni bir model geliştirilmiştir.

3.1.5. Google Colab (Colaboratory)

Google Colab, Python programlama dili ile makine öğrenimi, veri analizi ve yapay zeka projeleri üzerinde çalışmak isteyen kullanıcılar için tasarlanmış, ücretsiz ve bulut tabanlı bir Jupyter notebook ortamıdır. Bu platform, kullanıcıların çeşitli Python kütüphanelerini (NumPy, Pandas, TensorFlow, PyTorch vb.) kullanarak kod yazmalarını, çalıştırmalarını ve paylaşımlarını kolaylaştırmaktadır. Google Colab, herhangi bir kurulum gerektirmeden,

doğrudan tarayıcı üzerinden erişilebilen bir ortam sunmaktadır. Google'ın sunucularında çalışan bu notebook, yoğun hesaplama gerektiren işlemler için ücretsiz GPU ve TPU kaynakları sağlayarak makine öğrenimi ve derin öğrenme uygulamalarının hızlandırılmasına olanak tanımaktadır. Eğitim, araştırma ve projeler için ideal olan Colab, kullanıcıların bulut tabanlı bir ortamda kod geliştirmelerine, veri analizi yapmalarına, makine öğrenimi ve derin öğrenme yöntemleri ile modelleri oluşturmalarına imkan tanımaktadır. Böylece, kullanıcılar büyük veri setleri ve karmaşık hesaplamalarla çalışırken, kendi bilgisayarlarının kaynaklarından bağımsız olarak Google'ın sağladığı imkanlardan yararlanabilmektedirler (Bisong, 2019). Colab platformunun örnek arayüz görseli Şekil 25'te sunulmaktadır.

Colab üzerinde mevcut grafik birimleri Nvidia T4 (16G), V100 (16G) ve A100 (40G) bulunmaktadır. Bu çalışmada kapsamlı veri setinin işlenmesi ve modellerin eğitimi için Colab çalışma türü donanım konfigürasyonu; 90G yüksek ram, 250G depolama ve A100 grafik kartı kullanılmıştır.



Şekil 25. Google Colab (Colaboratory) Notebook örnek arayüz görseli

3.2. Yöntem

Çalışmada zararlı hasarlarının etkin, hassas ve hızlı bir şekilde tespiti hedeflenmektedir. Belirlenen hedefe ulaşmak amacıyla çalışmada gerçekleştirilen yöntem ve uygulamalar aşağıda sıralanmıştır.

3.2.1. Görüntülerin edinimi

Manisa ve Tokat illerinde asma yetiştiriciliğinin erken ilkbahar ile geç sonbahar dönemleri arasında (Mart-Kasım), zararlı hasarlarıyla ilgili çalışmalar yapılmıştır. Bu süreçte, bağlarda farklı zararlılar tarafından oluşturulan hasar semptomlarını belirlemek için, bitkide meydana gelen hasar durumlarına ve zararlıların gelişme dönemlerine göre görüntüler alınmıştır. Çalışma kapsamında, akıllı telefon kullanılarak 1173 x 1173 piksel çözünürlükte (1:1), 2x optik zoom kullanılarak toplam 5 000 adet görüntü alınmıştır. Bu görüntüler bitkinin hem yaprak hem de salkım kısımlarını içermektedir. Derin öğrenme algoritmasının başarısını ve genelleme yeteneğini artırabilmesi amacıyla, görüntüler farklı doğal aydınlatma koşullarında alınmıştır.

3.2.2. Veri setinin oluşturulması

Vejetasyon süresince elde edilen ham görüntüler, bilgisayara aktarılmış ve sağlıklı ile her bir zararlı hasar için ayrı dosyalarda düzenlenerek saklanmıştır. Çizelge 7'de oluşturulan veri setinin yapısı ve dağılımı gösterilmektedir. Veri seti, toplamda 5 000 görüntü içermekte olup, 7 farklı sınıfa (ID) ayrılmıştır. Sağlıklı sınıf ve trips sınıfı kendi içinde yaprak ve meyve olmak üzere 2'ye bölünmüştür. Literatürde genellikle bitki hastalık, zararlı ve zararlı hasarı tespiti amacıyla yapılan çalışmalarda, veri setleri genellikle 7:3, 7:2:1, 7:1:2 ve 8:2 oranında bölünmektedir. Bu çalışmada da benzer bir yaklaşım izlenerek, veri seti 7:1:2 oranında bölünmüştür. Her bir sınıfta bulunan görüntülerin %70'i eğitimde, %10'u doğrulamada ve %20'si testte kullanılmıştır. Toplam görüntü sayısının 3 500'ü eğitimde, 500'ü doğrulamada kullanılmıştır. Sistem tarafından hiç görülmemiş olan kalan 1 000 görüntü ise test aşamasında kullanılmıştır.

Çizelge 7. Çalışmada oluşturulan veri seti yapısı ve dağılımı

Sınıf (ID)	Sınıf Tanımı	Görüntü sayısı (adet)	Eğitim (%70)	Doğrulama (%10)	Test (%20)
0	Sağlıklı Yaprak	500	350	50	100
1	Sağlıklı Salkım	500	350	50	100
2	Salkım Güvesi	1 000	700	100	200
3	Trips Meyve	500	350	50	100
4	Trips Yaprak	500	350	50	100
5	İki Noktalı Kırmızı Örümcek	1 000	700	100	200
6	Bağ Yaprak Uyuzu	1 000	700	100	200
Toplam		5 000	3 500	500	1 000

3.2.3. Veri ön işleme ve etiketleme

Çalışma, zararlı hasarlarının belirlenmesine odaklandığından, görüntülerdeki nesnelerin örneklerini bulmak için bir nesne algılama algoritmaları kullanılmıştır. Nesne algılama algoritmaları, yüksek bir başarı oranında nesneleri tespit edebilmesi için görüntülerin önce bir ön işleminden geçirilmesini ve özellikle veri setinin doğru bir şekilde etiketlenmesini gerektirmektedir. Bu nedenle, çalışmada veri seti işleme tabi tutulmadan önce, bazı görüntülerdeki ışık yansıması, bulanıklık vb. gürültülerin giderilmesi amacıyla ön işleme uygulanmıştır. Gürültülerin temizlenmesinden sonra, tüm görüntüler model girişi olarak kullanılmak üzere 640x640 çözünürlüğe yeniden boyutlandırılmıştır. Ön işlemler tamamlandıktan sonra, Make Sense etiketleme aracıyla toplam 5 000 görüntü üzerinde etiketleme işlemleri gerçekleştirilmiştir. Bu uygulamada, sınırlayıcı kutu (bounding box) etiketi kullanılmıştır. Son olarak etiketlenen veri seti sıkıştırılmış (.zip) olarak YOLO formatında dışarı aktarılmıştır. Make Sense ile etiketlenen görüntülere ait örnekler Şekil 26 ile Şekil 30 arasında verilmiştir.




Şekil 26. Salkım güvesi hasar etiketi örneği



Şekil 27. Yaprakta trips hasar etiketi örneği



Şekil 28. Meyvede trips hasar etiketi örneği




Şekil 29. Bağ yaprak uyuzu hasar etiketi örneği




Şekil 30. İki noktalı kırmızı örümcek hasar etiketi örneği

Veri setinde etiket doğruluğunu kontrol etmek için Şekil 31’de gösterilen istatistiksel sonuçlar oluşturulmuştur. Burada Şekil 31a oluşturulan veri setindeki etiketlerin sayısını göstermektedir. Bu, modelin eğitiminde, doğrulamasında ve testinde kullanılan etiketlerin çeşitliliği ve dağılımı hakkında bilgi vermektedir. Bağ yaprak uyuzu sınıfı, küçük etiket boyutundan dolayı en çok etiket sayısına sahip sınıftır. Ardından bu etiket sayısını salkım güvesi ve iki noktali kırmızıörümcek sınıfları takip etmektedir. Şekil 31b etiketler için kullanılan sınırlayıcı kutuların büyüklüğünü göstermektedir. En büyük boyutlu etikete sağlıklı yaprak, sağlıklı salkım ve iki noktali kırmızıörümcek sınıfları sahiptir. Şekil 31c veriler üzerindeki etiketlerin normalleştirilmiş konum haritasını göstermektedir. Bu, etiketlerin boyutları baz alınarak görüntüler üzerindeki konumlarının dağılımını ve yoğunluğunu göstermektedir. Son olarak, Şekil 31d ise normalleştirilmiş etiket boyut haritası verilmiştir. Etiketlerin genişlik ve yüksekliğinin baz alındığı bu haritada ise dağılımın doğrusal bir şekilde ilerlediği, genişlik ve yüksekliği düşük olan etiketlerin daha yoğun olduğu görülmektedir.



Şekil 31. Oluşturulan veri seti etiketlerinin istatistiksel sonuçları; a) etiket sayıları, b) etiket boyutları, c) normalleştirilmiş hedef konum haritası ve d) normalleştirilmiş hedef boyut haritası

Veriler üzerindeki etiketlerin doğruluğu başka bir açıdan değerlendirilmiştir. Şekil 32’de oluşturulan korelogram dağılım grafiğinde etiketlerin dağılımı ve korelasyonu gösterilmektedir. Korelasyon, iki değişken arasındaki ilişkinin gücünü ve yönünü ifade etmektedir. Korelasyon katsayısı, -1 ile 1 arasında bir değer almakta ve bu değer ne kadar 0’a yakınsa ilişki o kadar zayıf, ne kadar 1 veya -1’e yakınsa ilişki o kadar güçlü olmaktadır. Pozitif korelasyon, iki değişkenin aynı yönde değiştiğini, negatif korelasyon ise zıt yönde değiştiğini göstermektedir. Histogram ve korelasyon grafiklerine göre etiket konumu (x,y) ve etiket boyutu (width, height) satır ve sütun olarak karşılaştırıldığında belirgin bir benzerlik ile 1’e yakınlık ve pozitif korelasyon olduğunu görülmektedir. Etiket konumu (x,y) ve etiket boyutu (width, height) değişkenleri arttıkça veya azaldıkça diğer değişkenlerde aynı yönde hareket etmektedir. Bu görsel sonuçlar, etiketlerin genellikle orantılı bir şekilde büyüdüğü veya küçüldüğü anlamına gelmektedir. Sunulan grafikler, etiket boyutlarının ve veri üzerindeki konumlarının düzenli bir dağılıma sahip olduğunu ve herhangi bir düzensiz veri içermediğini göstermektedir. Bu, modelin eğitimi için kullanılacak veri setinin kalitesinin yüksek olduğunu ve etiketlerin doğru bir şekilde yerleştirildiğini işaret etmektedir.




