



**ÖRTÜ ALTI DOMATES YETİŞTİRİCİLİĞİNDE, BAZI
EKONOMİK ZARARLILARIN YAPAY ZEKA İLE
TESPİTİ**

Yavuz Selim ŞAHİN



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ÖRTÜ ALTI DOMATES YETİŞTİRİCİLİĞİNDE, BAZI EKONOMİK
ZARARLILARIN YAPAY ZEKA İLE TESPİTİ**

Yavuz Selim ŞAHİN
0000-0003-1926-2548

Prof. Dr. Nimet Sema GENÇER
(Danışman)

DOKTORA TEZİ
ENTOMOLOJİ ANABİLİM DALI

BURSA – 2023
Her Hakkı Saklıdır

ÖZET

Doktora Tezi

ÖRTÜ ALTI DOMATES YETİŞTİRİCİLİĞİNDE, BAZI EKONOMİK ZARARLILARIN YAPAY ZEKA İLE TESPİTİ

Yavuz Selim ŞAHİN

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Entomoloji Anabilim Dalı

Danışman: Prof. Dr. Nimet Sema GENÇER

İkinci Danışman: Doç. Dr. Hasan ŞAHİN

Bu tez çalışması, YOLOv8 ve Mask RCNN gibi gelişmiş görüntü işleme modellerinin örtü altı yetiştiriciliği yapılan domates bitkisi üzerindeki bazı ekonomik zararlıların tespitinde ve segmentasyonunda sergilediği üstün performansı araştırmaktadır. Görüntü işleme modellerinin eğitimindeki değerlendirme kriterleri olan Precision, Recall ve mAP incelendiğinde, modellerin zararlı tespitinde büyük bir potansiyele sahip olduğu tespit edilmiştir. Özellikle, YOLOv8 modeli domates üzerindeki zararlıları hızlı ve doğru bir şekilde tespit edebilme kapasitesiyle öne çıkmaktadır, 0,1 saniye gibi kısa bir sürede yaklaşık olarak %90 ve üzerinde bir hassasiyetle zararlı tespiti yapabilmektedir. Üstün performans gösteren, görüntü işlemeye dayalı tespit modellerinin belirlenmesinden sonra, token girdisi kullanan dil modeli GPT-3 ile tespit modeli entegre edilmiştir. Tespit modelinin görüntüler üzerinden algıladığı nesneler token'e dönüştürülerek, API bağlantısı vasıtasıyla GPT-3 modeline girdi olarak prompt içine yerleştirilmiştir. GPT-3'ün YOLOv8 ile entegrasyonu, zararlıların biyolojisi, zarar şekilleri ve mücadele yöntemleri hakkında kapsamlı analizler yapılmasına olanak tanımıştır. GPT-3, 3,5 saniye içerisinde tespit edilen zararlı hakkında benzersiz, orijinal ve yaratıcı çıktılar üretmiştir. GPT-3, zararlıların biyolojisi ve nasıl zarar verdikleri hakkında detaylı bilgi verirken, zararlıları kontrol altına almak için kullanılan biyolojik mücadele gibi alternatif yöntemlere dair bilgilerin daha sınırlı olduğu görülmüştür. Biyolojik mücadele gibi daha spesifik konularda dil modellerinin güçlü ve kapsamlı bilgiler üretebilmesi için, model eğitiminde spesifik, hedef odaklı ve güvenilir kaynakların kullanılması gerektiği öngörülmektedir. Bu çalışma, tarımsal zararlı tespiti ve yönetimi konusunda yapay zekâ ve derin öğrenme teknolojilerinin büyük potansiyel taşıdığını göstermekte ve gelecekteki araştırmalara yönelik olarak çok disiplinli yaklaşımların benimsenmesi, gerçek dünya uygulamalarına odaklanması ve açık kaynak kodlu araçların geliştirilmesi gibi önemli öneriler sunmaktadır.

Anahtar Kelimeler: Domates, *Solanum lycopersicum*, yapay zekâ, YOLO, ChatGPT, zararlı tespiti

2024, xv + 184 sayfa.

ABSTRACT

PhD Thesis

DETECTION OF SOME ECONOMIC PESTS IN GREENHOUSE TOMATO CULTIVATION USING ARTIFICIAL INTELLIGENCE

Yavuz Selim ŞAHİN

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Plant Protection

Supervisor: Prof. Dr. Nimet Sema GENÇER

Co-Supervisor: Assoc. Prof. Dr. Hasan ŞAHİN

This thesis investigates the superior performance of advanced image processing models such as YOLOv8 and Mask RCNN in detecting and segmenting certain economic pests on greenhouse-grown tomato plants. When examining evaluation criteria for training image processing models, such as Precision, Recall, and mAP, it has been determined that these models possess great potential in pest detection. Notably, the YOLOv8 model stands out for its capacity to identify pests on tomatoes quickly and accurately, achieving pest detection with approximately 90% precision in as short a time as 0,1 seconds. Following the identification of image processing detection models that exhibit superior performance, the token-input-based language model GPT-3 has been integrated with the detection model. Objects detected in images by the detection model are converted into tokens and embedded into a prompt as input to the GPT-3 model via API connection. The integration of the GPT-3 language model with the YOLOv8 detection model has enabled comprehensive analyses regarding the biology of pests, their damage types, and control methods. Within 3,5 seconds, GPT-3 has generated unique, original, and creative outputs about the detected pests. While GPT-3 provides detailed information about the biology of pests and how they cause damage, it has been observed that information about alternative control methods, such as biological control, is more limited. For language models to generate strong and comprehensive information on more specific topics like biological control, it is anticipated that specific, target-oriented, and reliable sources need to be used in model training. This study demonstrates the significant potential of artificial intelligence and deep learning technologies in agricultural pest detection and management, offering important recommendations for future research, such as adopting interdisciplinary approaches, focusing on real-world applications, and developing open-source tools.

Key words: Tomato, *Solanum lycopersicum*, artificial intelligence, YOLO, ChatGPT, pest detection

2024, vii + 184 pages.

ÖNSÖZ

Lisans ve lisansüstü eğitimimde beni bilgi ve tecrübeleriyle destekleyen danışmanım Prof. Dr. Nimet Sema GENÇER hocama ve aynı süreçte ikinci danışmanım olarak özellikle yapay zekâ ve makine öğrenmesi konusunda bilgisini ve tecrübesini paylaşan, desteğini esirgemeyen Doç. Dr. Hasan ŞAHİN hocama; Lisans ve lisansüstü eğitimimde fikir ve tecrübeleriyle bana her zaman yardımcı olan Prof. Dr. Barış KOVANCI hocama; Lisans ve lisansüstü eğitimim boyunca bana bilgi ve tecrübesiyle rehberlik eden, maddi ve manevi desteğini esirgemeyen Prof. Dr. İsmail Alper SUSURLUK hocama teşekkür ederim. Tez çalışmalarımda yanımda olan ve desteğini hiçbir zaman esirgemeyen Prof. Dr. Nuray AKBUDAK hocama; Doktora sürecimde fikir alışverişinde bulunup destek olan Doç. Dr. Hilal SUSURLUK hocama minnettarım. Ayrıca, lisans ve lisansüstü eğitimim boyunca her daim destek olan Öğr. Üyesi Tufan Can ULU hocama ve akademik yolculuğumun başlangıcında bana destek olan Büşra SADIÇ ULU'ya teşekkürlerimi sunarım.

Lisansüstü eğitimim sırasında maddi ve manevi desteğini her zaman yanımda hissettiğim dostlarım Muhammet APAK, Abdullah BURHAN ve Ahcen BOUHARİ'ye; akademik çalışmalarımda yardımcı olan Emre DEDE ve Alperen Kaan BÜTÜNER'e; Tez çalışmasında fotoğraflama ve etiketleme süreçlerinde bana destek olan Doğukan AKKANAT ve Emre ÇAKIR'a; eğitim hayatım boyunca maddi manevi desteğini sunan annem Hayriye ŞAHİN'e, kardeşlerim Selma Belkıs ŞAHİN, Semra ŞAHİN ALBAYRAK, Abdulkadir ŞAHİN ve Cengizhan ŞAHİN'e teşekkürlerimi sunarım. Lisans ile lisansüstü eğitim süreçlerimde her türlü desteği ile yanımda olan sevgili eşim Dilara Nur Utaş ŞAHİN'e kalpten teşekkür ederim.

Yavuz Selim ŞAHİN
07/05/2024

İÇİNDEKİLER

Sayfa

ÖZET.....	vi
ABSTRACT.....	vii
ÖNSÖZ.....	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xvi
1. GİRİŞ.....	1
1.1. Domates Yetiştiriciliği: Ekonomik ve Tarımsal Perspektifler	2
1.2. Domates Yetiştiriciliğinde Karşılaşılan Zararlılar ve Tespit Yöntemleri	3
1.3. Yapay Zekâ ve Derin Öğrenme: Temel İlkeler ve Teknikler	6
1.4. Gelişmiş Görüntü İşleme Teknikleri ve Tarımsal Uygulamaları.....	9
1.5. Derin Öğrenme Modellerini Destekleyen Programlama Dilleri	11
1.6. Yapay Zekâ Uygulamalarında Kullanılan Entegre Geliştirme Ortamları.....	11
1.7. Dil Modellerinin Tarımsal Alanında Kullanım Potansiyeli ve Önemi	12
1.8. Yapay Zekâ Uygulamaları için API (Uygulama Programlama Arayüzü) İlkeleri...	15
1.9. Yapay Zekâ ile Zararlı Tespitinin Önemi ve Yenilikleri	15
1.10. Araştırmanın Amacı.....	18
2. KAYNAK ARAŞTIRMASI	20
2.1. Örtü Altı Domates Üretiminde Zararlıların Etkisi	20
2.2. Öne Çıkan Zararlı Türlerinin Tespiti ve Domates Bitkisi Üzerindeki Etkileri.....	22
2.3. Yapay Zekâ ile Zararlı Tespiti ve Kullanılan Yöntemler.....	38
3. MATERYAL VE YÖNTEM	48
3.1. Araştırma Sahasının ve Veri Setinin Tanımlanması	48
3.2. Veri Ön İşleme Teknikleri ve Uygulamaları.....	53
3.3. Model Kurulumu ve Eğitimi	55
3.4. Model Değerlendirme Metodolojisi ve Test Süreci	60
3.5. Dil Modeli ve API Entegrasyonu	63
3.6. Prompt Oluşturma ve Çıktıların Değerlendirilmesi	64
4. BULGULAR VE ANALİZLER	69
4.1. Eğitim (Train) ve Doğrulama (Validation) Kayıp Grafiği.....	70
4.2. Performans Değerlendirme Metrikleri: Recall, Precision, mAP.....	87
4.3. Modellerin Performans Karşılaştırmaları.....	108
4.4. Karmaşıklık (Confusion) Matris Analizi	110
4.6. Dil Modeli Varsayısıyla Elde Edilen Sonuçlar	132
5. TARTIŞMA	152
6. SONUÇ VE ÖNERİLER	160
KAYNAKLAR	162
ÖZGEÇMİŞ.....	184

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler	Açıklama
P	Hassasiyet: Precision
R	Duyarlılık: Recall
mAP	Ortalama hassasiyet
IOU	Birleşim üzerinden kesişim
Kısaltmalar	Açıklama
box_loss	Sınırlayıcı kutu kaybı
cls_loss	Sınırlayıcı sınıf kaybı
dfl_loss	Deformasyon kaybı
YZ	Yapay zekâ
MÖ	Makine öğrenimi
DÖ	Derin öğrenme
HT	Hassas tarım
DL (LM)	Dil modeli
IoT	Nesnelerin interneti
AIoT	Nesnelerin yapay zekâsı
SAM	Segment Anything Model
IDE (EGO)	Entegre gelişim ortamı
CNN	Evrişimli sinir ağları
DETR	DEtection TRansformer
SSD	Single Shot Multibox Detecto
IPM	Entegre zararlı yönetimi
SSPM	Alan özgü zararlı yönetimi
LSTM	Long Short-Term Memory
YOLO	You Only Look Once
GPT-3	Generative Pre-trained Transformer 3
DDİ	Dil işleme
API	Uygulama programlama arayüzleri

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1 Çalışma alanı konumu. A: Çeltikçi – Yenişehir. B: Bakırköy – Karacabey.....	49
Şekil 3.2 Görüntü Etiketleme Yöntemleri: A) Dikdörtgen Belirleme, B) Poligonal Segmentasyon.....	54
Şekil 3.3 OpenAI API Aracılığıyla Tarımsal Zararlılara Dair Bilgi Talebinde Bulunan Kod Parçası.....	64
Şekil 3.4 Tespit ve dil modeli entegrasyonu. Girdi: Domates bitkisine ait arazi fotoğrafları. Çıktı: Tespit ve Dil modeline ait ortak çıktı.....	68
Şekil 4.1 Zararlı Tespiti (Detection) amacıyla eğitilen YOLOv8 Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	72
Şekil 4.2 Zararlı Tespiti (Detection) amacıyla eğitilen EfficientDet (D7) Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	73
Şekil 4.3 Zararlı Tespiti (Detection) amacıyla eğitilen DETR Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	75
Şekil 4.4 Zararlı Tespiti (Detection) amacıyla eğitilen MobileNet SSD v2 Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	76
Şekil 4.5 Zararlı Tespiti (Detection) amacıyla eğitilen Detectron2 Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	78
Şekil 4.6 Zararlı Tespiti (Detection) amacıyla eğitilen GroundingDINO Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	79
Şekil 4.7 Zararlı Tespiti (Detection) amacıyla eğitilen Faster R-CNN Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	81

Şekil 4.8	Zararlı Segmentasyonu (Segmentation) amacıyla eğitilen Mask RCNN Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	83
Şekil 4.9	Zararlı Segmentasyonu (Segmentation) amacıyla eğitilen YOLOv8 Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	85
Şekil 4.10	Zararlı Segmentasyonu (Segmentation) amacıyla eğitilen SAM Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.....	86
Şekil 4.11	Zararlı Tespiti (Detection) amacıyla eğitilen YOLOv8 Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	89
Şekil 4.12	Zararlı Tespiti (Detection) amacıyla eğitilen MobileNet SSD v2 Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	91
Şekil 4.13	Zararlı Tespiti (Detection) amacıyla eğitilen GroundingDINO Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	93
Şekil 4.14	Zararlı Tespiti (Detection) amacıyla eğitilen Faster R-CNN Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	95
Şekil 4.15	Zararlı Tespiti (Detection) amacıyla eğitilen EfficientDet (D7) Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	97
Şekil 4.16	Zararlı Tespiti (Detection) amacıyla eğitilen DETR Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	99
Şekil 4.17	Zararlı Tespiti (Detection) amacıyla eğitilen Detectron2 Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	101

Şekil 4.18	Zararlı segmentasyonu (Segmentation) amacıyla eğitilen Mask RCNN Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	103
Şekil 4.19	Zararlı segmentasyonu amacıyla eğitilen SAM Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	105
Şekil 4.20	Zararlı segmentasyonu amacıyla eğitilen YOLOv8 Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.....	107
Şekil 4.21	Zararlı Tespiti amacıyla eğitilen YOLOv8 Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	112
Şekil 4.22	Zararlı Tespiti amacıyla eğitilen MobileNet SSD v2 Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	114
Şekil 4.23	Zararlı Tespiti amacıyla eğitilen GroundingDINO Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	115
Şekil 4.24	Zararlı Tespiti amacıyla eğitilen Faster R-CNN Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	117
Şekil 4.25	Zararlı Tespiti amacıyla eğitilen EfficientDet (D7) Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	119
Şekil 4.26	Zararlı Tespiti amacıyla eğitilen DETR Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	120
Şekil 4.27	Zararlı Tespiti amacıyla eğitilen Detectron2 Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	122
Şekil 4.28	Zararlı Segmentasyonu amacıyla eğitilen YOLOv8 Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	124
Şekil 4.29	Zararlı Segmentasyonu amacıyla eğitilen Mask R-CNN Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	126
Şekil 4.30	Zararlı Segmentasyonu amacıyla eğitilen Segment Anything Model (SAM) Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.....	127