Şekil 32. Oluşturulan veri setindeki etiketlerin korelogram dağılım grafikleri

3.2.4. AgDet-YOLO modelinin geliştirilmesi

Modelin geliştirilmesi standart YOLOv8n modelin mimarisi üzerinde yapılan çeşitli modifikasyonlar ile gerçekleştirilmiştir. Geliştirilen model omurga, boyun ve kafa ağları olmak üzere 3 farklı bölümden oluşmaktadır. Bu bölümlerde yapılan değişimler ve eklemeler aşağıda açıklanmıştır.

Omurga Ağı Geliştirilmesi

Omurga ağında ilk adım olarak standart modelin mevcut katmanında (Şekil 33a) bulunan SiLU aktivasyon fonksiyonu ReLU aktivasyon ile değiştirilmiştir. ReLU aktivasyon fonksiyonu derin öğrenme modellerinde düşük eğitim tur sayısında daha iyi performans gösterdiğinden ve genellikle hızlı hesaplama avantajı sağladığından dolayı tercih sebebi olmuştur. Katman, mimaride ReLU + Conv (Şekil 33b) olarak adlandırılmıştır. Bu yapılan değişiklik, ağı parametresi üzerinde herhangi bir değişiklik göstermemiştir. Modelde evrişim katmanları yapısı omurga ağında 3x3'lük bir filtre ve 2'lik bir adım (stride) değeri kullanılmıştır. ReLU + Conv, 64 kanal ile başlayıp; 128, 256, 512 ve 1024 kanala kadar 5 adet olarak omurga ağında bulunmaktadır.




Şekil 33. a) Standart Conv ve b) ReLU + Conv katmanı

Hayalet Evrişim (Ghost Conv) katmanı

Hayalet evrişim katmanı (Han ve ark., 2020), hesaplama maliyetini azaltmak ve modelin hafifletilmesi amacıyla tasarlanmıştır. Şekil 34b'de gösterildiği gibi, hayalet evrişim katmanı

evrişim için özelliklerin yarısını kullanmakta ve ardından bunları orijinal özelliklerle bağlamaktadır. Bu da gereksiz özellikler yaratmayı ve parametre ile hesaplama miktarlarını azaltmaktadır. Temelde, hayalet evrişimi, girdi verilerinin bir kısmını kullanarak daha az sayıda evrişim işlemi gerçekleştirmekte ve ardından bu işlemlerden elde edilen özellik haritalarını çeşitli doğrusal işlemlerle genişleterek tam özellik haritasını oluşturmaktadır. Bu yaklaşım, modelin hızını ve verimliliğini artırırken, performans kaybını en aza indirmeyi amaçlamaktadır. Ancak, omurga ağının ana amacı daha zengin özellikler çıkarmaktır. Standart evrişim katmanlarını doğrudan hayalet evrişim katmanlarıyla değiştirmek, hayalet evrişim katmanlarında yalnızca özelliklerin yarısının kullanılması nedeniyle, kaçınılmaz olarak ağ üzerinde performans düşüşüne yol açmaktadır. Bu nedenden dolayı AgDet-YOLO modelinin omurga ağında hayalet evrişim katmanları SPPF içerisine yerleştirilerek GSPPF bloğu oluşturulmuştur. Ayrıca hayalet evrişim katmanları, boyun ağında bulunan standart evrişim katmanlarının (Şekil 34a) yerini almıştır.




Şekil 34. a) Standart evrişim ve b) hayalet evrişim katmanı

Hayalet Hızlı Uzamsal Piramit Havuzlama (GSPPF) bloğu

İkinci değişiklik ise omurga ağının sonunda SPPF bloğu üzerinde olmuştur. Ağın hesaplama ve parametre miktarını azaltmak için standart modelde kullanılan SPPF bloğu (Şekil 35a) yerine önerilen AgDet-YOLO modelinin içerisinde hayalet evrişim katmanlarının ve ReLU aktivasyon fonksiyonunun dahil edildiği Hayalet Hızlı Uzamsal Piramit Havuzlama (GSPPF)

bloğu (Şekil 35b) yerleştirilmiştir. Hayalet evrişimlerde ReLU aktivasyon fonksiyonu özellik bilgilerinin doğrusal ilişkisini korumak için kullanılmıştır. Standart SPPF bloğu 164 608 parametre sayısına sahipken değiştirilen GSPPF bloğu ile parametre değeri 87 488'e düşürülmüştür. Standart SPPF modülüne göre sadece değişmeyen 5x5'lik havuzlama katmanı olmuştur.




Şekil 35. a) Standart SPPF ve b) GSPPF bloğu

Küresel Dikkat Mekanizması (GAM) modülü

Omurga ağında özellik algılama performansının artması amacıyla yapılan en önemli değişiklik Küresel Dikkat Mekanizması (GAM) modülü (Liu ve ark., 2021) (Şekil 36c) eklenmesi olmuştur. GAM, ağına belirli bir görevi yerine getirirken, önemli özelliklere odaklanmasını sağlaması ve performansın artırılması için tasarlanmıştır. GAM, modelin girdi verileri üzerindeki dikkatini yönlendirerek, önemli bilgileri vurgulamak ve gereksiz bilgileri bastırmak için kullanılmaktadır. Bu sayede, model daha etkili bir şekilde öğrenmekte ve daha doğru sonuçlar üretmektedir. GAM modülü uzamsal dikkat modülü (SAM) ve kanal dikkat modülü (CAM) olmak üzere 2 alt dikkat modülünden meydana gelmektedir. CAM (Şekil 36b), girdi özellik haritasında boyut dönüşümü gerçekleştirmekte ve ardından çok katmanlı algılayıcı (MLP)'ya beslenmektedir. MLP'ye beslenen görüntü orijinal boyutuna geri dönüştürülmektedir. Son olarak sigmoid işleminden geçtikten sonra çıktı üretilmektedir. SAM (Şekil 36a) ise, öncelikle kanal sayısını azaltmak için 7'lik çekirdek boyutuyla evrişim yapmaktadır. Ardından kanal sayısını artırmak için yine 7'lik çekirdek boyutuyla evrişim

işlemi gerçekleştirerek çalışmaktadır. Son aşama olarak sigmoid işleminden sonra çıktı elde edilmektedir. Bu üç dikkat mekanizması, modelin daha hassas ve etkili olmasını sağlayarak, bir sinir ağı modelinin performansını artırmak için birlikte çalışmaktadır.



Şekil 36. a) Uzamsal dikkat alt modülü (SAM), b) kanal dikkat alt modülü (CAM) ve c) küresel dikkat mekanizması (GAM) modülü

Boyun Ağı Geliştirilmesi

Modelin boyun ağında bulunan ve C2f katmanlarından sonra gelen standart evrişim katmanları Şekil 34b’de gösterilen hayalet evrişim katmanları ile değiştirilmiştir. Bu yapılan değişim ile model performansını düşürmeden parametre sayısının azaltılması amaçlanmıştır. Yapılan

katman değişikliği ile ilk standart evrişim katmanı 36 992 parametre sayısından 19 360'e düşürülmüştür. Aynı şekilde ikinci standart evrişim katmanı 147 712 parametre sayısından 75 584'e düşürülmüştür.

Kafa Ağı Geliştirmesi

Kafa ağında standart modelde bulunan 3 ayrı tespit kafa yapısı (P3, P4, P5) değiştirilmeyerek sadece yamll dosya yapısında bağlı olduğu blok ve modül numaraları güncellenmiştir. Bu değişiklik karşılaştırmalı yamll dosyası ekran görselleri olarak Şekil 37'de görülmektedir. AgDet-YOLO modelinin Şekil 37a'da gösterilen yamll dosyasındaki kafa ağı yapısı incelendiğinde "GAM_Attention" modülünün eklenmesiyle blok ve modül numara sıralaması değiştiğinden kafa numara atamaları "[[16, 19, 22], 1, Detect, [nc]]" şeklinde güncellenmiştir. Bu yapılan güncelleme ile kafa ağı 897 664 parametre sayısından 752 677'e düşürülmüştür. Bu işlem ile modelin daha da hafifletilmesi sağlanmıştır.

a	b
<pre># AgDet-YOLO backbone backbone: # [from, repeats, module, args] - [-1, 1, Conv, [64, 3, 2]] # 0-P1/2 - [-1, 1, Conv, [128, 3, 2]] # 1-P2/4 - [-1, 3, C2f, [128, True]] - [-1, 1, Conv, [256, 3, 2]] # 3-P3/8 - [-1, 6, C2f, [256, True]] - [-1, 1, Conv, [512, 3, 2]] # 5-P4/16 - [-1, 6, C2f, [512, True]] - [-1, 1, Conv, [1024, 3, 2]] # 7-P5/32 - [-1, 3, C2f, [1024, True]] - [-1, 3, GAM_Attention, [1024]] - [-1, 1, GSPPF, [1024, 5]] # 9 # AgDet-YOLO head head: - [-1, 1, nn.Upsample, [None, 2, 'nearest']] - [[-1, 6], 1, Concat, [1]] # cat backbone P4 - [-1, 3, C2f, [512]] # 12 - [-1, 1, nn.Upsample, [None, 2, 'nearest']] - [[-1, 4], 1, Concat, [1]] # cat backbone P3 - [-1, 3, C2f, [256]] # 15 (P3/8-small) - [-1, 1, GhostConv, [256, 3, 2]] - [[-1, 12], 1, Concat, [1]] # cat head P4 - [-1, 3, C2f, [512]] # 18 (P4/16-medium) - [-1, 1, GhostConv, [512, 3, 2]] - [[-1, 9], 1, Concat, [1]] # cat head P5 - [-1, 3, C2f, [1024]] # 21 (P5/32-large) - [[16, 19, 22], 1, Detect, [nc]] # Detect(P3, P4, P5)</pre>	<pre># YOLOv8.0n backbone backbone: # [from, repeats, module, args] - [-1, 1, Conv, [64, 3, 2]] # 0-P1/2 - [-1, 1, Conv, [128, 3, 2]] # 1-P2/4 - [-1, 3, C2f, [128, True]] - [-1, 1, Conv, [256, 3, 2]] # 3-P3/8 - [-1, 6, C2f, [256, True]] - [-1, 1, Conv, [512, 3, 2]] # 5-P4/16 - [-1, 6, C2f, [512, True]] - [-1, 1, Conv, [1024, 3, 2]] # 7-P5/32 - [-1, 3, C2f, [1024, True]] - [-1, 1, SPPF, [1024, 5]] # 9 # YOLOv8.0n head head: - [-1, 1, nn.Upsample, [None, 2, 'nearest']] - [[-1, 6], 1, Concat, [1]] # cat backbone P4 - [-1, 3, C2f, [512]] # 12 - [-1, 1, nn.Upsample, [None, 2, 'nearest']] - [[-1, 4], 1, Concat, [1]] # cat backbone P3 - [-1, 3, C2f, [256]] # 15 (P3/8-small) - [-1, 1, Conv, [256, 3, 2]] - [[-1, 12], 1, Concat, [1]] # cat head P4 - [-1, 3, C2f, [512]] # 18 (P4/16-medium) - [-1, 1, Conv, [512, 3, 2]] - [[-1, 9], 1, Concat, [1]] # cat head P5 - [-1, 3, C2f, [1024]] # 21 (P5/32-large) - [[15, 18, 21], 1, Detect, [nc]] # Detect(P3, P4, P5)</pre>