Şekil 4.31	Karmaşıklık Matrisi verilerine göre, tespit amacıyla eğitilen modellerin domates zararlılarını hatalı (A) ve doğru (B) tahmin oranları için ANOVA Analizi ve Tukey HSD post-hoc Testi Sonuçları.....	129
Şekil 4.32	Karmaşıklık Matrisi verilerine göre, segmentasyon amacıyla eğitilen modellerin domates zararlılarını hatalı (A) ve doğru (B) tahmin oranları için ANOVA Analizi ve Tukey HSD post-hoc Testi Sonuçları.....	131
Şekil 4.33	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile D. baccarum zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	134
Şekil 4.34	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile Toprak Pire Böcekleri ergin zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	135
Şekil 4.35	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile N. viridula ergin zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	136
Şekil 4.36	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile Aphid ergini zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	137
Şekil 4.37	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile B. tabaci ergini zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	138
Şekil 4.38	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile L. decemlineata ergini zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	139
Şekil 4.39	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile T. absoluta ergini zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	140
Şekil 4.40	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile N. viridula nimfi zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	141
Şekil 4.41	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile L. decemlineata larvası zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	142
Şekil 4.42	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile H. armigera larvası zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	143

Şekil 4.43	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile T. absoluta larvası zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	144
Şekil 4.44	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile L. bryoniae zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	146
Şekil 4.45	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile T. absoluta zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	147
Şekil 4.46	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile Thrips zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	148
Şekil 4.47	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile Akar zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	149
Şekil 4.48	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile H. armigera zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	150
Şekil 4.49	Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile T. absoluta zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.....	151

ÇİZELGELER DİZİNİ

Çizelge 2.1	Öne çıkan zararlı türlerin tespiti ve domates bitkisi üzerindeki etkileri kapsamında ele alınan çalışmaların yazarları ve zararlı türleri.....	37
Çizelge 2.2	Yapay zekâ ile tarımda zararlı tespiti kapsamında çalışan araştırmacılar ve kullanılan modeller.....	48
Çizelge 3.1	Tespit modelleri eğitimi için kullanılan zararlılar ve ait oldukları familyalar.....	52
Çizelge 3.2	Segmentasyon modelleri eğitimi için kullanılan görüntüler.....	52
Çizelge 3.3	Model eğitimi için görüntülerden oluşan veri setinin gruplara ayrılması.....	53
Çizelge 3.4	Tespit ve Segmentasyon modelleri için belirlenen etiket isimleri.....	56
Çizelge 3.5	Tez çalışmasına ait olan veri seti üzerinden eğitmek amacıyla tercih edilen modeller.....	58
Çizelge 3.6	Nesne tespiti performansını değerlendirmek için denklemler.....	62
Çizelge 3.7	Hedef odaklı çıktılar için Özelleştirilmiş Prompt Örnekleri.....	67
Çizelge 3.8	Tespit ve Dil Modelinin Entegre Edilme Basamakları.....	69
Çizelge 4.1	Tespit Modellerinin Precision, Recall, mAP50, ve mAP50-95 Değerleri için ANOVA Analizi ve Tukey HSD post-hoc Testi Sonuçları ($F(27, 56) = 100.69$, $p < .0001$).....	111
Çizelge 4.2	Segmentasyon Modellerinin Precision, Recall, mAP50, ve mAP50-95 Değerleri için ANOVA Analizi ve Tukey HSD post-hoc Testi Sonuçları ($F(11, 24) = 112.0377$, $p < .0001$).....	112

1. GİRİŞ

Tarım alanında zararlı kontrolü, küresel ekonomi ve gıda güvenliği üzerinde doğrudan etkiye sahip olduğu için büyük önem arz etmektedir (Barzman vd., 2015). Hassas Tarım uygulamalarında, verim ve kalite kaybına neden olan bitki hastalıkları ve zararlı böceklerin erken tespiti, hasarın yayılmadan önleyici tedbirlerin alınması için kritik bir rol oynamaktadır (Sishodia vd., 2020). Otonom robotik sistemler ve görüntü işleme teknolojilerindeki son yenilikler, insan gözlemine göre daha güvenilir ve hızlı seçenekler sunarak zararlı böcek ve hastalık tespitinde önemli potansiyel sunmaktadır (Ngugi vd., 2021).

Örtü altı domates yetiştiriciliği, tarımsal zararlıların etkisi altında ekonomik açıdan büyük bir risk taşımaktadır. Geleneksel yöntemlerle bu zararlıların tanımlanması ve yönetimi, genellikle insan uzmanlığına dayandırılmıştır; bu da zaman alıcı, hata olasılığı yüksek ve kapsamlı bilgi birikimi gerektiren bir süreçtir. Ancak yapay zekâ (YZ) ve derin öğrenme alanındaki son gelişmelerle bu geleneksel yaklaşımın temelden dönüştürülme potansiyeli ortaya çıkmıştır.

Gelişen teknolojilerin hassas tarım uygulamalarıyla entegrasyonu, tarımsal verimliliği artırırken, zararlılarla mücadele ile ilgili maliyetleri düşürerek dünya genelinde ekonomik faydalar sağlamaktadır (Mulla, 2013). Ayrıca, bu yenilikçi zararlı yönetimi stratejileri, geleneksel kimyasal temelli zararlı kontrol yöntemlerinin çevresel etkilerini azaltarak sürdürülebilir tarımın desteklenmesine katkı sağlamaktadır (Dhawan ve Peshin, 2009). Bu bağlamda yapılan araştırmalar, otonom robotik sistemlerin ve görüntü işleme tekniklerinin kapasitelerini daha da geliştirerek, daha etkin ve hassas zararlı tespiti ve yönetimi imkânı sunmaktadır (Bogue, 2016).

1.1. Domates Yetiřtiricilięi: Ekonomik ve Tarımsal Perspektifler

Solanaceae familyasına ait olan domates (*Solanum lycopersicum* L.) bitkisi global tarım arenasını ierisinde kritik bir yere sahiptir ve ekonomik deęeri, besin ierięi ve gastronomik zellikleri ile dikkat eker. Dnya apında en sık yetiřtirilen sebzeler arasında yer alan domates, tarımsal sistemlerdeki merkezi rolyle bilinir (Acharya vd., 2020). zellikle rt altında gerekleřtirilen domates retimi, aık alandaki geleneksel tarım yntemlerine nazaran pek ok avantaj barındırır. rt altı retim, dıř kaynaklı evresel faktrlere olan baęımlılıęı asgariye indirerek bitkiler iin optimal byme kořullarını sunar. Bu da daha yksek verim ve stn rn kalitesinin elde edilmesine olanak tanımaktadır (Jones, 1992; Akbudak ve Bicen, 2020).

İklim deęiřiklikleri ve artan hava olaylarının neden olduęu risklerden baęımsız bir yetiřtiricilik ortamını saęlaması, rt altı domates retiminin srdrlebilirlięini artırır (Heinz vd., 2004). Ayrıca, arazi kısıtlamaları veya toprak saęlık sorunları olan blgelerde bile tarımsal rn yetiřtiricilięini mmkn kılar. Bu, zellikle toprak erozyonu, tuzluluk gibi toprak kalitesi sorunlarına sahip alanlarda nemlidir (Van Lenteren, 2000). rt altı domates retimi hem srdrlebilir tarımın hem de yksek kaliteli domates yetiřtiricilięinin geleceęini temsil etmektedir. Ayrıca, domatesler sadece taze tketim iin yetiřtirilmez, iřlenmiř domates rnleri iin de nemli bir talep bulunmaktadır (Quinet vd., 2019). Ekonomik olarak, domates endstrisi global tarım ekonomisinde derin bir rol oynamaktadır. Dnya apında, domatesler en yksek deęere sahip meyve/sebze rn olarak ne ıkar ve global retimi 182 milyon tonu ařmaktadır (Hong vd., 2019; Ricupero vd., 2021). Bu geniř aplı yetiřtiricilik, kk lekli iftilere fayda saęlayarak kırsal kalkınmaya ve yoksulluęun azaltılmasına katkıda bulunmuřtur. rneęin, in, Hindistan, Amerika Birleřik Devletleri ve Brezilya gibi lkeler, elveriřli iklimleri ve ileri tarım yntemleri sayesinde domates retiminde ncdr.

Türkiye'nin domates üretim zincirindeki yeri özel bir öneme sahiptir. Bir Akdeniz ülkesi olarak, Avrupa domates tedarik zincirinde kilit bir rol oynamakta ve kıtanın en büyük üreticileri arasında yer almaktadır (Ricupero vd., 2021). Bu öne çıkış, birçok domates çeşidi, elverişli iklim koşulları ve zengin yetiştirme tarihiyle desteklenmektedir. Diğer taraftan domates bitkisinde ekonomik kayıp meydana getiren birçok hastalık, zararlı ve yabancı ot olduğu bilinmektedir. Domates üretiminde verim ve kalite kaybına sebep olan bazı zararlı böcekler ekonomik açıdan kritik öneme sahiptir (Fan vd., 2017). Böcek istilalarına bağlı ekonomik kayıpları azaltmak için etkili zararlı tespiti ve yönetimi zorunlu hale gelmiştir. Yapay zeka ve derin öğrenme modelleri, zararlıların kesin tanımlanmasını ve segmentasyonunu sunarak bu göreve katkıda bulunmaktadır (Wang ve Liu, 2021). Bu teknolojik müdahaleler, sürdürülebilir ve etkili zararlı yönetimi stratejileri vaat etmektedir.

Sonuç olarak, domateslerin hem beslenme hem de ekonomik açıdan global önemi inkâr edilemez. Gıda güvenliği, gelir oluşturma ve istihdamdaki hayati rolü, sürdürülebilir tarım uygulamaları ve politikalarının ihtiyacını vurgulamaktadır. Özellikle Türkiye gibi anahtar bölgelerdeki önemini tanımak, domates endüstrisinin sürekli başarısını garanti altına almak için önemlidir.

1.2. Domates Yetiştiriciliğinde Karşılaşılan Zararlılar ve Tespit Yöntemleri

Bitkisel üretimde zararlıların tespiti, ürünün ekonomik verimliliği için hayati öneme sahiptir (Maslo vd., 2017). Tarımsal ürünlerde zararlı böcekler, tarımsal verimliliği önemli ölçüde tehdit eder ve yıllık olarak milyarlarca dolarlık ürün kaybına neden olur (Maslo vd., 2017). Etkili zararlı yönetimi ve ekonomik kayıpların en aza indirilmesi için hızlı ve doğru bir zararlı tespiti gereklidir. Domates bitkisi beyazsinek, akar, yaprak bitleri, trips ve güveler gibi çeşitli böcek zararlılarına maruz kalabilir (Bleeker vd., 2012; Huda vd., 2020). Bu zararlılar doğrudan beslenme zararına neden olmanın yanı sıra, ekonomik kayıplara yol açan virüslerin de taşınmasına sebep olabilir (Bleeker vd., 2012). Özellikle *Epitrix* ve *Phyllotreta* cinslerinden pire böcekleri, genç domates bitkilerine zarar vererek kuruma veya bodurlaşma gibi problemlere yol açabilir (Brelh vd., 2003). Ek olarak, *Epitrix* türleri, patlıcan mozaik virüsünün domatese bulaşmasında aracı olabilir (Heuvelink, 2005).

Yaprak galeri sinekleri de domatese zarar verebilir, ancak bu genellikle tolere edilebilir düzeydedir (Şahin ve Genç, 2022). Ancak *Liriomyza* türlerinin saldırıları büyük ürün kayıplarına sebep olabilir (Walker, 2012). *Tuta absoluta* (Domates güvesi) ciddi zararlar verebilir ve tedbir alınmazsa %90'a varan ürün kaybına yol açabilir (Estay, 2000). *Nezara viridula* (Pis kokulu Yeşil Böcek) domates meyvelerini emerek onların pazar değerini azaltabilir (Heuvelink, 2005). *Myzus persicae*, *Aphis gossypii* ve *Macrosiphum euphorbiae* gibi yaprak biti türleri, yaprak özsuğu ile beslenerek bitki büyümesini engeller ve çiçek dökülmesine neden olabilir. Ayrıca, bu zararlılar Patates Y Virüsü'nün yayılmasında vektör olarak görev yapabilir (Heuvelink, 2005).

Domateste iki önemli akar zararlısı bulunmaktadır: İki noktalı kırmızı örümcek (*Tetranychus urticae*) ve Domates pas akarı (*Aculops lycopersici*). İki noktalı kırmızı örümcekler, özellikle yaşlı yaprakların alt kısımlarına yumurta bırakırlar ve bitki özsuğunu emerek beslenir. Bu durum yapraklarda klorotik nokta oluşumuna ve ipeksi ağlarla kaplanmasına yol açar. Domates pas akarı ise yaprakların önce gümüşü ve sonrasında nekrotik görünmesine neden olur. Popülasyon arttıkça gövde ve yaprak saplarında bronzlaşmaya ve yaprakların kurumasına yol açabilir (Heuvelink, 2005).

Çeşitli trips türleri domates üzerinde zarar vermektedir. Bu böcekler, bitki dokularından beslenir ve meyve, yaprak ve özellikle çiçeklerde hasara yol açar. Tripsler, domatesdeki virüslerin bulaşmasında da rol oynamaktadır (Heuvelink, 2005; Kirk, 1997). Domates üretiminde beyazsinek zararlıları arasında en yaygın olanları *Bemisia tabaci*, *B. argentifolii* ve *Trialeurodes vaporariorum*'dur. Beyazsinekler, bitki özsuğunu emerek domatesteki gelişimi zayıflatabilir. Daha büyük tehdit, bazı beyazsinek türlerinin bitki patojeni virüsleri taşıyor olmasıdır (Heuvelink, 2005). Emme sonucunda bitkide şekerli atıklar birikir, bu da fungal patojenler için elverişli bir ortam oluşturur (Henneberry vd., 1999).

Zararlıların tespiti için yaygın olarak kullanılan yöntemler, güve ve trips gibi böceklerle karşı çekici feromon kokuları ve yapışkan tuzaklar içermektedir (Pinto-Zevallos ve Vänninen, 2013). Zararlıların popülasyon yoğunlukları, tuzaktaki sayılarından elde edilen verilere göre tahmin edilmektedir. Tuzak sayımları insan gözlemine dayanmakta olup, zaman alıcı ve emek yoğun bir süreçtir. Özetle, tarımsal alanlardaki zararlı böceklerin

varlığı, erginlerin tuzaklara yakalanması ile belirlenir (Elekcioğlu, 2019). Günümüzde bitki hastalıklarının tespiti amacıyla kullanılan yöntemler arasında, moleküler teknikler, serolojik testler ve görüntü analizi gibi çeşitli seçenekler mevcuttur (Mahlein, 2016). Moleküler teknikler, patojenlerin DNA ve RNA analizlerini temel alarak hastalıkları saptamayı hedefler (Boonham vd., 2014). Serolojik testler ise, hastalığa yol açan patojenlerin antijenlerine karşı özgül antikorların reaksiyonunu ölçer (Narayanasamy, 2010).

Geleneksel zararlı tespiti ve takibi, çoğunlukla insan gözlemine dayandığı için hata yapma riski yüksektir. Bu yaklaşım, uzman bilgisi gerektirmesi, yoğun iş gücüne ihtiyaç duyması ve zaman alıcı olması nedeniyle oldukça zordur. Domates üretiminde zararlıların tespiti, etkili zararlı yönetimi stratejileri için hayati öneme sahiptir. Geleneksel zararlı tespit yöntemleri, zaman alıcı olmanın yanında genellikle doğru sonuçlar vermeme riski taşır (Wang vd., 2021). Ancak, derin öğrenme modellerindeki son gelişmeler, gerçek zamanlı olarak zararlıları doğru bir şekilde tespit etme ve tanıma konusunda umut vericidir (Fuentes vd., 2017; Wang vd., 2021). Bu modeller, *Dolycoris baccarum*, *Liriomyza bryoniae* ve *Helicoverpa armigera* gibi zararlıları, ayırt edici özelliklerine dayanarak tanımak için görüntü analiz tekniklerini kullanmaktadır (Huda vd., 2020). Ayrıca, segmentasyon modelleri, *Tuta absoluta*'nın yapraklarda ve *H. armigera* ile akarların meyvede neden olduğu zararları tespit edebilir ve miktarını belirleyebilir (Huda vd., 2020).

Domates üretiminde zararlıların erken tespiti, zamanında müdahaleye olanak tanır ve uygun zararlı yönetimi stratejilerinin uygulanmasını sağlar (Li ve Wang, 2020). Bu, sadece ürün zararını en aza indirmekle kalmaz, aynı zamanda kimyasal pestisitlere olan bağımlılığı azaltarak sürdürülebilir ve çevre dostu uygulamaları teşvik eder (Pérez-Hedo vd., 2021). Ayrıca, doğru zararlı tespiti, ekonomik etkilerin değerlendirilmesini kolaylaştırır ve karantina önlemleriyle ilgili karar alma süreçlerini destekler (Soliman vd., 2013). Sonuç olarak, domates üretiminde zararlıların tespiti, bu ürünün ekonomik önemi nedeniyle son derece önemlidir. İleri düzey derin öğrenme modelleri, zararlı tespitinde doğru ve gerçek zamanlı çözümler sunarak etkili zararlı yönetimi stratejilerine olanak tanımakta ve ekonomik kayıpları en aza indirmektedir.

1.3. Yapay Zekâ ve Derin Öğrenme: Temel İlkeler ve Teknikler

Yapay zekâ (YZ), makinelerin genellikle insan zekası gerektiren görevleri yerine getirme yeteneğini kapsayan ve hızla gelişen bir alandır (Yang, 2022). YZ'nin konsepti, insan zekasını taklit edebilen makineler oluşturma amacıyla 20. yüzyılın ortalarında ortaya çıkmıştır. Yıllar içinde YZ, çeşitli alt dallara ve tekniklere yer vererek evrimleşmiştir. Bu teknoloji, sağlıkta tanı, ilaç keşfi ve kişiselleştirilmiş tıp gibi alanlarda kullanılırken, aynı zamanda finasta dolandırıcılık tespiti ve algoritmik ticaret gibi işlevlerde de yer almaktadır (Chaudhari vd., 2020). Ulaşım sektöründe, YZ otonom araçlarda navigasyon ve nesne tespiti gibi görevler için kullanılırken; eğitimde, öğrencilere kişiselleştirilmiş geri dönüşler sunabilecek zeki eğitim sistemlerinde rol oynamaktadır (Şahin ve Topal 2018; Chaudhari vd., 2020).

Doğal Dil İşleme ve Bilgisayar Görüşü alanlarında, YZ teknikleri sıklıkla kullanılır. Bu teknikler, konuşma tanıma ve makine çevirisi gibi görevlerde oldukça başarılıdır (Liu vd., 2021). Ayrıca, oyun sektöründe de YZ'nin önemli katkıları vardır. Özellikle satranç ve Go gibi karmaşık oyunlarda, YZ ajanları insanüstü seviyelerde performans gösterebilmektedir (Legg ve Hutter, 2007). Haenlein ve Kaplan (2019)'a göre YZ, insan zekasını gerektiren görevleri gerçekleştirebilen zeki makinelerin geliştirilmesini amaçlayan çok disiplinli bir alandır. Alan Turing gibi erken dönem öncüleri, makine zekâsı için teorik çerçeveler önermiştir. Zamanla, bilgi işlem gücündeki, algoritmalarındaki ve veri erişilebilirliğindeki ilerlemeler, YZ teknolojilerinin gelişimini hızlandırmıştır (Haenlein ve Kaplan, 2019; Baştürk ve Şahin, 2022). Sağlıkta, finasta, ulaşımda ve eğitimde olduğu gibi birçok alanda YZ'nin uygulamaları mevcuttur. Ancak YZ'nin potansiyeli kadar etik kaygılar da bulunmaktadır. Gizlilik, önyargı ve iş displasmanı gibi konular, YZ teknolojilerinin sorumlu ve faydalı bir şekilde kullanılmasını garanti altına almak için dikkatlice ele alınmalıdır (Haenlein ve Kaplan, 2019; Atalan vd., 2022).

YZ modelleri, insan zekasını taklit eden ve belirli görevleri yerine getirebilen hesaplamalı sistemler veya algoritmalar olarak tanımlanabilir. Bu modeller, makine öğrenimi, derin öğrenme ve doğal dil işleme gibi teknikler kullanılarak oluşturulur. Örneğin, yapay sinir ağları (YSA), insan beyninin yapısından esinlenerek geliştirilmiş, veri içindeki desenleri ve ilişkileri tanımak için eğitilen modellerdir. Başka bir YZ modeli olan karar ağaçları, sınıflandırma ve regresyon görevleri için kullanılır. Ayrıca, partikül sürü optimizasyonu (PSO) ve yapay arı kolonisi (ABC) gibi optimizasyon algoritmaları da YZ modellerinde kullanılmaktadır (Ghafil ve Jármai, 2018; Güven ve Şahin 2022). Derin öğrenme teknikleri sayesinde, bilgisayar görüşü ve doğal dil işleme gibi alanlarda devrim yaratılmıştır.

Bir YZ modelinin çalışma ilkesi, etiketli bir veri kümesi üzerinde eğitim yapmasını içerir. Model, eğitim sürecinde tahminleri ve gerçek sonuçlar arasındaki farkı en aza indirmek için iç parametrelerini ayarlar. Eğitildikten sonra, model yeni verilere tahminde bulunmak için kullanılır. Bir kez derin öğrenme modeli eğitildiğinde, bitkileri sağlıklı ya da hastalık veya zararlı etkisi altında olarak sınıflandırmak için kullanılabilir. Model, bir giriş görüntüsünü alır ve tahminlerde bulunmak için özellikleri çıkartmak adına nöral ağı katmanlarına gönderir. Modelin çıktısı, bitkinin belirli bir hastalık veya zararlıdan etkilenme olasılığına dair bir olasılık dağılımıdır. Bitki hastalığı ve zararlı tespitinde derin öğrenme modellerinin performansını artırmak için çeşitli teknikler uygulanabilir. Örneğin, veri artırma teknikleri, görüntülere dönüşüm uygulayarak eğitim veri kümesinin boyutunu yapay olarak artırmak için kullanılabilir. Transfer öğrenme ise, büyük ölçekli veri kümelerinde önceden eğitilmiş modelleri kullanmayı ve bitki hastalığı ve zararlı tespiti gibi belirli bir görev için onları ince ayar yapmayı içerir. Bu yöntem, büyük veri kümesinden öğrenilen bilgiyi hedef görevdeki performansı artırmak için kullanır (Li ve Wang, 2021).

Tarımın hassas uygulamalarında YZ, makine öğrenimi (MÖ) ve derin öğrenme (DÖ) modellerinin entegrasyonu, bitki hastalıklarının ve zararlılarının tanımlanması da dahil olmak üzere çeşitli tarımsal görevlere yaygın olarak uygulanmıştır. Tarımda hastalık ve zararlı tespiti için YZ modelleri, artan gıda güvenliği talebini karşılama ve sürdürülebilir çiftçilik uygulamalarını teşvik etme konusunda önemli bir rol oynamaktadır (Yılmaz vd., 2021; Anitha vd., 2022; Wang vd., 2022; Jin vd., 2022).

YZ, MÖ ve DÖ modellerinin Hassas Tarım (HT) uygulamalarında entegrasyonu, hastalık tespiti ve zararlı kontrolü dahil olmak üzere tarımsal görevlerde devrim yaratmıştır. DÖ modelleri, bitkilerin görünümünü ve görsel belirtilerini analiz ederek bitki hastalıklarını doğru bir şekilde tanımlamada büyük potansiyel göstermiştir. Örneğin, çiftçilere potansiyel hastalık ve zararlılar hakkında uyarıda bulunan akıllı telefon tabanlı YZ uygulamaları geliştirilmiştir (Selvaraj vd., 2019). Ayrıca, bitki alanlarından gelen görselleri analiz ederek mahsullerle birlikte büyüyen çeşitli yabancı otları tespit etmek için tarımda ot tespiti için DÖ modelleri de kullanılmıştır (Murad vd., 2023). Bunun yanı sıra, akıllı tarım sistemlerinde zararlı tanımlama için YZ ve görüntü tanıma teknolojilerinin çevresel sensörler ve Nesnelerin İnterneti (IoT) ile entegrasyonu üzerinde çalışılmıştır (Chen vd., 2020). Ayrıca, bilgisayar görüşü (BG) tabanlı otomatik zararlı veya hastalık tanımlama teknikleri, akıllı tarım alanında popülerlik kazanmıştır. Yapay zekanın hızlı gelişiminden yararlanarak, araştırmacılar geleneksel makine öğrenimi modellerinden derin öğrenme tekniklerine odaklanarak kaydırmışlardır (Yang vd., 2019).

Genel olarak, hassas tarımda YZ, makine öğrenimi ve derin öğrenme modellerinin entegrasyonu hastalık ve zararlı tespitinde devrim yaratmıştır. DÖ modelleri, bitki hastalıklarını ve yabancı otları doğru bir şekilde tanımlamak için yaygın olarak kullanılmıştır. IoT ile YZ ve görüntü tanıma teknolojilerinin kombinasyonu, etkili zararlı tanımlamayı mümkün kılmıştır. Bilgisayar görüşü tabanlı zararlı tanımlamada derin öğrenme tekniklerinin kullanılması da ilgi görmüştür. YZ ve DÖ modellerindeki bu ilerlemeler, tarımda hastalık ve zararlı kontrolünün verimliliğini ve etkinliğini önemli ölçüde artırmış, gıda güvenliği ve sürdürülebilir çiftçilik uygulamalarına katkıda bulunmuştur (Selvaraj vd., 2019; Murad vd., 2023; Chen vd., 2020; Yang vd., 2019).

1.4. Gelişmiş Görüntü İşleme Teknikleri ve Tarımsal Uygulamaları

Evrişimli sinir ağları (CNN) resim sınıflandırma (bir resmin içerdiği şeyi tanımlama), nesne tespiti (bir resimdeki nesneleri ve sınırlayıcı kutularını bulma) ve resim bölütleme (bir resimdeki her pikseli sınıflandırma) gibi çeşitli görevlerde başarılı sonuçlar elde etmiştir. Bu ağlar, sosyal medya platformlarındaki fotoğraf etiketleme özelliklerinden otonom araçlardaki ileri sistemlere kadar birçok modern bilgisayarlı görü uygulamasının temelini oluşturmaktadır.

CNN kullanarak geliştirilen yapay zekâ ve derin öğrenme metotları, tarımda görüntü işlemenin kapasitesini önemli ölçüde artırmıştır (Şahin ve Topal 2016; Yang vd., 2019; Kamilaris ve Prenafeta-Boldú, 2018; Şahin vd., 2020). Geleneksel yöntemlerle zahmetli ve maliyetli olan zararlı tespit işlemleri, nesne tespiti ve örneklem bazlı bölütleme yöntemleri sayesinde dönüşmüştür. Bu yöntemler, zararlıların ve hastalıkların hızlı ve etkili bir şekilde tespitini sağlayarak tarımsal ürünlerin korunmasına katkıda bulunmaktadır (Tannous vd., 2023; Prabha vd., 2022; Yang vd., 2019; Cantez vd., 2023). Özellikle, CNN'lerin sağladığı yüksek performans, böcek türlerini sınıflandırmada kritik bir rol oynamaktadır (Zhang vd., 2022). Bu AI modellerinin eğitiminde kullanılan AgriPest gibi veri setleri, alandaki çalışmalara değerli bir katkı sağlamıştır (Wang vd., 2021). Üstelik, bu modellerin mobil uygulamalarla entegrasyonu, çiftçilere arazide anında zararlı tespiti yapma olanağı sunarak, sürdürülebilir ve verimli tarım pratiğinin önünü açmaktadır (Prabha vd., 2022; Pattnaik ve Parvathi, 2020). Sonuç olarak, yapay zekâ destekli bu gelişmiş görüntü işleme teknikleri, modern tarımda zararlı yönetimi, verim tahmini ve hastalık tespiti gibi alanlarda etkili bir araç seti sunmaktadır. Bu teknolojilerin tarımsal uygulamalara entegrasyonu, üretkenliği ve sürdürülebilirliği artırma potansiyeline sahiptir.

Tarımsal zararlı tespitinde yapay zekâ kullanımının alandaki konumunda, özellikle evrişimli sinir ağları (CNN) üzerine inşa edilen AI modelleri, zararlılara işaret eden görsel örüntüleri ayırt etmek için karmaşık görüntü işleme tekniklerini kullanmaktadır. JPG formatındaki bir görüntüyü işlerken, ana işlem, bu görüntüyü ölçülebilir bir diziye, yani genellikle kırmızı, yeşil ve mavi olmak üzere renk kanallarını da içeren üç boyutlu bir matrise çözümlemektir. Bu matristeki her değer, genellikle 0 ile 255 arasında değişen, ilgili pikselin yoğunluğunu ifade eder. CNN'ler, bu matris üzerinde, bir dizi evrişim, havuzlama ve tamamen bağlı katmanlar aracılığıyla uzamsal hiyerarşileri tanımlayarak ve öğrenerek işlev görür, giriş matrisini ardışık olarak soyut özellik temsillerine dönüştürür. Bu ilerlemenin zirvesinde, bu durumda belirli zararlıları belirten tespit kategorileri ortaya çıkar. Eş zamanlı olarak, yerelleştirme görevleri için model, tanımlanan zararlıların etrafına sınırlayıcı kutuları tahmin eder; bu kutular, varlığın merkezini belirten (x, y) koordinatlarla ve genişliğini ve yüksekliğini yansıtan (w, h) ile belirlenir. Bu sınırlayıcı kutu tahminleri, genellikle çoklu yakın varlıkları yerelleştirmede hassasiyeti sağlamak için maksimum olmayan bastırma gibi teknikler kullanılarak rafine edilmektedir.

CNN, bilgisayarlı görüde önemli ilerlemelere katalizör olmuştur. Bu ilerlemeler arasında kilit bir nokta, her görüntü pikselini önceden tanımlanmış bir kategoriye sınıflandıran semantik bölütlemenin ve bireysel nesne örneklerini ayırt eden örneklem bazlı bölütlemenin ayrımıdır. CNN tabanlı Mask R-CNN, bir nesne maske tahmini ile sınırlayıcı kutu tanımanın entegrasyonu ile sağlam bir örneklem bazlı bölütme yeteneği sunmaktadır. Segment Anything Model (SAM) modeli ise çeşitli sınıflar arasında örneklem bazlı bölütmeyi genelleştirme yeteneğini örneklerken, YOLOv8 gibi modeller hem örneklem bazlı segmentasyon hem de nesne tespiti için çift amaçlı olarak hizmet etmektedir. YOLOv8'in yeteneği, Detectron2, DETR, Faster R-CNN, MobileNet SSD v2 ve EfficientDet (D7) gibi diğer modellerle paylaşılan gerçek zamanlı nesne tespitinde yatmaktadır. Özellikle, DETR'deki dönüştürücülerin uygulanması, doğal dil işleme tekniklerinin görüş görevlerine entegrasyonunu sergilemektedir. GroundingDINO, nomenklatürde daha spesifik olmasına rağmen, kendi kendine denetimli öğrenme paradigmalara dalmaktadır. Tüm bu modeller, Tensorflow 2 gibi platformlar kullanılarak etkili bir şekilde faaliyete geçirilebilir, bu da CNN tabanlı modellerin pratik uygulamalara entegrasyonunu vurgulamaktadır.

1.5. Derin Öğrenme Modellerini Destekleyen Programlama Dilleri

Son yıllarda, derin öğrenme, yapay zekâ alanındaki birçok disiplini devrim niteliğinde değiştirmiştir, bu da özelleştirilmiş hesaplama araçları ve platformlarının geliştirilmesini zorunlu kılmıştır (LeCun vd., 2015). Python, TensorFlow (Abadi vd., 2016), PyTorch (Paszke vd., 2019) ve Keras gibi çok yönlü ve güçlü kütüphaneler sayesinde bu alandaki öncü programlama dili olarak konumunu sağlamlaştırmıştır. Ancak, alternatif diller de kayda değer katkılarda bulunmaktadır. Örneğin, Julia, Flux.jl kütüphanesiyle belirli hesaplama ihtiyaçlarına hizmet eden performans ve kullanım kolaylığının bir karışımını sunmaktadır (Innes vd., 2018). İstatistiksel yetkinliğiyle tanınan R dili, MXNet (Chen vd., 2015) gibi paketlerle derin öğrenme alanında ilerlemeler kaydetmiştir. Ayrıca, Lua'nın Torch kütüphanesi, daha önceki temel derin öğrenme araştırmalarında kritik bir rol oynamıştır (Collobert vd., 2011). Bu programlama ortamları, her biri kendi benzersiz güçleriyle, derin öğrenme alanındaki araştırmacılara sunulan çeşitli ve dinamik araç setini vurgulamaktadır.