Şekil 37. a) AgDet-YOLO ve b) YOLOv8n modelin yamll dosya yapıları

Tüm yapılan bu değişiklikler sonucunda ortaya çıkan AgDet-YOLO modelin katman ile blok yapılarının parametre ve kanal sayılarının detaylı olarak verildiği model özeti Şekil 38'de görülmektedir. Burada "from" sütunu, modülün hangi katmandan bilgi aldığını göstermektedir. "n" sütunu, modülün kaç adet olduğunu belirtmektedir. "params" sütunu, her katman/modül için parametre sayısını sayısal olarak göstermektedir. "module" sütunu ise kullanılan modülün

tipini belirtmektedir. Parametre sayısı artan ya da azalan katman ve modüller daha anlaşılabilir olması açısından görsel üzerinde belirtilmiştir. Genel olarak modelin parametre sayısı 3.2 M değerinden 2.9 M değerine düşürülmüştür. Yapılan bu işlemler standart modele göre modelin daha fazla küçültülmesini sağlayarak hesaplama karmaşıklığını azaltmıştır.

	from	n	params	module
0	-1	1	464	ultralytics.nn.modules.conv.Conv
1	-1	1	4672	ultralytics.nn.modules.conv.Conv
2	-1	1	7360	ultralytics.nn.modules.block.C2f
3	-1	1	18560	ultralytics.nn.modules.conv.Conv
4	-1	2	49664	ultralytics.nn.modules.block.C2f
5	-1	1	73984	ultralytics.nn.modules.conv.Conv
6	-1	2	197632	ultralytics.nn.modules.block.C2f
7	-1	1	295424	ultralytics.nn.modules.conv.Conv
8	-1	1	460288	ultralytics.nn.modules.block.C2f
9	-1	1	26628	ultralytics.nn.modules.conv.GAM_Attention
10	-1	1	87488	ultralytics.nn.modules.block.SPPF ↓
11	-1	1	0	torch.nn.modules.upsampling.Upsample
12	[-1, 6]	1	0	ultralytics.nn.modules.conv.Concat
13	-1	1	148224	ultralytics.nn.modules.block.C2f
14	-1	1	0	torch.nn.modules.upsampling.Upsample
15	[-1, 4]	1	0	ultralytics.nn.modules.conv.Concat
16	-1	1	37248	ultralytics.nn.modules.block.C2f
17	-1	1	19360	ultralytics.nn.modules.conv.GhostConv ↓
18	[-1, 12]	1	0	ultralytics.nn.modules.conv.Concat
19	-1	1	156416	ultralytics.nn.modules.block.C2f ↑
20	-1	1	75584	ultralytics.nn.modules.conv.GhostConv ↓
21	[-1, 9]	1	0	ultralytics.nn.modules.conv.Concat
22	-1	1	493056	ultralytics.nn.modules.block.C2f
23	[16, 19, 22]	1	752677	ultralytics.nn.modules.head.Detect ↓
AgDet-YOLO summary: 252 layers, 2904729 parameters, 2904713 gradients, 8.2 GFLOPs				


Şekil 38. Geliştirilen AgDet-YOLO modelinin özeti

Modelin İşleyişi


Standart modelin ve geliştirilen modelin genel mimarileri Şekil 39 ve Şekil 40'da omurga boyun ve kafa kısımlarını içerecek şekilde verilmiştir. AgDet-YOLO modelin mimarisindeki omurga ağında (Şekil 40a), ilk adım olarak modele 640 boyutunda 3 kanallı görüntü verilmektedir. Bu görüntü ardışık iki adet 3x3'lük 64 ve 128 kanallı ReLU evrişim katmanından geçerek 320 boyut 64 kanal ve 160 boyut 128 kanala dönüşerek girdi görüntüsü özellikleri çıkarılmaktadır. Ardından çıkarılan özellikler C2f katmanına geçerek daha ince ve spesifik özellikleri algılamasını sağlayacak ayrıntılı bir özellik çıkarımı gerçekleştirilmektedir. Bu da modelin tespit yeteneğini artırmaya katkı sağlamaktadır. Sonraki işlemde yine ReLU evrişim katmanında 80 boyut ile 256 kanala dönüşerek ve 8 ve 16 adıma (stride) sahip olan 2 adet C2f katmanından daha geçerek burada elde edilen özelliklerin bir kısmı ilk birleştirme katmanına beslenmektedir. Devamında tekrar bir ReLU evrişim katmanında 40 boyut ile 512 kanala dönüşerek ve C2f katmanından geçerek özelliklerin bir kısmı farklı bir birleştirme (concat) katmanına beslendirilmektedir. Bu şekilde tekrar birer adet ReLU evrişim ve C2f

katmanlarından geçmesinin ardından Küresel Dikkat Mekanizması (GAM) modülüne bağlanmaktadır. Bu modüle gelen özelliklerden gereksiz olanların azaltılıp, modelin daha önemli ve istenilen özelliklere odaklanması sağlanmaktadır. GAM modülünde tamamlanan süreçte elde edilen özellikler omurga kısmında son blok olan 32 adımlı GSPPF'e 20 boyut ve 512 kanal olarak aktarılmaktadır. Bu blokta farklı ölçeklerde özellik çıkarımı yapılmaktadır. Maksimum havuzlama işlemlerinin gerçekleştirildiği bu blok derin özellik haritalarından çoklu alıcı alanlarını birleştirerek modelin alıcı alanını önemli ölçüde artırmaktadır.

GSPPF bloğundan gelen özellikler modelin boyun kısmında (Şekil 40b) ilk üst örnekleme (up sample) katmanına gelmektedir. Bu katmanda özellik haritasının çözünürlüğünü artırılarak, daha düşük çözünürlüklü bir özellik haritası daha yüksek çözünürlüklü bir hale getirilmektedir. Bu, modelin daha küçük nesneleri tespit etmesine ve daha detaylı özellikleri yakalamasına yardımcı olmaktadır. Buradan çıkan özellik haritaları birleştirme katmanıyla birleştirilmektedir. Tüm birleştirme katmanlarında bir araya gelen özellik haritaları boyun kısmında bulunan C2f katmanlarından geçerek hayalet evrişim katmanına bağlanmaktadır. Bu bağlantı kısmında C2f katmanından transfer edilen özellik haritalarının bir kısmı kafa ağında (Şekil 40c) bulunan P3 (küçük), P4 (büyük) ve P5 (çok büyük) olan 3 ayrı tespit kafasına aktarılmaktadır. Özellik Piramit Ağı (FPN) yapısını kullanan kafada elde edilen sonuçlar birleştirilerek çıktı elde edilmektedir. Şekil 39 ve 40'da ayrıca değişen blok, katman ve modüllerin karşılaştırmalı görsel şekli mimari içerisinde gösterilmektedir.



Şekil 39. Standart YOLOv8n model mimarisi; a) omurga, b) boyun ve c) kafa



Şekil 40. Geliştirilen AgDet-YOLO model mimarisi; a) omurga, b) boyun ve c) kafa

3.2.5. Model değerlendirme göstergeleri

Bu çalışmanın denemelerinde, modelin sınırlayıcı kutu doğruluğunun değerlendirilmesi için Ortalama Kesinliklerin Ortalaması (mAP), Kesinlik (Precision), Duyarlılık (Recall) ve F1 skor metrikleri kullanılmıştır.

Ortalama Kesinliklerin Ortalaması (mAP- mean Average Precision)

Ortalama Kesinliklerin Ortalaması (mAP), tespit modelinin farklı sınıflar için hesaplanan Ortalama Kesinlik (AP)'lerin ortalamasıdır. mAP metriği aşağıda verilen Eşitlik 3.1'deki gibi hesaplanmaktadır:

$$\text{Ortalama Kesinliklerin Ortalaması (mAP)} = \frac{1}{N} \sum_{i=1}^N \text{AP}_i \quad (3.1)$$

Burada N, toplam sınıf sayısını ifade etmektedir. AP_i , her bir sınıfın hesaplanmış Ortalama Kesinlik (AP) değerini temsil etmektedir. Bu değer nesne tespiti modellerinin farklı kesinlik seviyelerinde, ne kadar etkili olduğunu değerlendirmek için kullanılmaktadır. $\text{mAP}@0.5$ ile $\text{mAP}@0.5:0.95$ metrikleri ise Eşitlik 3.2'deki gibi hesaplanmaktadır:

$$\text{mAP}@0.5:0.95 = \text{ort}(\text{mAP}_i), \quad i = 0.5:0.05:0.95 \quad (3.2)$$

Burada $\text{ort}(\text{mAPi})$, 0.5 ila 0.95 aralığındaki farklı IoU değerlerinde elde edilen mAP değerlerinin ortalamasını ifade etmektedir. Bu, genellikle nesne tespiti modellerinin farklı kesinlik eşiklerindeki performansını anlamak için kullanılmaktadır.