1.6. Yapay Zekâ Uygulamalarında Kullanılan Entegre Geliştirme Ortamları

Yapay zekâ alanındaki hızla gelişen değişikliklerde, entegre geliştirme ortamları (EGO) araştırma, geliştirme ve dağıtım sorunsuz bir şekilde kolaylaştırma rolünde vazgeçilmezdir. Açık kaynaklı bir web uygulaması olan Jupyter Notebook, interaktif hesaplama ve veri analizi için altın standart haline gelmiştir, birçok programlama dilini doğal olarak desteklemekte ve interaktif görselleştirmeyi mümkün kılmaktadır (Kluyver vd., 2016). Başka önemli bir EGO olan PyCharm, özellikle Python geliştirmesi için hazırlanmıştır; TensorFlow ve PyTorch gibi kütüphanelerle derin entegrasyonu, onu YZ geliştiricileri için tercih edilen bir seçenek haline getirmiştir (Kennedy, 2017). Ayrıca, Google'ın Colab'ı, Jupyter ortamını temel alarak, bulut tabanlı bir ortamda GPU desteği sunar, bu da onu derin öğrenme projeleri için özellikle avantajlı kılar (Bisong, 2019). Microsoft'un Visual Studio Code'u, geniş eklenti ekosistemiyle, çeşitli dillerde YZ uygulama geliştirmesi için çok yönlü bir ortam olarak hizmet vermektedir. YZ çeşitlenmeye devam ettikçe, DL4J entegrasyonu Eclipse gibi diğer EGO'ların önemi daha da artmaktadır. Bu, YZ araştırması ve uygulamalarında yenilik ve verimliliği teşvik etmedeki kritik rollerini vurgulamaktadır.

1.7. Dil Modellerinin Tarımsal Alanında Kullanım Potansiyeli ve Önemi

Dil modelleri (DM), bir dildeki kelime dizilerini tahmin etmek için tasarlanmış olasılıksal hesaplamalı birimlerdir. Temelde, bir DM, kelime dizisinin olasılığını ölçer ve bu, konuşma tanıma, makine çevirisi ve metin üretme gibi görevlerde yardımcı olur (Jurafsky ve Martin, 2019). Geleneksel olarak, n-gram modelleri DM'lerin temelini oluşturmuş, büyük veri kümelerinden istatistikleri kullanarak önceki kelime dizilerine dayanarak kelime oluşumlarını tahmin etmiştir (Chen ve Goodman, 1999). Ancak, modern DM'ler büyük ölçüde derin öğrenmeye, özellikle de sinir ağı temelli yaklaşımlara kaymıştır. Bu sinir modelleri, Long Short-Term Memory (LSTM) ve Transformer gibi mimariliklerle örneklenen, çok katmanlı ağların kapasitesini kullanarak metinsel verilerde karmaşık desenleri, bağımlılıkları ve semantikleri tanıma kapasitesine sahiptir (Hochreiter ve Schmidhuber, 1997; Vaswani vd., 2017).

Transformer tabanlı modeller, girdi belirteçlerini dinamik olarak değerlendiren dikkat mekanizmalarını kullanarak, uzun mesafeli bağımlılıkların üstün bir şekilde ele alınmasını sağlar (Vaswani vd., 2017). GPT-3 gibi devasa önceden eğitilmiş modellerin ortaya çıkışı, birçok dil görevinde insan benzeri performans sergileyen sinir DM'lerdeki ilerlemelerin zirvesini temsil etmektedir (Brown vd., 2020).

Tarım sektöründe yapay zekâ uygulamalarının ortaya çıkışı, özellikle OpenAI'nin GPT serisindeki ilerlemelerle öne çıkarılarak, sektörde dönüm noktası yeniliklere zemin hazırlamıştır. Dil modelleri, doğal dil işleme (DDİ) ve karmaşık makine öğrenimi yapılarıyla desteklenerek, tarımsal veri analitiğinde dönüştürücü bir güç olarak ortaya çıkmıştır (Chlingaryan vd., 2018; Radford vd., 2019). Bu modeller, bilimsel literatürden tarım raporlarına kadar geniş kapsamlı metinsel veri kümelerini işlemede uzmandır. Güçleri, karmaşık tarımsal bilgiyi eyleme dönüştürülebilir içgörülere çevirme ve yüksek seviyeli araştırmalarla sahadaki uygulamalar arasında köprü kurma yeteneklerindedir (Satiansiriwawat vd., 2018).

Ayrıca, dil modellerinin hassas tarımdaki etkileri derindir. Çeşitli veri kaynaklarını, hava durumu metriklerinden toprak koşullarına kadar, entegre ederek, dil modelleri çiftçilere gerçek zamanlı, eyleme dönüştürülebilir içgörüler sunar. Bu bütünsel veri yaklaşımı, sadece kaynak tahsisini optimize etmekle kalmaz, aynı zamanda mahsul verimini artırır ve çevresel zararı azaltır (Zhang vd., 2012; Satiansiriwawat vd., 2018). Uzman tarım danışmanlığına erişimin sınırlı olduğu bölgelerde, bu modeller karmaşık tarım araştırmalarını sindirilebilir bilgilere dönüştürerek iletişimi devrimleştirebilir ve mevcut bilgi uçurumunu kapatmada kilit bir rol oynar (Bengio vd., 2013; Mann vd., 2020).

Tarım sektörünü zorlayan artan sorunlar, iklim değişikliklerinden patlayan küresel gıda taleplerine kadar değişen zorluklarda, dil modellerinin yetenekleri giderek daha kritik hale geliyor. Karmaşık veri kümelerini çözme, tarımsal desenleri öngörme ve bilgilendirilmiş veri analizlerine dayanarak strateji belirleme konusundaki eşsiz kapasiteleri, dayanıklı ve sürdürülebilir bir tarım geleceği şekillendirme rolünün ne kadar önemli olduğunu vurgulamaktadır (Bronson ve Knezevic, 2016).

YZ temelli dil modelleri, tarımda, ürün yönetimi, zararlı kontrolü, hastalık tespiti ve karar alma süreçleri dahil olmak üzere çeşitli yönleri devrim niteliğinde değiştirme potansiyeline sahiptir. Bu modeller, bilimsel literatür, hava durumu örüntüleri, toprak koşulları ve tarihsel ürün performansı gibi büyük miktarda veriyi analiz ederek çiftçilere değerli içgörüler ve öneriler sunabilir. Dil modellerinin tarımsal açıdan sunabileceği iyileştirmeler “Ürün Yönetimi”, “Zararlı Kontrolü”, “Hastalık Tespiti”, “Karar Alma Süreçleri” ve “Zorluklar ve Etik Hususlar” başlıkları altında özetlenebilir.

Ürün Yönetimi: AI temelli dil modelleri, çiftçilere ürün yönetimi uygulamalarını optimize etmelerinde yardımcı olabilir. Toprak koşulları, hava durumu örüntüleri ve tarihsel ürün performansı üzerine veri analizi yaparak, bu modeller sulama, gübreleme ve zararlı kontrolü için kişiselleştirilmiş önerilerde bulunabilir. Bu, geliştirilmiş ürün verimlerine, kaynak israfının azalmasına ve artan sürdürülebilirliğe yol açabilir (Akbudak vd., 2022; Cavazza, 2023).

Zararlı Kontrolü: Zararlılar, tarımsal verimlilik için önemli bir tehdit oluşturmaktadır. AI temelli dil modelleri, uydu görüntüleri, sensör ağları ve zararlı izleme raporları gibi çeşitli kaynaklardan gelen veriyi analiz ederek zararlı popülasyonlarını tanımlamak ve izlemek için yardımcı olabilir. Gerçek zamanlı zararlı salgınları hakkında bilgi sağlayarak ve uygun kontrol önlemleri önererek, bu modeller çiftçilere zamanında müdahalede bulunma olanağı tanır, böylece ürün kayıplarını en aza indirir (Cavazza, 2023).

Hastalık Tespiti: Bitki hastalıklarının erken tespiti, yayılmalarını önlemek ve ürün kayıplarını en aza indirmek için hayati öneme sahiptir. YZ temelli dil modelleri, resimler, sensör verileri ve hastalık veri tabanları dahil olmak üzere çeşitli kaynaklardan gelen veriyi analiz ederek hastalık belirtileri ve örüntüleri belirleyebilir. Doğru ve zamanında hastalık tespiti sağlayarak, bu modeller çiftçilere hedeflenmiş müdahalelerde bulunma olanağı tanır, geniş spektrumlu pestisit ihtiyacını azaltır ve çevresel etkiyi en aza indirir (Cavazza, 2023).

Karar Alma Süreçleri: AI temelli dil modelleri, gerçek zamanlı içgörüler ve öneriler sunarak çiftçilere bilinçli kararlar almalarında destek olabilir. Bu modeller, pazar eğilimleri, hava tahminleri ve ürün performansı hakkında veriyi analiz ederek çiftçilere ekim programlarını optimize etme, optimal hasat zamanlarını belirleme ve ürün çeşitlendirme ve pazar seçimleri hakkında bilinçli kararlar alma konusunda yardımcı olabilir. Bu, çiftçiler için artan kârlılığa ve azaltılan risklere yol açabilir (Cavazza, 2023).

Zorluklar ve Etik Hususlar: AI temelli dil modelleri tarımda önemli bir potansiyel sunsa da ele alınması gereken birkaç zorluk ve etik husus bulunmaktadır. Ryan (2022) tarafından yapılan bir referans, AI'nın tarım sektöründe kullanılmasının sosyal ve etik etkilerini incelemektedir. Çalışma, literatürde tartışılan yaygın zorlukları ve etkileri belirler ve bunların AI etik kurallarıyla ilişkisini araştırır. Etik hususlar, veri gizliliği, algoritmik önyargı ve potansiyel insan emeği yer değiştirmesi içerir.

1.8. Yapay Zekâ Uygulamaları için API (Uygulama Programlama Arayüzü) İlkeleri

Yazılım geliştirmenin alanında, özellikle YZ konusundaki büyüyen ilerlemelerle birlikte, Uygulama Programlama Arayüzleri (API'ler) farklı sistemlerin iletişim kurmasına, entegre olmasına ve birlikte evrimleşmesine olanak tanıyan kritik bağlantıları oluşturmaktadır (Pautasso vd., 2008). Özgün karmaşıklıkları göz önüne alındığında, AI uygulamaları için API'ler, kesintisiz etkileşim, ölçeklenebilirlik ve sağlamlığı garanti etmek için temel ilkelere uygun olmalıdır. Bu ilkelere birincil olanı modülerliktir; bu, bileşenlerin gevşek bir şekilde birleşmesine izin vererek daha kolay bakım ve güncellemelerin yapılmasını teşvik etmektedir (Tilkov ve Vinoski, 2010). Bu, özellikle sık sık model güncellemeleri ve rafinemeleri yapan AI sistemleri için çok önemlidir (Goodfellow, Bengio ve Courville, 2016). Bir diğer ana ilke, API'nin yalnızca gerekli işlevleri açığa çıkardığı soyutlama ilkesidir; bu da karmaşık AI operasyonlarını ve model ayrıntılarını kapsamaktadır. Bu tür bir soyutlama, son kullanıcıların AI'ın yeteneklerinden yararlanmalarını, karmaşık detaylarına dalmadan sağlamaktadır.

Ayrıca, YZ etiği ve şeffaflığına yönelik artan endişeler ışığında, API'lerin yorumlanabilirlik ve açıklanabilirlik ilkelerini benimsemesi zorunlu hale gelmiştir, böylece kullanıcılara temel AI modellerinin karar alma süreçleri hakkında bilgi sağlanmaktadır (Doshi-Velez ve Kim, 2017). AI, çeşitli sektörlerle olan durdurulamaz ilerleyişine devam ederken, bu yönlendirici ilkeler temelinde API'lerin geliştirilmesi ve tasarımı, gerçek dünya senaryolarında YZ uygulamalarının tam potansiyelinin gerçekleştirilmesinde kilit bir role sahip olabilir.

1.9. Yapay Zekâ ile Zararlı Tespitinin Önemi ve Yenilikleri

Yapay zekâ ile zararlı tespiti, zararlılar ve hastalıklar nedeniyle oluşabilecek kayıpları azaltmanın yanı sıra ürün verimini ve kalitesini artırma potansiyeli nedeniyle tarımda giderek daha önemli hale gelmektedir (Chen vd., 2023). Geleneksel zararlı tespit ve tanımlama yöntemleri, genellikle manuel kontrolleri ve uzman teşhislerini gerektirir, bu da zaman alıcı ve verimsiz olabilir (Chen vd., 2023). Ancak, YOLOv8, Detectron2, GroundingDINO, DETR, Faster R-CNN, MobileNet SSD v2, Mask RCNN, SAM ve EfficientDet (D7) Tensorflow 2 gibi YZ ve derin öğrenme modellerindeki ilerlemelerle, bitki zararlıları ve hastalıklarının gerçek zamanlı tespiti ve erken uyarıları mümkün hale

gelmiştir (Chen vd., 2023). Ayrıca YZ dayalı uygulamalar, Alan Özgü Zararlı Yönetimini mümkün kılarak sürdürülebilir tarıma destek sunmaktadır. Alan Özgü Zararlı Yönetimi (Site-specific Pest Management, SSPM) ya da lokal veya noktasal ilaçlama, tarımsal alanlarda tespit edilen ve kontrol edilen zararlı ve hastalıklara özgü bölgelere odaklanan bir zararlı yönetim stratejisi olarak tanımlanmaktadır. Bu yöntem, geniş kapsamlı kimyasal müdahalelerin tarımsal alanlara uygulanması yerine, zararlı ve hastalıkların yoğunlaştığı bölgelere daha hassas ve hedef odaklı uygulamalar benimsemeyi amaçlar (Mulla, 2013; Slaughter vd., 2008). SSPM'nin önemi, bitki verimliliğini daha az kimyasal kullanarak artırma ve kimyasalların çevreye olan olumsuz etkilerini azaltma potansiyelinden kaynaklanmaktadır. Ek olarak, bu yaklaşım, hedef dışı faydalı organizmaların korunmasına destek olmakta ve zararlı böceklerin kimyasal direnç geliştirmesinin önlenmesinde önemli bir adım olarak kabul edilmektedir (Zhang vd., 2012).

SSPM'nin sağladığı avantajlar, daha sürdürülebilir tarımsal uygulamalar, düşük maliyetler, verimlilik artışı ve çevresel etkilerin azaltılması şeklinde özetlenebilir. Bu alanda yapılan çalışmalar genellikle, uydu görüntüleri, hava fotoğrafları ve sensör teknolojileri kullanarak zararlı ve hastalıkların dağılımını belirlemeye yöneliktir (Zhang vd., 2012; Schimmelpfennig ve Ebel, 2016; Liakos vd., 2018; Kreuze vd., 2022). YZ uygulamaları SSPM'ye önemli katkılar sağlayabilir. SSPM uygulamalarının daha etkili ve hedef odaklı hale gelmesine yardımcı olarak, kimyasal kullanımını daha da azaltabilir ve tarımsal üretimin sürdürülebilirliğine katkı sağlayabilir (Sankaran vd., 2015).

YZ modelleri, tarımsal ortamlarda zararlıları doğru ve güvenilir bir şekilde tespit etmek ve tanımak için derin evrişimli sinir ağlarından faydalanır (Jiao vd., 2022). Örneğin, YOLOv8 modeli, bir görüntüde birden fazla nesnenin sınırlayıcı kutularını ve sınıf olasılıklarını eşzamanlı olarak tahmin etmek için tek bir sinir ağı kullanır, bu da zararlı tespiti için etkili ve verimli kılar (Xiang vd., 2023). Benzer şekilde, Detectron2 modeli, zararlı tespiti görevlerine uygulanabilecek esnek ve modüler bir nesne tespiti ve örnek segmentasyon çerçevesi sağlar (Chen vd., 2023). YZ ile zararlı tespitin kullanılması, IP102 veri kümesi gibi büyük ölçekli referans veri kümelerinin mevcudiyatından da faydalanır. Bu veri kümeleri, özellikle böcek zararlısı tanımları için tasarlanmış YZ modellerinin geliştirilmesi ve değerlendirilmesi için geniş bir böcek zararlısı resim

yelpazesi içerir (Wu vd., 2019). Bu veri kümeleri, tarımda zararlı tespitinin otomasyonuna ve verimliliğine katkıda bulunur (Wu vd., 2019). Genel olarak, zararlı tespitinde YZ ve derin öğrenme modellerinin entegrasyonu, zararlı tanımlamanın doğruluğunu ve verimliliğini artırarak, gerçek zamanlı izleme ve erken uyarı sistemlerini mümkün kılma ve nihayetinde ürün verimini ve kalitesini artırma potansiyeline sahiptir (Zhang vd., 2023). Ancak, duruş değişikliğine sahip zararlılar, yoğun dağılım ve sınıf içi benzerlik gibi zorlukların üstesinden gelmek için daha kesin ve güvenilir bir zararlı tespiti elde etmek amacıyla daha fazla araştırma ve geliştirmeye ihtiyaç vardır (Jiao vd., 2022).