Kesinlik (Precision) ve Duyarlılık (Recall)

Kesinlik, modelin yaptığı pozitif tahminlerin doğruluğunu ölçmek için önemli bir metriktir. Özellikle, modelin gerçek nesneleri yanlış pozitiflerden ne kadar iyi ayırdığını değerlendirmektedir. Temelde kesinlik, modelin doğru pozitif tahminler yapma yeteneğine odaklanmakta ve gerçekten doğru pozitif olan tahminlerin oranını belirtmektedir. Yüksek bir kesinlik skoru, modelin yanlış pozitifleri en aza indirme ve güvenilir pozitif tahminler sunma yeteneğine sahip olduğunu göstermektedir. Kesinlik (Precision) Eşitlik 3.3'teki gibi hesaplanmaktadır:

$$\text{Kesinlik (Precision)} = \frac{TP}{(TP+FP)} \quad (3.3)$$

Burada TP, model tarafından gerçekten pozitif olarak tahmin edilen pozitif örneklerin sayısını ifade etmektedir. FP ise gerçekte negatif olan ancak model tarafından yanlışlıkla pozitif olarak tahmin edilen örneklerin sayısını ifade etmektedir.

Duyarlılık, aynı zamanda kesinlik veya doğru pozitif oranı olarak da bilinen, model performansını değerlendirmede, özellikle de nesne tespiti görevlerinde kullanılan önemli bir metriktir. Duyarlılık, modelin resimdeki tüm ilgili nesneleri yakalama yeteneğini ölçmektedir. Yüksek bir duyarlılık skoru, modelin verideki çoğu ilgili nesneyi etkili bir şekilde tanımladığını göstermektedir. Duyarlılık (Recall), Eşitlik 3.4'teki gibi hesaplanmaktadır.

$$\text{Duyarlılık (Recall)} = \frac{TP}{(TP+FN)} \quad (3.4)$$

Burada FN, gerçekte pozitif olan ancak model tarafından yanlışlıkla negatif olarak tahmin edilen örneklerin sayısını ifade etmektedir.


F1 ve Güven Skoru Eşiği

F1 Skoru (F1 Score), modelin kesinlik (precision) ve duyarlılık (recall) değerlerinin harmonik ortalamasıdır. Bu metrik, modelin performansını değerlendirirken hem yanlış pozitifleri hem de yanlış negatifleri dikkate almaktadır. F1 Skoru, modelin doğruluğunu değerlendirmek ve

performansını daha kapsamlı bir şekilde anlamak için kullanılmaktadır. F1 Skor Eşitlik 3.5'teki gibi hesaplanmaktadır.

$$F1 \text{ Skor} = \frac{2 * \text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (3.5)$$


F1 güven skoru eşiği eğrisi (Şekil 41) ise bir sınıflandırma modelinin çeşitli güven eşiği değerlerine göre kesinlik ve duyarlılık değerlerinin nasıl değiştiğini gösteren bir eğridir. Bir modelin çıkışı genellikle bir güven skoru (confidence score) içermekte ve bu skor, modelin tahmin ettiği bir örneğin ne kadar doğru olma olasılığına işaret etmektedir.



Şekil 41. F1 güven skoru eşiği eğrisi

Karışıklık Matrisi (Confusion matrix)


Karışıklık matrisi (Confusion matrix), bir modelin performansının gerçek pozitifler, gerçek negatifler, yanlış pozitifler ve yanlış negatiflerin özetini sunmaktadır. Şekil 42'de belirtildiği gibi pozitif, tespit etmek istediğimiz sınıfı temsil ederken, negatif ise diğer tüm sınıfları ifade etmektedir. Karışıklık matrisi, modelin performansının ayrıntılı bir açıklamasını sağlamaktadır. Kesinlik ve duyarlılık metrikleri ile özellikle dengesiz sınıf sorunlarına ilişkin olarak modelin davranışının nasıl değerlendirileceğinin belirlenmesine yardımcı olabilmektedir. Kısaca karışıklık matrisi, eğitilmiş bir sinir ağının tahmin performansını görselleştirerek, modelin sınıflarının nasıl tahmin ettiğinin daha iyi anlaşılmasına yardımcı olmaktadır.



Şekil 42. Karışıklık matrisi yapısı

Burada TN, model tarafından gerçekten negatif olarak tahmin edilen negatif örneklerin sayısını ifade etmektedir.

Bu aşamaya kadar Şekil 43'te gösterildiği gibi, çalışma veri edinimiyle başlamış ve ön işleme aşamasında etiketlenen veri seti üzerinde çalışılmış ve ardından model geliştirme süreci tamamlanmıştır. Bundan sonraki süreçte geliştirilen model farklı giriş boyutları ve optimizasyon algoritmaları test edilmiştir. Daha sonra, oluşturulan veri seti ile farklı modeller eğitilerek performans karşılaştırmaları yapılmıştır.




Şekil 43. Çalışmanın genel akış şeması

4. BULGULAR ve TARTIŞMA

4.1. Geliştirilen AgDet-YOLO Modelin Sonuçları

Geliştirilen modelin ön testleri bu çalışmadaki verilerden bağımsız olarak sera koşullarında edinilen 800 görüntü kullanılarak yapılmıştır. Domates bitkisindeki domates güvesi (*Tuta Absoluta* Meyrick.) zararlısının oluşturduğu hasarın tespiti için yapılan ön denemede, kesinlik (P) ve duyarlılık (R) metrikleri ile değerlendirilmiş ve sonuçlar Şekil 44’de P-R eğrisi şeklinde sunulmuştur. Model, farklı bir tarımsal veri setinde başarılı sonuçlar gösterdiği için AgDet-YOLO (Agricultural Detector-YOLO) adını almıştır. Bu sonuçlar, modelin tarımsal zararlı hasarı tespit etmede etkili olduğunu ve geniş bir uygulama potansiyeline sahip olabileceğini göstermektedir.




Şekil 44. AgDet-YOLO modelinin farklı veri seti ile eğitim sonuçları

Çalışma sürecinde geliştirilen modelin testleri ve performans karşılaştırmaları için toplam 14 eğitim yapılmıştır. Tüm modellerin eğitimleri için kullanılan standart hiper parametre değerleri Çizelge 8’de verilmiştir.

Çizelge 8. Modellerin standart eğitim hiper parametreleri


Parametre Tanımı	Değer
Eğitim devir sayısı	100
Veri yığının boyutu	8
Momentum	0.9
Öğrenme oranı	0.01

İlk olarak geliştirilen modelin sınırlayıcı kutu performansı sınıf bazında değerlendirilmiştir. Şekil 45 incelendiğinde, “Sağlıklı salkım”, “Sağlıklı yaprak” ve “İki noktalı kırmızı örümcek” sınıflarına ait mAP@0.5, mAP@0.5:0.95, Kesinlik (P) ve Duyarlılık (R) değerlerinin diğer sınıflardan daha yüksek olduğu görülmektedir. Bu sınıf değerini, “Trips meyve” ve “Bağ yaprak uyuzu” sınıfları takip etmektedir. En düşük sınıf performansı ise “Trips yaprak” sınıfı göstermiştir.




Şekil 45. AgDet-YOLO modelinin sınıf bazlı performans sonuçları

Model eğitim sürecinin güvenilirliğinin belirlenmesi için Şekil 46'da gösterildiği gibi, modelin eğitim ve doğrulama aşamalarındaki sınırlayıcı kutu (train/box_loss, val/box_loss) ve sınıf (train/cls_loss, val/cls_loss) kayıp grafikleri verilmiştir. Aynı şekilde model eğitim ve doğrulama sürecinde performans metrikleri mAP@0.5, mAP@0.5:0.95, Kesinlik (P) ve Duyarlılık (R) grafikleri de verilmiştir. Kayıp grafikleri incelendiğinde, eğitim ve doğrulama değerlerinin birbirine yakın olması modelin eğitiminin güvenilirliğini göstermektedir. Benzer biçimde 4 algılama ölçütü (mAP@0.5, mAP@0.5:0.95, Kesinlik (Precision), Duyarlılık (Recall)) çizgilerinin ve eğrilerin birbirine yakın sonuçlar göstermesi, modelin aşırı öğrenme (overfitting) yapmadığını ve yeni verilere iyi uyum sağlayabileceğini göstermektedir. Benzer olarak Kesinlik (P) ve Duyarlılık (R) grafikleri de eğitim ve doğrulama setlerinde benzer şekilde artması da modelin tutarlı ve güvenilir olduğunu işaret etmektedir.




Şekil 46. AgDet-YOLO modelinin performans grafikleri

Şekil 47’de belirtilen F1 güven skoru eşiği eğrisinde tüm sınıfların 0.386'den 0.95 F1 skoruna ulaştığını göstermektedir. Bu sonuç, modelin güven düzeyinde tüm sınıflarda yüksek kesinlik ve duyarlılık sağladığını ortaya koymaktadır. Genel olarak, modelin yüksek güven düzeylerinde bile iyi bir F1 skoru elde ettiği görülmekte ve bu da modelin nesne tespiti görevinde güvenilir olduğunu göstermektedir.



Şekil 47. Eğitim sonucunda oluşan F1 güven skoru eşığı eğrisi

Eğitim sonucunda AgDet-YOLO modelinin her bir sınıfı tespit etme performansını çeşitli kategoriler açısından değerlendirilmesi için, Şekil 48'de gösterilen karışıklık matrisi oluşturulmuştur. Belirtilen sınıfların tespiti için eğitilen AgDet-YOLO modeli, “İki Noktalı Kırmızı Örümcek” sınıfını tanımada en iyi performansı göstermiş ve onu “Trips Meyve”, “Bağ Yaprak Uyuzu”, “Sağlıklı salkım”, “Sağlıklı yaprak” ve “Salkım güvesi” sınıfları takip etmektedir. “Bağ Yaprak Uyuzu” sınıfı ise aynı zamanda arka plan ile en çok karışan sınıf olmuştur. Bu karışıklığın nedeni, en küçük etikete sahip olunmasından kaynaklanmaktadır. En düşük tanıma değeri ise “Trips Yaprak” sınıfına aittir. “Trips Yaprak” sınıfına ait görüntülerdeki hasar belirtileri, diğer sınıflardakilere kıyasla daha az belirgin olduğu için, model bu sınıfı tanımada, daha düşük bir başarı oranına sahip olmuştur.




Şekil 48. AgDet-YOLO modelinin karışıklık matrisi

Eğitim süresi ve GPU kullanımı, modelin farklı giriş boyutlarında A100 GPU ile eğitimi sırasında ölçülmüştür. Çizelge 9, eğitim süresi (dk) ve GPU kullanım (G) değerlerini göstermektedir. Model, 640 giriş boyutunda en yüksek eğitim süresini ve en yüksek GPU bellek kullanımını göstermiştir. Elde edilen sonuçlar, artan giriş boyutlarının hem eğitim süresi hem de GPU bellek kullanımını artırdığı görülmüştür.

Çizelge 9. AgDet-YOLO modelinin farklı giriş görüntüsü boyutlarında oluşturduğu eğitim süresi ve GPU kullanım grafiği.


Giriş Boyutu	Eğitim Süresi (dk)	Nvidia A100 GPU Kullanımı (G)
80x80	61	0.3
160x160	69	0.47
320x320	81	0.81
640x640	94	1.62

Modelin farklı giriş boyutlarıyla oluşturduğu performans sonuçları Şekil 49’da verilmiştir. Sonuçlar değerlendirildiğinde, en yüksek mAP@0.5, mAP0.5:0.95, Kesinlik (P), Duyarlılık (R) ve F1 skor değeri 640 giriş boyutunda elde edilmiştir. Giriş boyutları arttıkça, Kesinlik (P), Duyarlılık (R), mAP@0.5, mAP@0.5:0.95 ve F1 skoru genellikle iyileşmektedir. Bu sonuçlar, daha yüksek çözünürlüğün genel model performansını artırdığını göstermektedir.




Şekil 49. AgDet-YOLO modelinin farklı giriş boyutlarında gösterdiği genel sınıf performans sonuçları

Şekil 50’de gösterildiği gibi geliştirilen model, çeşitli optimizasyon algoritmaları ile de performans değerlendirmeleri yapılmıştır. mAP@0.5, mAP@0.5:0.95, Kesinlik (P), Duyarlılık (R) ve F1 skor değeri 640 giriş boyutunda, her bir optimizasyon algoritmasının performansını farklı açılardan değerlendirmek için kullanılmıştır. SGD, Adam, AdamW, RAdam, NAdam ve Adamax optimizasyon algoritmaları arasında karşılaştırma yapıldığında, AdamW'nin genel performansta en yüksek değerlere sahip olduğu görülmektedir. mAP@0.5, mAP@0.5:0.95, Kesinlik (P), Duyarlılık (R) ve F1 skorlarına göre AdamW, diğer algoritmaların önünde yer almaktadır. RAdam, NAdam ve Adamax da genel olarak iyi bir performans sergilemekle birlikte, bu algoritmaları Adam ve SGD takip etmektedir.



Şekil 50. AgDet-YOLO modelinin farklı optimizasyon algoritmalarıyla gösterdiği genel sınıf performans sonuçları


Şekil 51'deki Kesinlik (P) ve Duyarlilik (R) eğri grafikleri, farklı optimizasyon algoritmalarının performansları karşılaştırılmaktadır. Grafikler incelendiğinde, genel sınıf eğrisinde (lacivert) AdamW, Kesinlik (P) ve Duyarlilik (R) değerlerini en iyi birleştiren ve 1 değerine en yakın sonuçları sunan optimizasyon algoritması olmuştur. Özellikle, “Trips Yaprak” sınıfı eğrisi (pembe), 1 değerine yakınlığıyla AdamW algoritması ile en iyi performansı sergilemiştir. Diğer yandan, Adam optimizasyon algoritması, Kesinlik (P) ve Duyarlilik (R) eğrisinde en düşük performansı göstermiş ve diğer algoritmalarla karşılaştırıldığında 1 değerine daha az yakınlık sergilemiştir.



Şekil 51. AgDet-YOLO modelinin farklı optimizasyon algoritmaları ile P-R grafikleri açısından karşılaştırılması


4.2. Standart YOLOv8n Modeli ile Karşılaştırılması

AgDet-YOLO modeli, YOLOv8 serisinin diğer üyelerine kıyasla daha az parametre içermektedir. Şekil 62’de belirtildiği üzere, YOLOv8 serisinin en büyük modeli olan YOLOv8x, 68.2 milyon parametreye sahipken; serinin en küçük üyesi YOLOv8n ise 3.2 milyon parametre barındırmaktadır. Modifikasyonlar sonucunda geliştirilen AgDet-YOLO modeli, sadece 2.9 milyon parametre ile en hafif model olarak öne çıkmaktadır.



Şekil 52. Geliştirilen AgDet-YOLO modelinin farklı boyutlarda olan standart YOLOv8 modelleriyle parametre sayısı (M) karşılaştırması


AgDet-YOLO modelinin parametre sayısındaki azalma, $mAP@0.5$, Kesinlik (P) ve Duyarlılık (R) metrikleri dikkate alındığında performansını olumsuz etkilememiştir. Şekil 53’te sunulan verilere göre, genel sınıf için YOLOv8n modeli 0.955’lik bir değer elde edilirken, AgDet-YOLO modeli ile daha yüksek bir değer (0.963) elde edilmiştir. Sınıf bazında incelendiğinde, “Trips Yaprak”, “Trips Meyve” ve “Salkım Güvesi” sınıflarında AgDet-YOLO, YOLOv8n’den daha iyi $mAP@0.5$ sonuçlarına ulaşmıştır. “İki Noktalı Kırmızıörümcek”, “Sağlıklı Salkım” ve “Sağlıklı Yaprak” sınıflarında ise, her iki model benzer sonuçlar sergilemiştir. Yalnızca “Bağ Yaprak Uyuzu” sınıfında YOLOv8n, 0.7’lik bir $mAP@0.5$ farkıyla AgDet-YOLO’dan daha iyi performans göstermiştir. Genel sınıf için Kesinlik (P) ve Duyarlılık (R) eğrisinin (lacivert) altında kalan alanın genişliği, AgDet-YOLO’nun daha başarılı olduğunu gösteren bir diğer faktördür.




Şekil 53. YOLOv8n ve AgDet-YOLO model performans karşılaştırması

Eğitim sonrasında her iki model de test veri seti üzerinde değerlendirilmiş ve tespit örnekleri elde edilmiştir. Şekil 54, sağlıklı verilerin tespitini; Şekil 55 ise zararlı hasarı tespitlerini göstermektedir. İncelemeler sonucunda, AgDet-YOLO modelinin sınırlayıcı kutu tespitinde standart modele göre daha iyi performans sergilediği görülmektedir. Bu sonuçlar, parametre

sayısının azaltılmasının modelin performansını olumsuz etkilemediğini ve hesaplama karmaşıklığını azaltarak algılama performansını iyileştirdiğini gösteren güçlü bir kanıttır.




Şekil 54. YOLOv8n ve AgDet-YOLO modellerinin sağlıklı sınıflara ait tespit örnek görüntüleri



Şekil 55. YOLOv8n ve AgDet-YOLO modellerinin zararlı hasarı sınıflarına ait tespit örnek görüntüleri

4.3. Farklı Tek Aşamalı Nesne Algılama Modeller ile Performans Karşılaştırılması


Oluşturulan veri seti ile geliştirilen model ve farklı tek aşamalı modeller, 640 giriş boyutu, 100 eğitim devir sayısı, 0.01 öğrenme oranı ve 8 veri yığın boyutu gibi hiper parametrelerle eğitilmiştir. Nvidia A100 GPU kullanılarak gerçekleştirilen eğitimlerden elde edilen sonuçlar Şekil 56’da sunulmuştur. MobileNetv2-SSD modeli 0.928 mAP@0.5 ile en düşük performansı sergilerken, YOLOv5n Kesinlik (P) metriğinde, MobileNetv2-SSD ise Duyarlılık (R) metriğinde en düşük değerlere sahip olmuştur. Buna karşın, AgDet-YOLO modeli tüm metriklerde en yüksek performansı göstermiş olması, tarımsal alanda zararlı hasarının tespiti için diğer modellere göre daha etkili olduğunu kanıtlamıştır. Bu sonuçlar, AgDet-YOLO’nun azaltılmış parametre sayısına rağmen, yüksek doğruluk ve duyarlılık sağladığını göstermektedir.



Şekil 56. AgDet-YOLO modelinin önceki YOLO modelleri ve farklı algoritmaya sahip model ile performans karşılaştırılması

Şekil 57’de verilen sonuçlar Kesinlik (P) ve Duyarlılık (R) eğri grafikleri açısından değerlendirildiğinde, genel sınıf eğrisinde (lacivert) AgDet-YOLO, 1 değerine en yakın sonuçları sunan model olmuştur. Özellikle, “Trips Yaprak” sınıfı eğrisinin (pembe) altında kalan alanın büyüklüğü bakımından AgDet-YOLO en iyi performansı sergilemiştir. Buna karşın, MobileNetv2-SSD modeli, diğer modellere kıyaslandığında en düşük performansı

göstermiş ve Kesinlik (P) ve Duyarlılık (R) eğrilerinde 1 değerine daha az yakınlık elde etmiştir.



Şekil 57. AgDet-YOLO modelinin farklı modeller ile P-R grafikleri açısından performans karşılaştırması

AgDet-YOLO modelinin performansı, bağ alanlarındaki zararlıların neden olduğu hasarın tespiti bağlamında, literatürde mevcut geliştirilen bazı YOLO tabanlı derin öğrenme modelleriyle değerlendirilmiştir (Çizelge 10). Değerlendirmeler $mAP@0.5$, Kesinlik (P) ve Duyarlılık (R) metrikleri ile giriş boyutu ve eğitim devir sayısı hiper parametreleri açısından yapılmıştır. Bu çalışmada geliştirilen AgDet-YOLO modeli, oluşturulan veri seti üzerinde 100 eğitim devri sonucunda 0.963 $mAP@0.5$, 0.960 Kesinlik (P) ve 0.947 Duyarlılık (R)

değerlerine ulaşarak tablodaki tüm geliştirilen modeller arasında en yüksek performansı sergilemiştir. Ayrıca, literatürdeki çalışmalarda derin öğrenme modellerinin genellikle hazır veri setleri ile eğitildiği gözlemlenmektedir. Ancak, bu çalışmada doğal aydınlanma koşullarının mevcut olduğu gerçek arazi şartlarında toplanan özgün verilerle yeni bir veri seti oluşturulması, çalışmanın özgünlüğünü artırmaktadır. Gerçek arazi koşullarında elde edilen veriler, geliştirilen modelin genelleme yeteneğini artırarak gerçek dünya koşullarına daha iyi uyum sağlamasına ve tarımsal problemlerin çözümünde daha doğru sonuçlar sunmasına olanak tanımaktadır.