Görsel gözlemlerin geleneksel yöntemleri, akıllı tarımın taleplerini karşılamak için artık yeterli değildir (Zhang vd., 2022). Ancak bilgisayar ve yapay zekâ teknolojisindeki ilerlemelerle yenilikçi zararlı tespit yöntemleri ortaya çıkmıştır. GPT-3 gibi büyük dil modellerinin kullanılması gibi yapay zekâ temelli teknolojiler, verimli ve doğru zararlı tespit çözümleri sunarak tarım alanında devrim yaratma potansiyeline sahiptir (Gupta vd., 2022). OpenAI tarafından geliştirilen ve eğitilen GPT-3, Üretici Önceden Eğitilmiş Dönüştürücü 3 (GPT-3) modeline dayanan bir sohbet sistemidir (Zhavoronkov, 2022). GPT-3, doğal dil metnini anlama ve oluşturma konusundaki etkileyici yetenekleriyle bilinen büyük bir dil modelidir (Zhavoronkov, 2022).

Büyük miktarda veriyi işleme ve analiz etme yeteneği nedeniyle tarım da dahil olmak üzere çeşitli alanlarda uygulanma potansiyeline sahiptir. Tarımda zararlı tespiti bağlamında, GPT-3 zararlı tespit sistemlerinin doğruluğunu ve verimliliğini artırmak için kullanılabilir. GPT-3, görüntüler, sensör verileri ve tarihi kayıtlar gibi çeşitli kaynaklardan gelen verileri analiz edip yorumlayarak zararlı istilalarıyla ilişkilendirilen desenleri ve anomaliyi tanımlayabilir (Gupta vd., 2022). Bu, çiftçilere ve tarım profesyonellerine zararlı yönetimi stratejileri hakkında bilinçli kararlar alma konusunda yardımcı olabilir.

Özellikle, pestisitlerin zamanında uygulanması veya entegre zararlı yönetimi uygulamalarının gerçekleştirilmesi gibi. Ayrıca, GPT-3 zararlı salgınları için öngörücü modellerin geliştirilmesine de yardımcı olabilir. Model, tarihi verileri ve çevresel faktörleri analiz ederek belirli bölgelerde veya ürünlerde zararlı istilalarının olasılığını öngörebilir (Gupta vd., 2022). Bu proaktif yaklaşım, çiftçilere önleyici tedbirler almayı ve zararlıların ürün verimine olan etkisini en aza indirmeyi sağlar. Ancak, GPT-3'ün sınırlamaları olduğunu belirtmek önemlidir. Bir dil modeli olarak, mevcut veritabanlarına ve içeriğe dayanmaktadır, bu da onun güncel bilgi sağlama yeteneğini sınırlayabilir (Buriak vd., 2023). Ayrıca, GPT-3 metin oluşturabilir ve doğal dili anlayabilirken, bilim insanlarının sahip olması beklenen analitik yeteneklere sahip değildir (Buriak vd., 2023). Bu nedenle, insan uzmanlığının bir yerine getirici yerine karar verme sürecini desteklemek için bir araç olarak kullanılmalıdır.

1.10. Araştırmanın Amacı

Bu çalışmada hem tespit hem de segmentasyon yapabilen yenilikçi YOLOv8 (You Only Look Once), Detectron2, GroundingDINO, DETR, Faster R-CNN, MobileNet SSD v2, Mask RCNN, Segment Anything Model (SAM) ve EfficientDet (D7) Tensorflow 2 modeller test edilmiştir. Tespit amacıyla domates bitkisinde zararlı olan, *Dolycoris baccarum*, *Liriomyza bryoniae*, *Helicoverpa armigera*, *Phyllotreta* spp., *Nezara viridula*, yaprak bitleri, *Bemisia tabaci*, *Leptinotarsa decemlineata*, *Tuta absoluta*, *Frankliniella occidentalis* ve *Tetranychus urticae* türlerine ait arazi fotoğrafları elde edilmiştir. Segmentasyon amacıyla ise, *L. bryoniae*'nin yapraklarda, *H. armigera*'nın meyvelerde, *T. absoluta*'nın yaprak ve meyvelerde, *F. occidentalis* ve *T. Urticae*'nin yapraklarda ve meyvelerde yaptığı zararları içeren arazi fotoğraflar temin edilmiştir.

Çalışmada kullanılan derin öğrenme modelleri arasından, zararlıları hız ve doğruluk açısından en iyi tespit performansı gösterenler belirlenmiştir. En iyi performans gösteren model belirlendikten sonra, dil modeli GPT-3 ile entegre edilmiştir. Buradaki amaç, dil modeli aracılığıyla zarar biçimlerini, yaşam döngülerini ve bu zararlılarla ilgilenirken ekolojik olarak dostane alternatif yöntemleri değerlendirmektir. Bu amaçla, API bağlantısı kullanılarak, tespit modeli tarafından bulunan zararlı etiketleri dize değerlerine dönüştürülerek GPT-3 dil modeli için giriş olarak kullanılmıştır. Böylece, hatalara eğilimli, zaman alıcı, yüksek insan gücü gerektiren ve büyük bir bilgi tabanı talep eden

insan gözlemine kıyasla, yapay zekâ modelleriyle daha doğru, ekonomik ve çevre dostu mücadele yöntemleri önerebilme potansiyeline ulaşılabilecektir. Ayrıca, tespit modeli ile dil modelinin entegrasyonu, gerçek zamanlı uzman içgörülerini sağlama potansiyeline sahip olup, uzak bölgelerde tarımı dönüştürmeyi ve sürdürülebilir ekolojik uygulamaları teşvik etmeyi planlamaktadır.



2. KAYNAK ARAŞTIRMASI

2.1. Örtü Altı Domates Üretiminde Zararlıların Etkisi

Örtü altı domates üretimi, dış çevre koşullarından bağımsız olarak sıcaklık, nem ve ışık gibi mikro iklim parametrelerinin kontrol edilmesine imkân tanır, bu da optimize edilmiş büyüme koşullarını mümkün kılar (Jones, 1992). Ancak bu kontrollü ortam, zararlı böceklerin daha hızlı yayılmasını ve doğal düşmanların varlığının sınırlı olmasını nedeniyle, zararlı popülasyonlarının kontrolsüz bir şekilde artmasına sebep olabilir (Heinz vd., 2004). Ayrıca örtü altı üretim, yüksek başlangıç yatırımları gerektirir, arazi şartlarına kıyasla daha yoğun bir üretim döngüsüne sahiptir. Örtü altı üretimde ciddi ekonomik kayıplarla karşılaşmamak için zararlı kontrolü kritik bir öneme sahiptir (Van Lenteren, 2000). Bu bağlamda, örtü altı domates üretimi üzerindeki zararlıların kontrolü hem ekonomik hem de üretim verimliliği açısından vazgeçilmedir.

Örtü altı domates üretiminde veya diğer bitkisel üretimlerde zararlı kontrolü, çeşitli böcek zararlıları tarafından oluşturulan potansiyel zarar nedeniyle önemlidir. Bu zararlılar, ürün verimini ve kalitesini önemli ölçüde etkileyerek çiftçiler için yıkıcı ekonomik kayıplara neden olabilir. Domates ve diğer ürünleri zarar verebilecek böcek zararlılarına *Dolycoris baccarum*, *Phyllotreta* spp., *Myzus persicae*, *Bemisia tabaci*, *Tuta absoluta*, *Leptinotarsa decemlineata*, *Nezara viridula*, *Liriomyza bryoniae*, *Frankliniella occidentalis*, *Tetranychus urticae* ve *Helicoverpa armigera* örnek verilebilir (Belder vd., 1999). Zararlı kontrolü, sera içindeki domates üretimi ve diğer ürün üretimlerinde birkaç nedenden dolayı önemlidir.

İlk olarak, böcek zararlıları, yaprak, sap, meyve veya köklere beslenerek ürünlere doğrudan zarar verebilir. Bu beslenme, bitki büyümesinde azalmaya, verim kaybına ve hatta bitki ölümüne yol açabilir (Maruthi vd., 2004; Mugerwa vd., 2018). İkincisi, böcek zararlıları ürünlere hastalık bulaştırabilir (Pan vd., 2012; Polston vd., 2014). Üçüncüsü, böcek zararlıları, seradaki veya tarladaki ekosistem dengesini bozarak zararlıların doğal düşmanlarını etkileyebilir ve biyolojik kontrol yöntemlerinin etkinliğini azaltabilir (Leeuwen vd., 2015). Bu nedenle, böcek zararlıları tarafından oluşturulan zararı en aza indirmek ve sera içindeki domates üretiminin ve diğer ürün üretim sistemlerinin verimliliğini ve karlılığını sağlamak için etkili zararlı kontrol önlemleri gereklidir.

Domates üretiminde zararlılar tarafından oluşturulan ekonomik etkiler önemli olup, çiftçilere önemli bir mali yük getirebilmektedir. *T. absoluta* gibi zararlılar, kontrol önlemleri alınmadığı takdirde domates mahsullerinde ciddi verim kayıplarına yol açabilmektedir (Desneux vd., 2010). Son zamanlarda istilaya uğrayan bölgelerde, *T. absoluta*'nın domates mahsullerinde %80-100'e varan verim kayıplarına neden olduğu bilinmektedir, bu da hem seralarda hem de açık tarlalarda domates üretimi için bir tehdit oluşturmaktadır (Desneux vd., 2010). *T. absoluta* tarafından hızla kolonileşme ve yüksek seviyede zarar verme hem açık hem de sera mahsullerinde domates üretimi için anahtar bir konu haline getirmiştir (Vacas vd., 2011).

Böcek zararlılarından kaynaklanan doğrudan ve dolaylı maliyetler, bir çiftçinin gelirine önemli bir etkisi olabilmektedir. Doğrudan maliyetler, böcek ilaçları ve diğer zararlı kontrol ürünlerinin satın alınması gibi zararlı kontrol önlemleri için yapılan harcamaları içermektedir. Bu maliyetler, istilanın şiddetli olması ve böcek ilacı uygulamalarının sıkça yapılmasını gerektirmesi durumunda önemli olabilir (Akhtar vd., 2021). Ayrıca, böcek ilaçlarının kullanımı, hedef olmayan organizmalar ve çevre üzerinde olumsuz etkilere neden olabilecek özel ekipman ihtiyacı gibi ilgili maliyetlere de sahip olabilmektedir (Arnó ve Gabarra, 2011).

Dolaylı maliyetler de zararlı yönetiminde önemli bir endişe kaynağıdır. Dolaylı maliyetler, zararlı hasarı nedeniyle hem korunan hem de açık tarla domates mahsullerinde bitkilerin fotosentetik kapasitesinin ve üretim seviyelerinin azalmasını içerebilir (Garzia vd., 2012). Ayrıca, enfeste olmuş bitki ve meyve dokularında ikincil enfeksiyonlar gelişebilir ve ek kayıplara yol açabilir (Garzia vd., 2012). Bu dolaylı maliyetlerin ekonomik etkisi, toplam verimi ve domates mahsulünün kalitesini daha da azaltabileceği için önemli olabilmektedir.

Zararlı kontrolü için yapılan yatırımlar da çiftçilere mali yükler getirebilir. Bu yatırımlar, zararlı kontrol ürünlerinin satın alınmasını, zararlı izleme sistemlerinin uygulanmasını ve entegre zararlı yönetimi stratejilerinin benimsenmesini içermektedir. Entegre zararlı yönetimi, zararlı hasarını en aza indirmek ve kimyasal kontrolü azaltmak için biyolojik kontrol, kültürel uygulamalar ve böcek ilaçlarının ölçülü kullanımı gibi birden fazla zararlı kontrol yöntemini kullanmayı içerir (Chailleux vd., 2012). Bu yatırımlar maliyetli olabilir, ancak zararlılar tarafından oluşturulan ekonomik kayıpları hafifletmek ve domates yetiştiriciliğinin verimliliğini ve karlılığını sürdürmek için gereklidir.

2.2. Öne Çıkan Zararlı Türlerinin Tespiti ve Domates Bitkisi Üzerindeki Etkileri

D. baccarum zararlısı, Hemiptera takımının ve Pentatomidae familyasının bir üyesidir. *B. tabaci* gibi diğer böceklerle beslenmesi, avantaj olarak görülse de domates bitkisinde önemli ekonomik kayba sebep olabilir. *D. baccarum*, meyveleri delerek ve gövdelerde ve çiçeklerde nekrotik halkalar oluşturarak domates bitkilerinde beslenir (Calvo vd., 2008). Bu beslenme davranışı, meyvenin kalitesinin ve veriminin düşmesine neden olabilir. *D. baccarum*'un varlığını tespit etmek ve domates bitkileri üzerindeki etkisini belirlemek için çeşitli yöntemler kullanılmıştır. Önerilen yöntemlerden biri, domates bitkisi hastalıklarının ve zararlılarının gerçek zamanlı tanıma için derin öğrenme tabanlı dedektörlerin kullanılmasıdır. Bu dedektör, domates bitkilerinde *D. baccarum*'un ve onun tarafından oluşturulan hasarın görüntülerini içeren büyük bir Domates Hastalıkları ve Zararlıları Veri Kümesi üzerinde eğitilmiş ve test edilmiştir (Fuentes vd., 2017). Bu yaklaşım, domates bitkilerinde zararlının varlığını otomatik ve doğru bir şekilde tespit edilmesine olanak tanır. *D. baccarum*'un varlığını tespit etmek için kullanılan diğer bir yöntem ise saha kafes çalışmalarının kullanılmasıdır. Bu çalışmalarda zararlılar kontrol altındaki ortamlara yerleştirilir ve davranışları ve domates bitkileri üzerindeki etkileri gözlemlenir. Bu yöntem, *D. baccarum* tarafından oluşturulan hasara ve diğer zararlılarla olan etkileşimlere dair değerli bilgiler sunar. Zararlı tespit yöntemlerine ek olarak, *D. baccarum*'un domates bitkileri üzerindeki etkisini anlamak için de çalışmalar yapılmıştır. Karışık yetiştiriciliğin, refakatçi bitkilerin kullanılmasıyla kiraz domateslerinin büyümesi ve kalitesi üzerindeki etkisini incelenmiştir (Lee vd., 2021).

Konukçu (Refakatçi) bitkilerin varlığının, *D. baccarum* ve diğer zararlılardan kaynaklanan hasarı azalttığını, böylece domates bitkilerinin büyümesinin ve kalitesinin arttığı bulunmuştur. Bu, refakatçi bitki ekiminin, *D. baccarum* tarafından oluşturulan hasarı hafifletmek için etkili bir strateji olabileceğini göstermektedir. Ayrıca, *D. baccarum*'un hasar görmüş domates bitkilerine olan ilgisini inceleyen çalışmalar da bulunmaktadır. Hasar görmüş domates bitkilerinin, *D. baccarum* ve diğer zararlıları çeken kimyasal sinyaller yayabileceğini belirttiler (Carrillo vd., 2019). Bu çekim mekanizmalarını anlamak, zararlının davranışını bozmak ve domates bitkileri üzerindeki etkisini azaltmak için stratejiler geliştirmeye yardımcı olabilir.

Toprak Pire Böcekleri (Coleoptera: Chrysomelidae) domates bitkilerine önemli zararlar verebilmektedir. Bu böcekler domates bitkisinin yaprak ve gövdeleri üzerinden beslenerek şekil bozukluğuna ve gelişiminin durmasına neden olabilmektedir (Gentile ve Stoner, 1968). Pire böceği tarafından verilen zararlar, özellikle bitki büyümesinin erken aşamalarında şiddetli olabilmektedir (Boavida vd., 2013). Böcekler büyüyen bitkilerin kotiledon'ları ve yaprakları üzerinden beslenerek üst katmanlara çıkar ve fotosentezi ciddi şekilde kısıtlar, bu da gelişiminin durmasına yol açar (Agegnehu vd., 2020). Doğrudan beslenme zararına ek olarak, pire böcekleri beslenme sırasında enfekte olmuş bitkilerden sağlam bitkilere bitki patojenlerini de taşıyabilir, bu da daha fazla zarara neden olabilmektedir (Toshova vd., 2009).