Çizelge 10. Benzer modellerin kullanıldığı literatür çalışmaları ve karşılaştırmalar

Literatür	Model	Giriş Boyutu	Veri seti	Eğitim devir sayısı	mAP@0.5	P	R
Zhang ve ark., 2023	YOLOv8+CBM+DCF	640x640	IP102	60	0.608	0.53	0.604
Orchi ve ark., 2023	YOLOv8	614x614	PlantDoc	100	0.633	0.628	0.630
Leng ve ark., 2023	CEMLB-YOLO	640x640	NLB	300	0.875	0.934	0.793
Xie ve Sun, 2023	Tea-YOLOv8s	640x640	Oluşturulan veri seti	300	0.882	0.948	0.812
Huang ve ark., 2023b	YOLO-EP	960x960	Oluşturulan veri seti	300	0.886	0.824	0.788
Kang ve ark., 2023	YOLOv8+GAN	640x640	IDADP	100	0.910	0.920	0.930
Bu çalışma	AgDet-YOLO	640x640	Oluşturulan veri seti	100	0.963	0.960	0.947

5. SONUÇ ve ÖNERİLER

Bağ alanlarında salkım güvesi, bağ yaprak uyuzu, trips ve iki noktalı kırmızıörümcek zararlılarının yapraklar ve meyveler üzerinde neden olduğu hasarların derin öğrenme yöntemleri ile tespit edilmesi amacıyla yapılan bu çalışmada elde edilen bulgular şu şekildedir:

1. Modellerin eğitilmesi amacıyla gerçek arazi koşullarından (farklı aydınlanma, gölgeler ve karmaşık arka planlar) edinilen veriler ile orijinal bir veri seti oluşturulmuştur. Oluşturulan veri seti, 2 sağlıklı ve 5 hasarlı sınıftan meydana gelmektedir. Veri seti için Manisa ilinden 2 000 ve Tokat ilinden 3 000 olmak üzere toplamda 5 000 adet yaprak ve meyve görüntüsü edinilmiştir. Yapılan çalışma ile literatüre yeni bir özgün veri seti eklenmiştir.
2. Çalışmada, YOLOv8n tabanlı tek aşamalı AgDet-YOLO isimli nesne algılama modeli geliştirilmiştir. Modelin omurga ağında standart evrişim katmanlarında kullanılan SiLU aktivasyon fonksiyonu ReLU aktivasyon fonksiyonu ile değiştirilmiştir. Ayrıca omurgada SPPF bloğu yerine hayalet evrişim katmanını içeren GSPPF bloğu kullanılmıştır. Omurga ağındaki değişimlere ek olarak GAM modülü eklenmiştir. Modelin boyun ağında ise standart evrişim katmanları hayalet evrişim katmanlarıyla değiştirilmiştir. Son olarak modelin kafa ağında bağlı oldukları blok numaraları güncellenmiştir. Modelin ağlarında yapılan bu değişiklikler ile toplam parametre sayısı 3.2M'dan 2.9M'a düşürülmüştür. Bu sayede modelin daha da hafifletilmesi sağlanmış ve hesaplama karmaşıklığı azaltılmıştır.
3. Geliştirilen model, 80, 160, 320 ve 640 giriş boyutlarıyla eğitilmiş ve test edilmiştir. Elde edilen sonuçlarda model, en iyi performansını 640 giriş boyutunda göstermiştir. Ayrıca en yüksek GPU kullanımını da 640 giriş boyutunda göstermiştir. En düşük performansı ise model, 80 giriş boyutunda göstermiştir.
4. Ayrıca geliştirilen model SGD, Adam, AdamW, RAdam, NAdam ve Adamax optimizasyon algoritmaları ile eğitilmiş ve test edilmiştir. Model en iyi performansını AdamW algoritmasında sergilemiştir.
5. Son olarak geliştirilen model, YOLOv5n, YOLOv8n ve MobileNetv2-SSD gibi tek aşamalı nesne algılama modelleri ile performans değerlendirmeleri yapılmıştır. Değerlendirme sonucunda, standart YOLOv8n modeli de dahil olmak üzere yapılan karşılaştırmada, geliştirilen model mAP@0.5, hassasiyet (P) ve duyarlılık (R) metriklerinde sırasıyla 0.963, 0.960 ve 0.947 değerleriyle en yüksek performansı göstermiştir.

Önerilen yöntem, geliştirilen modelin bağlardaki zararlı hasarları başarıyla tespit edebilme yeteneğini göstererek, tarımsal mücadelede kullanılabilir bir araç olarak önemli bir potansiyel sunduğunu ortaya koymaktadır. Ayrıca, çalışmada geliştirilen hafifletilmiş modelin sınırlı kaynaklara sahip olan gömülü sistem cihazlar için gerçek zamanlı uygulamalarda daha az işlemci gücü ve bellek kullanımıyla etkin bir şekilde çalışmasını sağlamaktadır. Bu durum, tarımsal alandaki mobil uygulamalarda gerçek zamanlı veri analizinin ve karar alma süreçlerinin iyileştirilmesine katkı sağlayabilir. Bu da gömülü sistemlerin yoğun bir şekilde kullanıldığı otonom robotlar ve dronlar gibi araçların gelişimine katkı sağlayabilir. Otonom robot ve drone gibi araçlar sayesinde tarımsal alanlarda hastalık ve zararlıların erken tespiti gerçekleştirilebilir. Bu durum çiftçiler için otomatik tespit sistemlerinin geliştirilmesiyle zamanında müdahale fırsatı sunarak verim kayıplarını minimize etme olanağı sağlar. Ekonomik açıdan ise bu tür otomatik tespit sistemleri sayesinde daha az insektisit kullanımı sağlanması ile girdi maliyetleri düşürülüp, verimli ve kaliteli üretimle tarım ürünlerinin fiyatlarının arttığı günümüz koşullarında ülke ekonomisine önemli katkılar sağlanabilir.

6. KAYNAKLAR

- Adem, K., 2018. Exudate detection for diabetic retinopathy with circular hough transformation and convolutional neural networks. *Expert Systems with Applications*, (114):289-295.
- Adem, K. ve Közkurt, C., 2019. Defect detection of seals in multilayer aseptic packages using deep learning. *Turkish Journal of Electrical Engineering & Computer Sciences* 27 6, 4220–4230. doi:10.3906/elk-1903-112.
- Adem, K., Ozguven, M.M. ve Altas, Z., 2022. A sugar beet leaf disease classification method based on image processing and deep learning. *Multimedia Tools and Applications* 82 8, 12577–12594. doi:10.1007/s11042-022-13925-6.
- Ahmed, S.F., Alam, Md.S.B., Hassan, M., Rozbu, M.R., Ishtiaq, T., Rafa, N., Mofijur, M., Shawkat Ali, A.B.M. ve Gandomi, A.H., 2023. Deep learning modelling techniques: current progress, applications, advantages, and challenges. *Artificial Intelligence Review* 56 11, 13521–13617. doi:10.1007/s10462-023-10466-8.
- Alguliyev, R., Imamverdiyev, Y., Sukhostat, L. ve Bayramov, R., 2021. Plant disease detection based on a deep model. *Soft Computing* 25 21, 13229–13242. doi:10.1007/s00500-021-06176-4.
- Altuntaş, Y. ve Kocamaz, F., 2021. Deep feature extraction for detection of tomato plant diseases and pests based on leaf images. *Celal Bayar Üniversitesi Fen Bilimleri Dergisi* 17 2, 145–157. doi:10.18466/cbayarfbe.812375.
- Alzubaidi, L., Zhang, J., Humaidi, A.J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M.A., Al-Amidie, M. ve Farhan, L., 2021. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data* 8 1. doi:10.1186/s40537-021-00444-8.
- Anonim, 2011. Bağ entegre mücadele teknik talimatı. Ankara: T.C. Gıda Tarım ve Hayvancılık Bakanlığı.
- Anonim, 2017. Bağ entegre mücadele teknik talimatı. Ankara: T.C. Gıda Tarım ve Hayvancılık Bakanlığı.
- Anonim, 2024a. <https://www.hortiturkey.com/bitki-yetistirciligi/uzum-yetistirciligi>. (Erişim Tarihi: 07.02.2024).
- Anonim, 2024b. <https://stats.stackexchange.com/questions/314123/the-training-accuracy-dropped-over-the-epochs>. (Erişim Tarihi:07.02.2024).
- Aszemi, N.M. ve Dominic, P.D.D., 2019. Hyperparameter optimization in convolutional neural network using genetic algorithms. *International Journal of Advanced Computer Science and Applications* 10 6. doi:10.14569/ijacsa.2019.0100638.
- Avelino, J., Cristancho, M., Georgiou, S., Imbach, P., Aguilar, L. ve Bornemann, G., 2015. The coffee rust crises in Colombia and Central America (2008–2013): Impacts, Plausible Causes and Proposed Solutions. *Food Security*. 7(2):303–21.
- Bai, R., Shen, F., Wang, M., Lu, J. ve Zhang, Z., 2023. Improving detection capabilities of YOLOv8-n for small objects in remote sensing imagery: Towards Better Precision with Simplified Model Complexity. <https://doi.org/10.21203/rs.3.rs-3085871/v1>.
- Bartel, E. ve Bennison, J., 2023. ADAS Horticulture 2023. <https://horticulture.ahdb.org.uk/knowledge-library/spider-mites>. (Erişim Tarihi: 14.10.2023).
- Bhandari, M., Shahi, T.B., Neupane, A. ve Walsh, K.B., 2023. BotanicX-AI: Identification of tomato leaf diseases using an explanation-driven deep-learning model. *Journal of Imaging* 9 2, 53. doi:10.3390/jimaging9020053.
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K. ve Ghayvat, H., 2021. CNN variants for computer vision: History, Architecture, Application, Challenges and Future Scope. *Electronics* 10 20, 2470. doi:10.3390/electronics10202470.

- Bisong, E., 2019. Google Colaboratory. In: Building machine learning and deep learning models on Google Cloud platform. Apress, Berkeley, CA. https://doi.org/10.1007/978-1-4842-4470-8_7.
- Blekos, A., Chatzis, K., Kotaidou, M., Chatzis, T., Solachidis, V., Konstantinidis, D. ve Dimitropoulos, K.A., 2023. Grape dataset for instance segmentation and maturity estimation. *Agronomy*, 13, 1995. <https://doi.org/10.3390/agronomy13081995>.
- Bock, C.H., Poole, G.H., Parker, P.E. ve Gottwald, T.R., 2010. Plant disease severity estimated visually, by digital photography and image analysis and by hyperspectral imaging. *Critical Reviews in Plant Sciences*, 29(2): 59–107. doi:10.1080/07352681003617285.
- Campeato, O., 2020. Artificial intelligence, machine learning, and deep learning. Mercury Learning and Information, 300p, USA.
- Cazaux, M., Navarro, M., Bruinsma, K.A., Zhurov, V., Negrave, T., Van Leeuwen, T., Grbic, V. ve Grbic, M., 2014. Application of Two-spotted Spider Mite *Tetranychus urticae* for plant-pest interaction studies. *Journal of Visualized Experiments* 89. doi:10.3791/51738.
- Chen, Z., Wu, R., Lin, Y., Li, C., Chen, Siyu, Yuan, Z. ve Chen, Shiwei, Zou, X., 2022. Plant disease recognition model based on improved YOLOv5. *Agronomy* 12 2, 365. doi:10.3390/agronomy12020365.
- Clevert, D. A., Unterthiner, T. ve Hochreiter, S., 2016. Fast and accurate deep network learning by Exponential Linear Units (Elus). *Machine Learning*. <https://doi.org/10.48550/arXiv.1511.07289>.
- Çarkacı, N., 2018. “Derin öğrenme uygulamalarında en sık kullanılan hiper-parametreler,” 2018. <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> (Erişim Tarihi: 08.11.2023).
- Dananjayan, S., Tang, Y., Zhuang, J., Hou, C. ve Luo, S., 2022. Assessment of state-of-the-art deep learning based citrus disease detection techniques using annotated optical leaf images. *Computers and Electronics in Agriculture* 193, 106658. doi: 10.1016/j.compag.2021.106658.
- Deng, L. ve Yu, D., 2014. Deep Learning: Methods and applications. *Foundations and Trends in Signal Processing* Vol. 7, Nos. 3–4 (2013) 197–387. DOI: 10.1561/20000000039.
- Dönmez, E., Kılıçarslan, S., Közkurt, C., Diker, A., Demir, F. B. ve Elen, A., 2023. Identification of haploid and diploid maize seeds using hybrid transformer model. *Multimedia Systems*, 29(6), 3833–3845. <https://doi.org/10.1007/s00530-023-01174-y>.
- FAO, 2023. <https://www.fao.org/faostat/en/#data/QCL/visualize>. (Erişim Tarihi: 25.12.2023).
- Fasulo, T.R. ve Denmark, H.A., 2003. “Twospotted Spider Mite, *Tetranychus Urticae* Koch (Arachnida: Acari: Tetranychidae): EENY150/IN307, 8/2000”. *EDIS* 2003 (15). <https://doi.org/10.32473/edis-in307-2000>.
- Fenu, G. ve Mallocci, F.M., 2023. Classification of pear leaf diseases based on ensemble convolutional neural networks. *AgriEngineering* 5 1, 141–152. doi:10.3390/agriengineering5010009.
- Gaspar, A., Oliva, D., Cuevas, E., Zaldívar, D., Pérez, M. ve Pajares, G., 2021. Hyperparameter optimization in a convolutional neural network using metaheuristic algorithms. In: Oliva, D., Houssein, E.H., Hinojosa, S. (eds) *Metaheuristics in Machine Learning: Theory and Applications*. *Studies in Computational Intelligence*, vol 967. Springer, Cham. https://doi.org/10.1007/978-3-030-70542-8_2.
- Goodfellow, I., J., Warde-Farley, D., Mirza, M., Courville, A. ve Bengio, Y., 2013. Maxout networks. *arXiv preprint arXiv:1302.4389*, 2013.
- Guo, W., Feng, Q., Li, X., Yang, S. ve Yang, J., 2022. Grape leaf disease detection based on attention mechanisms. *International Journal of Agricultural and Biological Engineering* 15 5, 205–212. doi: 10.25165/j.ijabe.20221505.7548.
- Gutiérrez, S., Hernández, I., Ceballos, S., Barrio, I., Díez-Navajas, A.M. ve Tardaguila, J., 2021. Deep learning for the differentiation of downy mildew and spider mite in grapevine

- under field conditions. *Computers and Electronics in Agriculture* 182, 105991. doi: 10.1016/j.compag.2021.105991.
- Han, K., Wang, Y., Tian, Q., Guo, J., Xu, C. ve Xu, C., 2020. "GhostNet: More features from cheap operations," 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2020, pp. 1577-1586, doi: 10.1109/CVPR42600.2020.00165.
- Huang, Z.J., Li, L.T., Krizek, G.C. ve Sun, L.H., 2023a. Research on traffic sign detection based on improved YOLOv8. *Journal of Computer and Communications*, 11, 226-232. <https://doi.org/10.4236/jcc.2023.117014>.
- Huang, Y., He, J., Liu, G., Li, D., Hu, R., Hu, X. ve Bian, D., 2023b. YOLO-EP: A detection algorithm to detect eggs of *Pomacea canaliculata* in rice fields. *Ecological Informatics* 77, 102211. doi: 10.1016/j.ecoinf.2023.102211.
- Jadon, S., 2018. Introduction to different activation functions for deep learning. Medium, *Augmenting Humanity*. Vol.16.
- Jocher, G., Chaurasia, A. ve Qiu, J., 2023. YOLO by Ultralytics. GitHub. 1 January 2023. Available online: <https://github.com/ultralytics/ultralytics> (Erişim Tarihi: 17.10.2023).
- Kang, J., Zhao, L., Wang, K. ve Zhang, K., 2023. Research on an improved YOLOv8 image segmentation model for crop pest. *Advances in Computer, Signals and Systems* Clausius Scientific Press, Canada. DOI: 10.23977/acss.2023.070301. ISSN 2371-8838 Vol. 7 Num. 3.
- Karabat, S., 2014. Türkiye ve dünya bağcılığı. <https://arastirma.tarimorman.gov.tr/manisabagcilik/Menu/26/Genel-Bagcilik> (Erişim Tarihi: 07.09.2023).
- Karar, E.M., Alsunaydi, F., Albusaymi, S. ve Alotaibi, S., 2021. A new mobile application of agricultural pests recognition using deep learning in cloud computing system. *Alexandria Engineering Journal*, (2021) 60, 4423–4432.
- Kerkech, M., Hafiane, A. ve Canals, R., 2020. Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach. *Computers and Electronics in Agriculture* 174, 105446. doi: 10.1016/j.compag.2020.105446.
- Kiliçarslan, S., Közkurt, C., Baş, S. ve Elen, A., 2023. Detection and classification of pneumonia using novel Superior Exponential (SupEx) activation function in convolutional neural networks. *Expert Systems with Applications*, 217, 119503. <https://doi.org/10.1016/j.eswa.2023.119503>.
- Közkurt, C., Kiliçarslan, S., Baş, S. ve Elen, A., 2023. α -SechSig and α -TanhSig: Two novel non-monotonic activation functions. *Soft Computing*, 27(24), 18451–18467. <https://doi.org/10.1007/s00500-023-09279-2>.
- Kumar, V.S., Jaganathan, M., Viswanathan, A., Umamaheswari, M. ve Vignesh, J., 2023. Rice leaf disease detection based on bidirectional feature attention pyramid network with YOLO v5 model. *Environmental Research Communications* 5 6, 065014. doi:10.1088/2515-7620/acdece.
- Lee, S., Lin, S. ve Chen, S., 2020. Identification of tea foliar diseases and pest damage under practical field conditions using a convolutional neural network. *Plant Pathology* 69 9, 1731–1739. doi:10.1111/ppa.13251.
- Leng, S., Musha, Y., Yang, Y. ve Feng, G., 2023. CEMLB-YOLO: Efficient detection model of maize leaf blight in complex field environments. *Appl. Sci.*, 13, 9285. <https://doi.org/10.3390/app13169285>.
- Li, X., Chen, J., He, Y., Yang, G., Li, Z., Tao, Y., Li, Yanda, Li, Yu, Huang, L. ve Feng, X., 2023a. High-through counting of Chinese cabbage trichomes based on deep learning and trinocular stereo microscope. *Computers and Electronics in Agriculture* 212, 108134. doi: 10.1016/j.compag.2023.108134.