Toprak pire böceklerinin varlığını tespit etmek ve etkilerini belirlemek için çeşitli yöntemler kullanılmıştır. Yaygın bir yöntem olan görsel inceleme ile araştırmacılar beslenme zararının belirtileri ve erişkin böceklerin varlığı için bitkileri gözlemlemektedirler. Bir diğer yöntem olan yapışkan tuzaklar, erişkin böcekleri yakalayabilir ve popülasyonları hakkında bilgi sağlayabilir (Cárcamo vd., 2008). Bazı çalışmalarda araştırmacılar, pire böceklerini çekmek ve tuzağa düşürmek için bitki uçucularını kullanmışlardır, bu da popülasyonun izlenmesi ve zararın değerlendirilmesi için olanak tanımaktadır (Wan vd., 2022). Ek olarak, araştırmacılar, pire böceklerinin farklı türlerini tanımlamak ve ayırt etmek için genetik teknikler kullanmışlardır (Boavida vd., 2013).

Yapılan bazı çalışmalarda, toprak pire böceklerinin domates bitkileri üzerindeki etkisinin çeşitli faktörlere bağlı olarak değişebileceği bulunmuştur. Örneğin, hardal yağı gibi tuzak bitkilerin kullanılmasının, pire böceği popülasyonlarını yönetmede ve ana mahsullere verilen zararı azaltmada etkili olduğu tespit edilmiştir (George vd., 2019). Bitki genotipleri de pire böcekleri ile domates bitkileri arasındaki etkileşimleri etkileyebilir. Farklı mum ağacı genotiplerinin pire böceği zararına karşı değişen direnç seviyeleri gösterdiği belirlenmiştir, bu da bitki genetiğinin pire böceklerinin etkisini belirlemede bir rol oynadığını göstermektedir (Li vd., 2016). Yönetim stratejileri açısından, çeşitli yaklaşımların araştırıldığı görülmektedir. Yaygın bir yöntem olan insektisitlerin kullanımı, pire böceği popülasyonlarını etkili bir şekilde kontrol edebilir ve domates bitkilerine verilen zararı azaltabilir (Tansey vd., 2009). Ancak, insektisit kullanımının olumsuz çevresel etkileri olabilir ve pire böceklerinde insektisit direncinin gelişmesine yol açabilir (Tansey vd., 2009). Bu nedenle ara bitki yetiştiriciliği ve kültürel uygulamalar gibi alternatif yöntemler araştırılmıştır. Hardal yağı gibi tuzaklar, pire böceklerini bitkisel ürünlerden uzaklaştırabilir, zararı azaltabilir (George vd., 2019). Domates bitkilerini diğer mahsullerle, örneğin börülce veya bamya ile, ara ekim yaparak pire böceklerinden kaynaklanan zarar da azaltabilir (Pitan ve Olatunde, 2006). Ayrıca, ekim tarihlerini ve bitki yoğunluğunu ayarlamak gibi kültürel uygulamalar, pire böceği popülasyonlarını yönetmeye ve zararı en aza indirmeye yardımcı olabilir (Doddall ve Stevenson, 2005).

Yaprak biti (Hemiptera: Aphididae) zararlısı, domates bitkilerinde ekonomik açıdan önemli kayıplara neden olabilmektedir. Yaprak bitleri, domates bitkilerini istila eden başlıca tarım zararlılarıdır (Digilio vd., 2010). Beslenme aktiviteleriyle ve fitopatojenik virüsleri taşıyarak zarara yol açabilmektedirler (Digilio vd., 2012). Yaprak bitleri, domates bitkisinin öz suyunu emerler, bu da büyümenin durmasına, solmaya ve yaprakların sararmasına neden olabilmektedir (Riedell ve Kieckhefer, 1995). Ayrıca yaprakların şekil değiştirmesine, kıvrılmasına, gallerin ve nekrotik lekelerin oluşumuna da yol açabilmektedirler (Avila vd., 2012).

Yaprak bitlerinin varlığını tespit etmek ve etkilerini belirlemek için çeşitli yöntemler kullanılmıştır. Bir yaklaşım, domates bitkilerindeki bitki bitlerinin davranışını ve beslenme alışkanlıklarını incelemektir. Örneğin, Avila ve diğerleri (2012) domates bitkilerinde belirli bir genin antisens baskılanmasının yaprak biti istilasını azalttığını tespit etmiştir, bu da bu genin yaprak biti direncindeki önemini göstermektedir. Benzer şekilde, Digilio ve diğerleri (2012), domatesin uçucu organik bileşikleri (VOCs) ile yaprak biti davranışı arasındaki etkileşimleri araştırmışlardır. Yaprak biti istilasından sonra domates bitkileri tarafından salınan belirli VOC'ların, yaprak biti kabulünü ve beslenme davranışını değiştirdiğini belirlemişlerdir. Bir diğer yaklaşım, yaprak biti istilasının domates bitkileri üzerindeki etkilerini incelemektir. Stout ve diğerleri (1997), domates yaprağında indüklenmiş direncin belirleyicisi olan polifenol oksidaz aktivitelerinin, yaprak bitleri tarafından zarar görmüş yapraklarda azaldığını tespit etmiştir. Bu polifenol oksidaz aktivitesindeki azalma, yaprakların yaprak bitleri için artan uygunluğuna kısmen neden olabilir. Ayrıca, Sasso ve diğerleri (2007) bir yaprak biti parazitoitin domates bitki uçucularına olan elektrofizyolojik ve davranışsal tepkilerini incelemişlerdir. Domates bitkileri tarafından salınan belirli bileşiklerin parazitoiti çektiğini ve bu sayede yaprak biti popülasyonunu azaltmaya yardımcı olabileceğini tespit etmişlerdir.

Araştırmacılar, domates bitkilerinde yaprak biti istilasını tespit etmek için kimyasal ve elektronik yöntemlerin kullanılmasını da araştırmışlardır. Cui ve diğerleri (2019), yaprak biti stresi altındaki domates bitkilerinin erken aşama tanısına yönelik hızlı bir elektronik burun sistemi geliştirmişlerdir. Bu sistem, yaprak biti istilasından sonra domates bitkileri tarafından salınan uçucu organik bileşiklerdeki değişiklikleri tespit etmiştir, bu da yaprak bitlerini hızlı ve tahrip olmayan bir yöntemle tespit etme olanağı sağlamaktadır. Ek olarak, Sasso ve diğerleri (2009) bir yaprak biti zararlısının domates bitki uçucularına olan elektrofizyolojik ve davranışsal tepkilerini incelemişlerdir. Domates bitkileri tarafından salınan belirli bileşiklerin zararlıyı çektiğini ve bu sayede yaprak biti popülasyonunu kontrol etmeye yardımcı olabileceğini belirlemişlerdir. Bu çalışmalardan elde edilen bulgulara göre, domates bitkilerinin yaprak biti istilasına karşı çeşitli savunma mekanizmaları sergilediği görülmektedir.

Avila ve diğ erleri (2012), domates bitkilerinde belirli bir genin fonksiyonunun kaybının salisilik asidin etkisiyle bazal yaprak biti direncini arttırdığını tespit etmiştir. Bu, salisilik asidin domates bitkilerinin yaprak bitilere karşı savunma tepkisinde bir rol oynadığını göstermektedir. Digilio ve diğ erleri (2012) domates bitkilerinin, bitki bitleri tarafından istila edildiğinde yeni uçucu bileşikler saldıgını ve belirli terpen bileşiklerinin konsantrasyonunu değıştirdiğini belirlemiştir. Bu uçucu bileşiklerdeki değışiklikler, yaprak bitilerinin doğal düşmanlarını çekmeye veya yaprak bitilerini kendilerinden uzaklaştırmaya yardımcı olabilir. Ayrıca, araştırmacılar yaprak biti istilasının diğ er zararlılara ve domates bitkilerinin genel sağığına olan etkisini de araştırmışlardır. Tan ve diğ erleri (2014), domates bitkilerinde yeşil şeftali bitinin (*M. persicae*) istilasının tatlı patates beyaz uçağının (*B. tabaci*) yerleşme davranışını ve pop lasyon dinamiğini nasıl etkilediğini incelemişlerdir. Yaprak biti istilasısı, beyaz uçların davranışını ve gelişimini etkilemiştir, bu da domates ürünlerinde her iki zararlının yönetimi için sonuçları olabileceğini göstermektedir. Ek olarak, Ni ve diğ erleri (2001) yaprak bitilerinin buğday bitkilerini beslemesinin enzimatik klorofil katabolizmasını nasıl değıştirdiğini belirlemiştir, bu da klorozise ve azalan bitki büyümesine yol açmaktadır.

B. tabaci (Hemiptera: Aleyrodidae), yaygın olarak beyazsinek olarak bilinmekte olup, domates bitkilerine önemli zararlar verebilmektedir. Bu zararlı, tropikal ve subtropikal habitatlarda geniş bir yayılış göstermekte ve dünya genelinde yaygın bir tarım zararlısı olarak bilinmektedir (Pan vd., 2012). *B. tabaci*'nin, Tomato yellow leaf curl vir s  (TYLCV) da dahil olmak  zere çeşitli bitki vir slerini bulaştırdığı bilinmektedir (Caciagli vd., 1995; Czosnek vd., 2002; Pan vd., 2012; Cañizares vd., 2014; Moreno-Delafuente vd., 2013; Liu vd., 2013; Su vd., 2016). TYLCV, domates bitkilerine ciddi zararlar veren bir begomovir s't r (Su vd., 2016; Pan vd., 2012; Cañizares vd., 2014). Çin'deki TYLCV'nin hızlı yayılımı, ana vekt r olan *B. tabaci* tarafından kolaylaştırılmıştır (Pan vd., 2012; Liu vd., 2013). *B. tabaci*'nin domates bitkilerine verdiğı zarar  ok y nl d r. Beyazsinek nimflerinin ve erginlerinin beslenme aktiviteleri,  z suyu ve besin maddelerini  ekerek bitkilere doğırudan zarar verebilir, bu da gelişmenin durmasına, solmaya ve yaprakların sararmasına neden olabilir (Kakimoto vd., 2007; Fernandes vd., 2011).

Beyazsinekler ayrıca balözü salgılamakta olup, bu da isli küfün büyümesini teşvik edebilir ve karıncaları çekebilir, bu da bitkilerin sağlığını daha da tehlikeye atabilir (Kakimoto vd., 2007). Ek olarak, *B. tabaci*, TYLCV dahil olmak üzere bitki virüsleri için bir vektör olarak hizmet edebilir ve bu da domates ürünlerinde önemli verim kayıplarına neden olabilir (Su vd., 2016; Pan vd., 2012; Cañizares vd., 2014).

B. tabaci'nin varlığını tespit etmek ve domates bitkileri üzerindeki etkisini değerlendirmek için çeşitli yöntemler kullanılmıştır. Bir yaklaşım, beyazsineğin farklı konukçu bitkilerdeki performansını ve davranışını değerlendirmektir. Araştırmalar, *B. tabaci*'nin konukçu bitki tercihleri gösterdiğini, patlıcan, salatalık ve tütün gibi belirli bitkilerin pamuk ve domatesten daha çok tercih edildiğini ortaya koymuştur (Tian vd., 2020; Shah ve Liu, 2013). Bu bilgi, beyazsinek istilalarının dinamiklerini anlamada ve etkili kontrol stratejileri tasarlamada yardımcı olabilir. Başka bir yaklaşım, *B. tabaci*, domates bitkileri ve bitki virüsleri arasındaki etkileşimleri incelemektir. Araştırmacılar, Tomato yellow leaf curl virüsü (TYLCV)'nin domates konugu, *B. tabaci* ve diğer herbivorlar, örneğin iki benekli örümcek akarı arasındaki etkileşimlerin sonuçlarını nasıl etkilediğini incelemişlerdir (Su vd., 2016). Bu çalışmalar, TYLCV'nin bitki savunma yanıtlarını vektör ve vektör olmayan herbivorlara karşı farklı şekillerde etkileyebileceğini, beyazsinek, virüs ve bitki arasındaki karmaşık etkileşimleri ortaya koymaktadır.

B. tabaci'nin davranışını ve etkileşimlerini incelemenin yanı sıra, araştırmacılar farklı tespit yöntemlerinin kullanımını da araştırmışlardır. Örneğin, beyazsineklerin virüs taşıyan ve taşımayan domates bitkilerinde ne kadar süre kaldığı incelenmiştir. Bu, beyazsineklerin virüsle ne kadar etkileşimde olduğunu (yani virüs taşıyıp taşımadıklarını) belirlemek için yapılmıştır (Moreno-Delafuente vd., 2013). Bu yaklaşım, bitki virüsünü taşıyan beyazsineklerin toplanmasına olanak tanımakta olup, daha sonra daha ileri analiz ve tespit için kullanılabilir. Ayrıca, çeşitli biyopestisitlerin ve bitki türlerinin *B. tabaci*'yi uzaklaştırma ve yumurtlama yapmasını engellemedeki etkinliği değerlendirilmiştir (Wagan vd., 2017; Abdel-Razek vd., 2016; Diabaté vd., 2014). Bu araştırmalar, domates mahsullerinde beyazsinek istilalarını yönetmek için potansiyel çevre dostu kontrol önlemleri hakkında değerli bilgiler sağlamaktadır.

T. absoluta (Lepidoptera: Gelechiidae), domates yaprak güvesi olarak da bilinmekte olup, domates bitkilerine önemli zararlar veren oldukça yıkıcı bir zararlıdır (Desneux vd., 2010; Garzia vd., 2012; Cuthbertson vd., 2013; Illakwahhi ve Srivastava, 2017; Cherif ve Verheggen, 2019; Hoge, 2020; Zhang vd., 2021; Agboka vd., 2022). Güney Amerika kökenli olan bu zararlı, dünya genelinde, Avrupa, Asya, Afrika ve Akdeniz Havzası da dahil olmak üzere çeşitli bölgelere yayılmıştır (Seplyarsky vd., 2010; Desneux vd., 2011; Calvo vd., 2012; Azouz, 2016; Chidege vd., 2016; Dong vd., 2017; Perdakis vd., 2017; Yule vd., 2021; A vd., 2022;). *T. absoluta*'nın kontrol altına alınmazsa domates ürünlerine ciddi bir tehdit oluşturduğu ve ürün kayıplarını %100'e kadar çıkarabileceği belirtilmiştir (Eski, 2023). *T. absoluta*'nın neden olduğu zarar, özellikle beslenme davranışı ile ilişkilendirilmektedir. *T. absoluta*'nın larvaları, domates bitkisinin yapraklarına, gövdelerine ve meyvelerine girerek geniş bir doku hasarına yol açmaktadır (Garzia vd., 2012; Cuthbertson vd., 2013; Illakwahhi ve Srivastava, 2017; Cherif ve Verheggen, 2019; Hoge, 2020; Agboka vd., 2022). Larvalar, bitki dokuları içerisinde tüneller oluşturarak solma, nekroz ve azalmış bitki canlılığına neden olmaktadır (Garzia vd., 2012). Ayrıca, *T. absoluta* larvalarının beslenme aktivitesi, patojenlerin ikincil enfeksiyonlarına da yol açabilmekte, böylece zararı daha da arttırmaktadır (Garzia vd., 2012).

T. absoluta'nın varlığını tespit etmek ve etkisini değerlendirmek için çeşitli yöntemler kullanılmıştır. Yaygın olarak kullanılan bir yöntem, erişkin güveleri çekmek ve yakalamak için feromon tuzaklarıdır (Adilkhankyzy vd., 2022). Feromon tuzakları kullanarak *T. absoluta*'nın popülasyon dinamiğini izlemek, zararının bolluğu ve dağılımı hakkında değerli bilgiler sağlamaktadır (A vd., 2022). Ek olarak, larvaların ve galerilerin varlığı için bitkilerin görsel olarak incelenmesi de gerçekleştirilmiştir (Agboka vd., 2022; Cuthbertson vd., 2013; Garzia vd., 2012; Hoge, 2020; Illakwahhi ve Srivastava, 2017; Cherif ve Verheggen, 2019). *T. absoluta*'nın domates bitkilerine etkisi üzerine yapılmış birçok çalışma bulunmaktadır. Bu çalışmalar, *T. absoluta*'nın önemli ürün kayıplarına neden olabileceğini ve domates meyvelerinin kalitesini azaltabileceğini ortaya koymuştur (Agboka vd., 2022; Cuthbertson vd., 2013; Garzia vd., 2012; Hoge, 2020; Illakwahhi ve Srivastava, 2017; Cherif ve Verheggen, 2019).