- Li, X., Zhang, Y., Peng, Y. ve Li, S., 2023b. VLDNet: An ultra-lightweight crop disease identification network. *Agriculture* 13 8, 1482. doi:10.3390/agriculture13081482.
- Lin, T., Chang, H. ve Chen, K., 2020. The pest and disease identification in the growth of sweet peppers using Faster R-CNN and Mask R-CNN. *Journal of Internet Technology*, vol. 21, no. 2, pp. 605-614, Mar. 2020. DOI: 10.3966/160792642020032102027.
- Liu, J. ve Wang, X., 2020. Tomato diseases and pests detection based on improved YOLOv3 convolutional neural network. *Frontiers in Plant Science* 11. doi:10.3389/fpls.2020.00898.
- Liu, Y., Shao, Z. ve Hoffmann, N., 2021. Global Attention Mechanism: Retain information to enhance channel-spatial interactions. *ArXiv*, abs/2112.05561.
- Lou, H., Duan, X., Guo, J., Liu, H., Gu, J., Bi, L. ve Chen, H., 2023. DC-YOLOv8: Small-Size object detection algorithm based on camera sensor. *Electronics* 2023, 12, 2323. <https://doi.org/10.3390/electronics12102323>.
- Lu, X., Yang, R., Zhou, J., Jiao, J., Liu, F., Liu, Y., Su, B. ve Gu, P., 2022. A hybrid model of ghost-convolution enlightened transformer for effective diagnosis of grape leaf disease and pest. *Journal of King Saud University - Computer and Information Sciences* 34 5 , 1755–1767. doi: 10.1016/j.jksuci.2022.03.006.
- Ma, L., Yu, Q., Yu, H. ve Zhang, J., 2023. Maize leaf disease identification based on YOLOv5n algorithm incorporating attention mechanism. *Agronomy* 13 2, 521. doi:10.3390/agronomy13020521.
- Mahesh, T.Y. ve Mathew, M.P., 2023. Detection of bacterial spot disease in bell pepper plant using YOLOv3. *IETE Journal of Research* 1–8. doi:10.1080/03772063.2023.2176367.
- Mkonyi, L., Rubanga, D., Richard, M., Zekeya, N., Sawahiko, S., Maiseli, B. ve Machuve, D., 2020. Early identification of *Tuta absoluta* in tomato plants using deep learning. *Scientific African* 10, e00590. doi: 10.1016/j.sciaf. 2020.e00590.
- Nair, V. ve Hinton, G., E., 2010. Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML10)*, pages 807–814, 2010.
- Orchi, H., Sadik, M., Khaldoun, M. ve Sabir, E., 2023. Real-Time detection of crop leaf diseases using enhanced YOLOv8 algorithm. *International Wireless Communications and Mobile Computing (IWCMC) 2023* | 979-8-3503-3339-8/23/\$31.00 ©2023 IEEE | DOI: 10.1109/IWCMC58020.2023.10182573.
- Ozguven, M.M. ve Adem, K., 2019. Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A*, 535:122537.
- Ozguven, M. M., 2020. Deep learning algorithms for automatic detection and classification of mildew disease in cucumber. *Fresenius Environmental Bulletin*, 29(08/2020), 7081-7087.
- Ozguven, M. M. ve Yanar, Y., 2022. The technology uses in the determination of sugar beet diseases. In: Misra, V., Srivastava, S., Mall, A.K. (eds) *Sugar Beet Cultivation, Management and Processing*. Springer, Singapore. https://doi.org/10.1007/978-981-19-2730-0_30.
- Ozguven, M. M. ve Altas, Z., 2022. A new approach to detect mildew disease on cucumber (*Pseudoperonospora cubensis*) leaves with image processing. *J Plant Pathol*. <https://doi.org/10.1007/s42161-022-01178-z>.
- Ozguven, M.M., 2023. *The digital age in agriculture*. Florida: CRC Press Taylor & Francis Group LLC. ISBN 9781032385808.
- Özgüven, M.M., 2019. Teknoloji kavramları ve farkları. *International Erciyes Agriculture, Animal Food Sciences Conference 24-27 April 2019-Erciyes University-Kayseri/Türkiye*.
- Özgüven, M.M., 2020. Tarımda dijital dönüşüm ve akıllı makineler. *Yeni Türkiye Dergisi*. Tarım Politikaları Özel Sayısı 2. Temmuz- Ağustos 2020, Yıl 26, Sayı 114, s.105-132.

- Philips, H., 2023. A simple introduction to softmax. <https://medium.com/@hunter-j-phillips/a-simple-introduction-to-softmax-287712d69bac>. (Erişim Tarihi: 02.11.2023).
- Ramachandran, P., Zoph, B. ve Le, Q. V., 2017. Searching for activation functions. arXiv preprint arXiv:1710.05941, 2017b.
- Rashid, J., Khan, I., Ali, G., Rehman, S., Alturise, F. ve Alkhalifah, T., 2023. Real-Time multiple guava leaf disease detection from a single leaf using hybrid deep learning technique. *Computers, Materials & Continua* 74 1, 1235–1257. doi:10.32604/cmc.2023.032005.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A., 2015. You Only Look Once: Unified, real-time object detection. *Computer Vision and Pattern Recognition*. <https://doi.org/10.48550/arXiv.1506.02640>.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A., 2016. You Only Look Once: Unified, real-time object detection, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 779–788.
- Ruder, S., 2016. An overview of gradient descent optimization algorithms. *ArXiv*, abs/1609.04747.
- Saleem, M.H., Khanchi, S., Potgieter, J. ve Arif, K.M., 2020. Image-Based plant disease identification by deep learning meta-architectures. *Plants* 9 11, 1451. doi:10.3390/plants9111451.
- Savary, S. ve Willocquet, L., 2014. Simulation modeling in botanical epidemiology and crop loss analysis. *The Plant Health Instructor*. 173 p.
- Semerci, A., Kızıltuğ, T., Çelik, A.D. ve Kiracı, M.A., 2015. Türkiye bağcılığının genel durumu. *Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi*, 20(2):42-51 (2015), Hatay.
- Terven, J., Córdova-Esparza, D.M. ve Romero-González, J.A., 2023. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction* 5 4, 1680–1716. doi:10.3390/make5040083.
- Terven, J. R. ve Cordova-Esparza, D. M., 2023. A comprehensive review of YOLO: from YOLOv1 and Beyond. arXiv:2304.00501v4 [cs.CV] 7 Aug 2023.
- Terzi, İ., Özgüven, M.M., Altaş, Z. ve Uygun T., 2019. Tarımda yapay zeka kullanımı. *International Erciyes Agriculture, Animal Food Sciences Conference 24-27 April 2019- Erciyes University - Kayseri/Turkey*.
- TÜİK, 2023. <https://data.tuik.gov.tr/Kategori/GetKategori?p=tarim-111&dil=1>. (Erişim Tarihi: 25.12.2023).
- Uygun, T., Ozguven, M. M. ve Yanar, D., 2020. A new approach to monitor and assess the damage caused by two-spotted spider mite. *Experimental and Applied Acarology*, 82(3), 335-346. <https://doi.org/10.1007/s10493-020-00561-8>.
- Walia, A.S., 2017. Activation functions and its types-which is better? <https://medium.com/@anishsingh20/activation-functions-and-its-types-which-is-better-a9a5310cc8f>. (Erişim Tarihi: 03.11.2023).
- Wang, Q. ve Qi, F., 2019. Tomato diseases recognition based on Faster RCNN. *IEEE, 10th International Conference on Information Technology in Medicine and Education (ITME)*, 78-1-7281-3918-0. doi: 10.1109/ITME.2019.00176.
- Wang, H., Shang, S., Wang, D., He, X., Feng, K. ve Zhu, H., 2022. Plant disease detection and classification method based on the optimized lightweight YOLOv5 model. *Agriculture* 12 7, 931. doi:10.3390/agriculture12070931.
- Wang, G., Chen, Y., An, P., Hong, H., Hu, J. ve Huang, T., 2023. UAV-YOLOv8: A small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios. *Sensors*, 23, 7190. <https://doi.org/10.3390/s23167190>.

- Wu, Z., Shen, C. ve van den Hengel, A., 2019. Wider or deeper: Revisiting the ResNet model for visual recognition. *Pattern Recognition* 90, 119–133. doi: 10.1016/j.patcog.2019.01.006.
- Wu, J., Wen, C., Chen, H., Ma, Z., Zhang, T., Su, H. ve Yang, C., 2022. DS-DETR: A model for tomato leaf disease segmentation and damage evaluation. *Agronomy*, 12. <https://doi.org/10.3390/agronomy12092023>.
- Xie, X., Ma, Y., Liu, B., He, J., Li, S. ve Wang, H., 2020. A deep-learning-based real-time detector for grape leaf diseases using improved convolutional neural networks. *Frontiers in Plant Science* 11. doi:10.3389/fpls.2020.00751.
- Xie, S. ve Sun, H., 2023. Tea-YOLOv8s: A tea bud detection model based on deep learning and computer vision. *Sensors*, 23, 6576. <https://doi.org/10.3390/s23146576>.
- Xue, Z., Xu, R., Bai, D. ve Lin, H., 2023. YOLO-Tea: A tea disease detection model improved by YOLOv5. *Forests* 14 2, 415. doi:10.3390/f14020415.
- Yang, H., Deng, X., Shen, H., Lei, Q., Zhang, S. ve Liu, N., 2023a. Disease detection and identification of rice leaf based on improved detection transformer. *Agriculture* 13 7, 1361. doi:10.3390/agriculture13071361.
- Yang, G., Wang, J., Nie, Z., Yang, H. ve Yu, S., 2023b. A lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention. *Agronomy* 13 7, 1824. doi:10.3390/agronomy13071824.
- Yılmaz, E.K., Adem, K., Kılıçarslan, S., Aydın, H.A., 2023. Classification of lemon quality using hybrid model based on Stacked AutoEncoder and convolutional neural network. *European Food Research and Technology* 249 6 , 1655–1667. doi:10.1007/s00217-023-04245-6.
- Yu, T. ve Zhu, H., 2020. Hyper-Parameter optimization: A review of algorithms and applications. *Machine Learning*. <https://doi.org/10.48550/arXiv.2003.05689>
- Yue, X., Qi, K., Na, X., Zhang, Y., Liu, Y. ve Liu, C., 2023. Improved YOLOv8-Seg network for instance segmentation of healthy and diseased tomato plants in the growth stage. *Agriculture* 13 8, 1643. doi:10.3390/agriculture13081643.
- Zhang, Z., Qiao, Y., Guo, Y. ve He, D., 2022. Deep learning based automatic grape downy mildew detection. *Frontiers in Plant Science* 13. doi:10.3389/fpls.2022.872107.
- Zhang, L., Ding, G., Li, C. ve Li, D., 2023. DCF-Yolov8: An improved algorithm for aggregating low-level features to detect agricultural pests and diseases. *Agronomy*, 13, 2012. <https://doi.org/10.3390/agronomy13082012>.
- Zhu, J., Cheng, M., Wang, Q., Yuan, H. ve Cai, Z., 2021. Grape leaf black rot detection based on super-resolution image enhancement and deep learning. *Frontiers in Plant Science* 12. doi:10.3389/fpls.2021.695749.

7. ÖZGEÇMİŞ