T. absoluta'nın neden olduđu zarar, azalmış bitki büyümesine, meyve boyutunun azalmasına ve ikincil enfeksiyonlara karşı artan duyarlılığa yol açabilir (Garzia vd., 2012). Bazı durumlarda, *T. absoluta*'nın istilası tam bir ürün başarısızlığına yol açabilmektedir (Eski, 2023). Kontrol önlemleri açısından, *T. absoluta* istilalarını yönetmek için çeşitli stratejiler uygulanmıştır. Bunlar arasında kimyasal insektisitlerin kullanımı, biyolojik kontrol ajanları, kültürel uygulamalar ve entegre zararlı yönetimi yaklaşımları yer almaktadır (Urbaneja vd., 2012; Campos vd., 2019; Calvo vd., 2012; McNitt vd., 2019; Cocco vd., 2012; Calvo vd., 2016; Shiberu, 2017). Kimyasal insektisitler, *T. absoluta* popülasyonlarını azaltmada etkili olabilir, ancak direnç gelişimini en aza indirmek için kullanımları dikkatlice yönetilmelidir (Lietti vd., 2005; Dağlı vd., 2012; Siqueira vd., 2000). Parazitoit yaban arıları gibi biyolojik kontrol ajanları da *T. absoluta* için potansiyel kontrol seçenekleri olarak araştırılmıştır (Urbaneja vd., 2012; Campos vd., 2019; Calvo vd., 2016; Bodino vd., 2018). Ekin nöbeti ve sanitasyon gibi kültürel uygulamalar, *T. absoluta* istilalarının riskini azaltmaya yardımcı olabilir (Calvo vd., 2012; Hoge, 2020). Birden fazla kontrol stratejisinin birleştirildiği entegre zararlı yönetimi yaklaşımları, *T. absoluta* popülasyonlarını yönetmede başarılı olmuştur (Cocco vd., 2012).

L. decemlineata, aynı zamanda Colorado patates böceği olarak da bilinmekte olup, patates, patlıcan ve domates bitkilerine önemli zararlar verebilen oldukça yıkıcı bir böcek zararlısıdır (Kim ve Lan, 2011). Kuzey Amerika ve Avrupa'da solanaceous ürünlerinin en yıkıcı böcek zararlılarından biri olarak kabul edilmektedir (Kim ve Lan, 2011). *L. decemlineata*'nın hem larva hem de yetişkin evreleri bu bitkilere zarar verebilir ve doğru bir şekilde kontrol edilmezse, beslenmeleri solanaceous ürünlerinin tarla başarısızlığına yol açabilir (Clements vd., 2022). *L. decemlineata*'nın, bitki savunmalarını bastırmak için ağızla salgılanan bakteriyi kullandığı tespit edilmiştir (Chung vd., 2013). *L. decemlineata* larvalarının oral salgılarının mekanik olarak yaralanmış bitkilere uygulanması, yaralanmış ve su ile işlem görmüş bitkilere kıyasla domates ve patatesten uyarılan savunmaları bastırdığı gösterilmiştir (Chung vd., 2013). Bu salgılar, tomurcuk büyümesini artırarak bitkiye yarar sağlayan, domatesin salisilik asit sinyal yolunu indükleyen ve jasmonik asit aracılı savunmaları bastıran bir mikrobiyal makyaj olarak hizmet eden bakterileri içermektedir (Wang vd., 2017).

Böceğin oral salgılarındaki mikrobiyal simbiyontlar savunma bastırılmasında yer almaktadır (Zhu vd., 2014). Araştırmalar ayrıca *L. decemlineata*'nın domates bitkileri üzerindeki etkisini ve varlığını tespit etmek ve etkisini belirlemek için kullanılan yöntemleri incelemiştir. Domates bitkilerindeki trichomların, *L. decemlineata* da dahil olmak üzere artropod zararlıların caydırılmasıyla ilişkilendirildiği belirlenmiştir (Pandey vd., 2023). Bir yetiştirme sezonu boyunca patates çeşitlerinin foliar yağ asidi bileşimindeki farklılıkların, *L. decemlineata*'nın ev sahibi konum tercihini etkileyebileceği belirtilmiştir (Clements vd., 2022). Trichomların *L. decemlineata*'ya karşı savunmadaki rolü incelenmiştir ve trichomlara sahip domates bitkilerinin, *L. decemlineata* büyümesini etkileyen indüklenen savunmaları tetiklediği bulunmuştur (Chung ve Felton, 2011). Patates bitkilerinin yaprak yüzey bileşiklerinin, *L. decemlineata*'nın beslenmesini etkilediği tespit edilmiştir (Szafrank vd., 2008).

L. decemlineata'nın varlığını tespit etmek için, çalışmalar çeşitli yöntemler kullanarak gerçekleştirilmiştir. α -mangostin'in *L. decemlineata* larvalarına karşı larvisidal aktivitesi test edilmiştir (Kim ve Lan, 2011). Bitki özütlerinin *L. decemlineata*'nın farklı larval evrelerine temas toksisitesi de araştırılmıştır (Alkan vd., 2017). Ayrıca, *L. decemlineata*'nın domates bitkilerinde larva hayatta kalma ve büyümesini anlamak için genetik analizler gerçekleştirilmiştir (Lu ve Kennedy, 2001).

N. viridula, yaygın olarak güney yeşil kokarca böceği olarak bilinmekte olup, domates bitkilerine ve diğer önemli gıda ürünlerine önemli zararlar verebilen son derece polifag bir zararlıdır (Ewunkem vd., 2020). Bu zararlı, Pentatomidae familyasına aittir ve birçok bitki türünde beslenebilme yeteneğiyle bilinmektedir (Musolin, 2012). *N. viridula* tarafından domates bitkilerine verilen zarar, verimde ve ürün kalitesinde azalmaya yol açabilir (Ewunkem vd., 2020). *N. viridula*'nın domates bitkilerine zarar verme yollarından biri beslenme davranışdır. Bu zararlı, bitki dokusunu delmek ve bitkiden öz suyunu çıkarmak için kullandığı delici-emici ağız parçalarına sahiptir (Depieri ve Panizzi, 2011). *N. viridula*'nın beslenme aktivitesi, domates bitkisinin yapraklarında ve meyvelerinde nekrotik bölgelerin oluşmasına neden olabilir (Depieri ve Panizzi, 2011). Ek olarak, *N. viridula*'nın tükürüğü, doku hasarına daha da katkıda bulunabilecek proteazlar ve nükleazlar içermektedir (Lomate ve Bonning, 2016).

N. viridula'nın varlığını tespit etmek ve etkisini değerlendirmek için çeşitli yöntemler kullanılmıştır. Bir yaklaşım, *N. viridula*'nın popülasyon yoğunluğunu izlemek için cazibesiz tuzakların kullanılmasıdır (Haseeb vd., 2018). Bu tuzaklar, bu zararlının bolluğunu belirlemeye ve belirli bir alandaki dağılımı hakkında bilgi sağlamaya yardımcı olabilir (Haseeb vd., 2018). Diğer bir yöntem ise *N. viridula*'nın nimflerinin ve yetişkinlerinin varlığı için bitkilerin görsel olarak incelenmesidir (Athey vd., 2019). Ek olarak, araştırmacılar, *N. viridula*'nın gen ifadesini ve nöropeptidomiklerini incelemek için RNA dizilemesi ve proteomik gibi moleküler teknikleri kullanmışlardır (Lavore vd., 2018). *N. viridula* üzerine yapılan çalışmalar, domates bitkileri üzerindeki etkisi hakkında çeşitli bulguları ortaya koymuştur. Örneğin, araştırmalar, *N. viridula*'nın beslenme aktivitesinin soya fasulyesi tohumlarına yüzeysel ve derinlemesine zarar verebileceğini göstermiştir (Depieri ve Panizzi, 2011). *N. viridula*'nın soya fasulyesi tohumlarında beslenme süresi de incelenmiştir ve daha uzun beslenme sürelerinin daha ciddi zararlara yol açabileceği bulunmuştur (Depieri ve Panizzi, 2011). Ayrıca, çalışmalar, *N. viridula*'nın domates bitkilerinin doğrudan savunma tepkisini etkileyebileceğini ve zararlının varlığının, bitki savunma mekanizmalarında yer alan genlerin ifadesinde değişikliklere yol açabileceğini göstermiştir (Alınç vd., 2021).

L. bryoniae (Diptera: Agromyzidae), yaygın olarak yaprak galeri sineği olarak bilinmekte olup, domates bitkilerine önemli zararlar verebilmektedir. Bu zararlı, hastalıkların vektörü olarak işlev görmesi, genç fidanların yok edilmesi, ürün verimlerinin azaltılması, gelişmekte olan domateslerin üstünde yaprak dökümünün hızlanması (bu, meyvede "güneş yanığı"na neden olabilir), süs bitkilerinin estetik değerlerinin azaltılması ve bazı bitki türlerinin karantinaya alınmasını içeren birçok şekilde ürünlere etki etmektedir (Parrella, 1987). Bu zararlı, dünyanın tropikal ve astropikal bölgelerinde üretimin miktar ve kalitesinde önemli kayıplara neden olan, domates, fasulye, patlıcan, patates, kişniş ve süs bitkileri dahil olmak üzere çeşitli sebze ürünlerine saldıran en önemli böcek zararlılarından biri olarak kabul edilmektedir (Baker ve Hassan, 2019).

L. bryoniae'nin varlığını tespit etmek ve etkisini belirlemek için çeşitli yöntemler kullanılmıştır. Bir çalışmada, bir olfaktometre kullanılarak *L. bryoniae*'nin konuk bitki koku tercihleri incelenmiş ve bu zararlının domates bitkilerine olan ilgisini ortaya koymuştur (Radžiutė ve Būda, 2012). Başka bir çalışma, İtalya'daki marul yetiştiriciliği sistemlerinde *L. huidobrensis*'in ilişkili türlerden ayrılması için polimeraz zincir reaksiyonu-kısıtlama parça uzunluğu polimorfizmi testlerini kullanmıştır (Masetti vd., 2006). Ek olarak, araştırmacılar *L. bryoniae*'nin kontrolünde kimyasal pestisitlerin ve biyopestisitlerin etkinliğinin laboratuvar değerlendirmelerini yapmışlardır (Baker ve Hassan, 2019). Ayrıca, *Liriomyza* spp.'nin domates bitkileri üzerindeki etkisi ve verim çıktısı üzerine çalışmalar yapılmıştır. Nijerya'da yapılan bir deney, *Liriomyza* spp.'nin domates bitkilerine verdiği zararın seviyesini değerlendirmiştir ve bu zararlının domates çeşidi UC82B'nin verim çıktısını önemli ölçüde etkilediğini bulmuştur (Mustapha vd., 2021). Başka bir çalışma, Japonya'da ticari olarak yetiştirilen domates bitkilerini istila eden *Liriomyza* yaprak galerilerinin tür bileşimini incelemiş ve *L. sativae*, *L. trifolii* ve *L. bryoniae*'nin mevcut olduğunu bulmuştur (Abe ve Kawahara, 2001). Ayrıca, Kyoto Eyaleti, Japonya'da ticari olarak yetiştirilen domates bitkilerinde *L. sativae*, *L. trifolii* ve *L. bryoniae*'nin bir arada yaşaması üzerine araştırmalar yapılmıştır (Tokumaru vd., 2007). Zararlı yönetimi açısından, bir çalışma *L. bryoniae* yaprak galeri sineği için kairomon cazibelerinin kullanımını incelemiş ve sentetik metil salisilatın (MeSa) bu zararlı için cazip olduğunu bulmuştur (Būda ve Radžiutė, 2008). Başka bir çalışma, domateslerin ciddi zararlıları olan *L. trifolii* ve *L. bryoniae*'nin kontrolü için *Gronotoma micromorpha* parazitoidinin kullanılmasını incelemiştir (Abe, 2006). Ek olarak, yan yana dikilmiş domates ve kerevizde *Liriomyza* türlerinin ve ilişkili parazitlerin konuk seçimi üzerine araştırmalar yapılmıştır (Zehnder ve Trumble, 1984).

Trips'ler (Thysanoptera: Thripidae) domates bitkilerine ciddi ekonomik kayıplar verebilen önemli zararlılardır. Bitkilerin yapraklarına ve çiçeklerine beslenmenin yanı sıra Domates benekli solgunluk virüsü (TSWV) ve Yerfıstığı tomurcuk nekroz virüsü (GBNV) gibi yıkıcı virüsleri de bulaştırabilmektedirler (Srinivasan vd., 2018; Chaisuekul vd., 2003). Trips'lerin beslenme hasarı, gelişmenin durdurulması, yaprakların bozulması ve meyve kalitesi ile verimin azalmasına neden olabilmektedir (Escobar-Bravo vd., 2017). Ayrıca, trips'ler virüs hastalıklarının yayılmasını kolaylaştırarak domates bitkilerinin sağlığına ve verimliliğine dolaylı zararlar verebilmektedir (Jones, 2005).

Trips'lerin varlığını tespit etmek ve domates bitkileri üzerindeki etkilerini değerlendirmek için çeşitli yöntemler kullanılmıştır. Bir yaklaşım, tarlada yerleştirilen tuzaklar veya yapışkan kartlar kullanarak trip popülasyonlarını izlemektir. Bu tuzaklar, trips'leri çekip yakalayarak araştırmacıların popülasyon yoğunluklarını tahmin etmelerine ve aktivitelerini zamanla izlemelerine olanak tanımaktadır (Csizinszky vd., 1995). Başka bir yöntem, trip istilasının belirtileri olan beslenme hasarı, bozulmuş yapraklar veya trip'lerin kendisinin varlığı için bitkileri görsel olarak incelemektir (Escobar-Bravo vd., 2017). Bazı çalışmalarda, araştırmacılar, domates bitkilerinde trip tarafından bulaştırılan virüslerin varlığını tespit etmek için PCR gibi moleküler teknikler kullanmışlardır (Marchoux vd., 1991).

Birçok çalışma, trips'lerin domates bitkileri üzerindeki etkisini araştırmış ve değerli bulgular sağlamıştır. Örneğin, bir çalışma, Batı çiçek trips'i (*Frankliniella occidentalis*) ile domates bitkilerinin istila edilmesinin, türdaşlarının otlatma kararları için konuk bitkinin uygunluğunu değiştirdiğini bulmuştur (Escobar-Bravo vd., 2017). Başka bir çalışma, *F. occidentalis* dahil olmak üzere çiçek trips'lerini yönetmek için bir çek-çevir sisteminin etkinliğini değerlendirmiştir, bu zararlı dünya genelinde domatesin ciddi bir zararlısıdır. Çalışma, arkadaş bitkilerin UV yansıtıcı örtü ve kaolinle birleştirilmesinin trip popülasyonlarını baskılamada etkili olduğunu bulmuştur (Tyler-Julian vd., 2018).

Ayrıca, araştırmalar, trips'lerin Domates benekli solgunluk virüsü (TSWV) bulaşmasında önemli bir etkiye sahip olduğunu göstermektedir. Çalışmalar, trips'lerin TSWV'nin yayılmasında kritik bir rol oynadığını ve trip popülasyonlarını kontrol ederek virüsün yayılma oranının azaltılabileceğini göstermiştir (Jones, 2005). Ek olarak, TSWV'nin varlığı, trip'lerin beslenme davranışını ve yaşam tarihini etkileyerek domates bitkileri üzerindeki etkilerini daha da artırabilmektedir (Chen vd., 2014).

Kırmızı örümcek olarak adlandırılan zararlılar, domates bitkilerini yoğun bir şekilde istila edebilen ekonomik olarak önemli bir akar türüdür (Calvo vd., 2008; Godzina vd., 2011). Bu zararlı, domates bitkisinin yapraklarından beslenerek, bitki hücrelerinden özü emer ve bu, yapraklarda sarı lekelerin oluşmasına ve etkilenen dokunun ölümüne yol açmaktadır (Godzina vd., 2011). Ayrıca, akarlar ağ örmekte ve bu, fotosentezi engelleyerek ve bitkinin besinleri emme yeteneğini azaltarak bitkiye daha fazla zarar verebilmektedir (Godzina vd., 2011). Akarlar tarafından verilen hasar, domates bitkisinin belirli bölümleriyle sınırlı değildir, fakat bitkinin tamamını, yaprakları, apikal tomurcukları, gövdeleri, çiçekleri ve meyveleri de etkileyebilmektedir (Đurić vd., 2017). Bu zararlı, aynı zamanda patlıcan, patates, tütün ve muz gibi diğer mahsullerde de hasara neden olabilmektedir (Mamphogoro vd., 2020).

Akar varlığını tespit etmek ve etkisini belirlemek için çeşitli yöntemler kullanılmıştır. Bir yaklaşım, domates seralarında akar popülasyon dinamiklerini izlemektir (Sánchez, 2008). Diğer bir yöntem, akar yoğunluğunun, sıcaklığın ve nemin bitki beslenme yoğunluğuna etkisini analiz etmeyi içermektedir (Sánchez, 2008). Kontrollü koşullar altında laboratuvar deneyleri de avın varlığı, sıcaklık ve nem ile bitki beslenme yoğunluğunun belirlenmesi için gerçekleştirilmiştir (Sánchez, 2008). Bu çalışmalar, domates bitkileri üzerinde akar varlığını ve etkisini etkileyen faktörlere dair bilgiler sunmaktadır.

Popülasyon izleme ve laboratuvar deneylerine ek olarak diğer çalışmalar, akar ile diğer organizmalar arasındaki etkileşime odaklanmıştır. Örneğin, akarın *Nesidiocoris tenuis* tarafından avlanması incelenmiştir. *N. tenuis*, akar avlayabilmekte ve potansiyel olarak popülasyonunu azaltabileceği görülmüştür (Calvo vd., 2008). *N. tenuis* ve *Macrolophus pygmaeus* gibi genel avcılarının bir refakatçi bitki olan *Sesamum indicum* ile kombinasyonu, akarların biyolojik kontrolü için de incelenmiştir (Kouassi vd., 2021). Bu çalışmalar, doğal avcılarının ve refakatçi bitkilerin akar istilalarını yönetmedeki potansiyelini vurgulamaktadır. Ayrıca, akar istilalarını tespit etmek ve tanımlamak için moleküler teknikler kullanılmıştır. Örneğin, bir çalışma, akar istilalarıyla ilişkilendirilen yetiştirilen domates bitkilerindeki polimorfizmleri tanımlamak için oligonükleotid dizi analizi kullanmıştır (Sim vd., 2009). Bu yaklaşım, domates bitkilerinin akar duyarlılığına veya direncine katkıda bulunan genetik varyasyonlar hakkında değerli bilgiler sunabilir.

H. armigera (Lepidoptera: Noctuidae) zararlısı, aynı zamanda domates meyve kurdu veya pamuk meyve kurdu olarak da bilinmektedir, oburca beslenen bir zararlı olup, domates bitkilerine ekonomik açıdan önemli zararlar verebilmektedir (Pratissoli vd., 2015). Bu zararlı, yetiştirme sezonu boyunca doğrudan meyvelere zarar verdiği için domates mahsullerine büyük bir tehdit olarak kabul edilmektedir; bu durum verim kayıplarına neden olup, bu kayıplar %20 ila %60 arasında değişmektedir (Toffa vd., 2021). *H. armigera*'nın larvaları ekimden meyve olgunlaşmasına kadar domates mahsullerine saldırabilmekte ve büyüyen yapraklara ve meyvelere büyük zararlar verebilmektedir (Pratissoli vd., 2015). Larvaların beslenme davranışı, domates mahsullerinde önemli verim kayıplarına yol açabilmektedir (Manu ve Afun, 2021).

H. armigera'nın varlığını tespit etmek ve etkisini belirlemek için çeşitli yöntemler kullanılmıştır. Bu yöntemlerden biri, *Beauveria bassiana* gibi faydalı mantar izolatlarının kullanımıdır, bu mantarlar domates bitkilerini endofitik olarak kolonize edebilmekte ve *H. armigera* larvalarında yaprak hasarına neden olabilmektedir (Toffa vd., 2021). Bu yöntem, domates bitkilerinin *B. bassiana* ile aşılması ve *H. armigera* larvalarının neden olduğu hasarın gözlemlenmesini içermektedir.

Başka bir teknik ise, lepidopteran böceklerine, *H. armigera* dahil olmak üzere, karşı koruma sağlamak için domates bitkilerinin faydalı mantar izolatları ile aşılmasıdır (Toffa vd., 2023). Bu yöntem, bu mantarların *H. armigera* tarafından verilen hasarı önlemedeki etkinliğini değerlendirmeye izin vermektedir. Araştırmalar, *H. armigera*'nın domates mahsullerinde mevsimsel görülme sıklığına ve abiyotik faktörlerle ilişkisine de odaklanmıştır. Araştırmacılar, *H. armigera*'nın görülme sıklığı ile nispi nem ve hava koşulları gibi faktörler arasındaki ilişkiyi incelemiştir (Yadav vd., 2022; Wakil vd., 2010). Bu çalışmalar, istilanın paternleri ve çevresel faktörlerin domates tarlalarındaki *H. armigera* popülasyon dinamikleri üzerindeki etkisi hakkında bilgiler sunmaktadır. Bu yöntemlerin yanı sıra, araştırmacılar domates mahsullerinde *H. armigera*'yı kontrol etmek için farklı zararlı yönetimi modüllerinin etkinliğini değerlendirmiştir. Kültürel uygulamalar, biyolojik kontrol ajanları ve insektisitlerin dikkatli kullanımını bir araya getiren entegre zararlı yönetimi (IPM) modülleri, domates mahsullerinde *H. armigera* ve diğer zararlıların yönetimi için değerlendirilmiştir (Sharma vd., 2016; Abbas vd., 2015). Bu çalışmalar, *H. armigera*'nın neden olduğu hasarı azaltmada ve domates verimini artırmada farklı yaklaşımların etkinliğini değerlendirmektedir. Ayrıca, domates bitkilerinde *H. armigera* popülasyonları üzerinde pestisitlerin ve biyopestisitlerin etkisi üzerine çalışmalar yapılmıştır. Farklı insektisitlerin ve *Azadirachta indica* ve *Jatropha carcus* gibi bitkilerin sulu ekstraktlarının *H. armigera* ve diğer zararlılar üzerindeki etkisi incelenmiştir (Diabaté vd., 2014).

Bu çalışmalar, *H. armigera*'yı domates mahsullerinde yönetmek için biyopestisitlerin ve alternatif kontrol yöntemlerinin potansiyel kullanımı hakkında bilgiler sunmaktadır. Ev sahibi bitki direnci de domates mahsullerinde *H. armigera*'yı yönetme yöntemi olarak çalışılmıştır. Araştırmacılar, farklı domates erişimlerinin *H. armigera*'ya direncini değerlendirmiş ve dirençli çeşitlerin geliştirilmesine yardımcı olabilecek direnç faktörlerini belirlemiştir (Selvanarayanan ve Narayanasamy, 2006; Talekar vd., 2006). Bu çalışmalar, *H. armigera* hasarına daha az duyarlı domates çeşitlerinin geliştirilmesine katkıda bulunmaktadır. Bu tez çalışmasında değerlendirmeye alınan bilimsel araştırmalar Çizelge 2.1'de listelenmiştir.

Çizelge 2.1. Öne çıkan zararlı türlerin tespiti ve domates bitkisi üzerindeki etkileri kapsamında ele alınan çalışmaların yazarları ve zararlı türleri

Zararlı Böcek Türleri	Kaynaklar
<i>Bemisia tabaci</i>	(Caciagli vd., 1995; Czosnek vd., 2002; Kakimoto vd., 2007; Fernandes vd., 2011; Pan vd., 2012; Liu vd., 2013; Moreno-Delafuente vd., 2013; Cañizares vd., 2014; Diabaté vd., 2014; Abdel-Razek vd., 2016; Su vd., 2016; Wagan vd., 2017; Tian vd., 2020)
<i>B. argentifolii</i> <i>Trialeurodes vaporariorum</i>	(Calvo vd., 2008; Fuentes vd., 2017; Carrillo vd., 2019; Lee vd., 2021)
<i>Dolycoris baccarum</i>	(Calvo vd., 2008; Fuentes vd., 2017; Carrillo vd., 2019; Lee vd., 2021)
<i>Frankliniella occidentalis</i>	(Chaisuekul vd., 2003; Jones 2005; Heuvelink 2005; Chen vd., 2014; Escobar-Bravo vd., 2017; Srinivasan vd., 2018; Tyler-Julian vd., 2018)
<i>Helicoverpa armigera</i>	(Selvanarayanan ve Narayanasamy 2006; Talekar vd., 2006; Diabaté vd., 2014; Pratissoli vd., 2015; Toffa vd., 2021; Manu ve Afun 2021; Yadav vd., 2022; Wakil vd., 2010; Toffa vd., 2023)
<i>Leptinotarsa decemlineata</i>	(Szafraneck vd., 2008; Chung ve Felton 2011; Kim ve Lan 2011; Chung vd., 2013; Zhu vd., 2014; Wang vd., 2017; Alkan vd., 2017; Clements vd., 2022; Clements et ark. 2022; Pandey vd., 2023)
<i>Liriomyza bryoniae</i> <i>L. sativae</i> <i>L. trifolii</i>	(Abe ve Kawahara 2001; Abe ve Kawahara 2001; Masetti et ark. 2006; Abe 2006; Tokumaru vd., 2007; Būda ve Radžiūtė 2008; Radžiūtė ve Būda 2012; Baker ve Hassan 2019; Mustapha vd., 2021; Şahin ve Gençer 2022)
<i>Nezara viridula</i>	(Heuvelink, 2005; Depieri ve Panizzi 2011; Musolin 2012; Lomate ve Bonning 2016; Haseeb et ark. 2018; Athey et ark. 2019; Ewunkem vd., 2020; Alınç et ark. 2021)
<i>Phyllotreta</i> spp.	(Brelh vd., 2003; Dosdall ve Stevenson 2005; Pitan ve Olatunde 2006; Cárcamo vd., 2008; Tansey vd., 2009; Toshova vd., 2009; Boavida vd., 2013; Li vd., 2016; George vd., 2019; Agegnehu vd., 2020; Wan vd., 2022)
<i>Epitrix</i> spp.	(Estay, 2000; Lietti vd., 2005; Seplyarsky vd., 2010; Desneux vd., 2010; Desneux vd., 2011; Calvo vd., 2012; Cocco vd., 2012; Garzia vd., 2012; Urbaneja vd., 2012; Dong vd., 2017; Perdakis vd., 2017; Chidege vd., 2016; Azouz 2016; Shiberu 2017; Hoge 2020; Campos vd., 2019; McNitt vd., 2019; Calvo vd., 2016; Bodino vd., 2018; George vd., 2019; Yule vd., 2021; A vd., 2022; Adilkhankyzy vd., 2022; Agboka vd., 2022)
<i>Tuta absoluta</i>	
<i>Macrosiphum euphorbiae</i> <i>Myzus persicae</i> <i>Aphis gossypii</i>	(Riedell ve Kieckhefer 1995; Ni vd., 2001; Heuvelink, 2005; Sasso vd., 2007; Tan vd., 2014; Digilio vd., 2010; Digilio vd., 2010; Avila vd., 2012; Avila vd., 2012; Cui vd., 2019)
<i>Tetranychus urticae</i> <i>Aculops lycopersici</i>	(Heuvelink, 2005; Calvo vd., 2008; Sim vd., 2009; Sánchez 2008; Godzina vd., 2011; Đurić vd., 2017; Mamphogoro vd., 2020)

2.3. Yapay Zekâ ile Zararlı Tespiti ve Kullanılan Yöntemler

Tarımsal zararlı tespitinde görüntü işleme yöntemleriyle yapılan çalışmalar, tarım biliminde umut verici sonuçlar göstermiştir. Bu çalışmalar, zararlı görsellerini analiz etmek ve tespit için zararlı ile ilişkilendirilmiş özellikleri tanımlamak amacıyla bilgisayarlı görü tekniklerini ve görüntü işleme algoritmalarını kullanmaktadır (Wang vd., 2021). Görüntü işleme tekniklerinin zararlı tespitinde kullanılması, en üst düzeyde bitki koruması, geliştirilmiş bitki yönetimi ve artırılmış verimlilik gibi birçok avantaja sahiptir (Divya ve Santhi, 2023). Bir araştırma, görüntü işleme tekniklerini kullanarak otomatik bir zararlı izleme sistemi geliştirmeye odaklanmıştır ve hibrit FF-GWO-CNN algoritmasının kullanımı zararlıların doğru tespitini ve sınıflandırılmasını başarıyla sağlamıştır (Divya ve Santhi, 2023). Bu sistem, tarımsal ürün alanlarında iş gücünü azaltmayı ve zararlı tespitindeki hataları en aza indirmeyi hedeflemektedir. Otomatik olarak zararlıları tespit edip sınıflandırarak, bu sistem zararlı yönetim stratejilerine etkili bir şekilde katkıda bulunabilir. Başka bir çalışma, karmaşık doğal arka planlardaki zararlı tespit lambalarından elde edilen zararlı resim verisiyle bir zararlı veri kümesi olan Pest Rotation Detection (PRD21) oluşturmuştur (Zhang vd., 2022). Araştırmacılar, farklı hedef tespit algoritmalarını kullanarak görüntü tanıma üzerine karşılaştırmalı bir çalışma yürüttüler. Sonuçlar, döner tespit algoritmasının yatay tespit algoritmasına kıyasla ortalama Hassasiyeti %18,5 artırarak %78,5'e ulaştığını göstermiştir (Zhang vd., 2022). Bu, çeşitli doğal ortamlarda doğru zararlı tespiti için uygun algoritmaların kullanılmasının önemini vurgulamaktadır. Belirli ürünler bağlamında, bir çalışma, Mango zararlı tespitinde Whale Optimizasyon Algoritması ile Entropy-ELM (Extreme Learning Machine) kullanmaya odaklandı (Muthaiah ve Chitra, 2023). Araştırmacılar, ekonomik kayıpları azaltmak ve ürün kalitesini artırmak için bitki hastalıklarını erken aşamada tespit etmeyi hedeflediler. Görüntü işleme tekniklerini uygulayarak, etkili bir şekilde mango zararlılarını tespit edebileceği ve tarımsal üretimin genel yönetimine katkıda bulunabileceği belirlenmiştir (Muthaiah ve Chitra, 2023).

Derin öğrenme teknikleri, hindistancevizi ağaçlarında zararlı istilasının tanımlanmasında başarılı bir şekilde kullanılmıştır (Chandy, 2019). Fakat tarımsal zararlı tespitinde görüntü işleme yöntemlerini kullanırken, farklı modellerin etkinliği, tespit etmeyi amaçlanan belirli zararlılara göre önemli ölçüde değişebilir. Zararlıların morfolojik özellikleri, çevrelerinin karmaşıklığı ve eğitim verilerinin kalitesi gibi faktörler, bir modelin performansını etkileyebilir (Barbedo, 2019). Dahası, CNN'ler gibi çeşitli modellerin mimari nüansları, bazılarını karmaşık arka planlarda zararlıları tespit etmede daha yetenekli hale getirirken, diğerleri hız veya doğrulukta üstün olabilir (Ghosal vd., 2018; Mohanty vd., 2016). Derin öğrenmeye dayanan ileri tekniklerin, bu zorlukların üstesinden gelmede özellikle etkili olduğu gösterilmiştir (Kamilaris ve Prenafeta-Boldó, 2018). Zararlı tespitine yönelik tüm bu verileri dikkate aldığımızda, hedeflenen zararlıya yönelik hangi modelin veya yöntemin daha iyi performans göstereceğini tespit etmenin önemli olduğu görülmektedir (Amara vd., 2017).

YOLO (You Only Look Once) modeli, tarım başta olmak üzere farklı sektörlerde nesne tespitinde sıkça tercih edilmektedir. Bu modelin tarımsal bağlamda bitki zararlılarının tespitindeki başarısı üzerine birçok araştırma yapılmıştır. Faster R-CNN modeli de benzer bir amaçla tarımda zararlı tespit çalışmalarında değerlendirilmiştir. Bu çalışmalar genel olarak derin öğrenme yöntemlerini, zararlı ve hastalıkları etkin bir şekilde belirlemek ve sınıflandırmak için kullanmaktadır. DETR (DEtection TRansformer) gibi modellemeler, bitki zararlısı tespitinde yüksek başarı göstererek tarım teknolojisi alanında öne çıkmıştır. Özellikle MobileNet ve EfficientDet gibi evrimsel sinir ağı (CNN) temelli modeller, tarımda zararlı tanımda gösterdikleri başarıyla dikkat çekmektedir. Bunlar, tarım profesyonelleri için değerli araçlar haline gelmiştir. Tarımsal üretimde zararlıların erken tespiti, hastalıkların yayılmasını engelleme ve ürün kayıplarını minimize etme noktasında hayati öneme sahiptir. Son zamanlarda, bu konudaki çalışmaların odağını derin öğrenme modelleri oluşturmaktadır. Detectron2 gibi modeller, bu alandaki yenilikçi yaklaşımların örneklerinden biridir ve üzerinde gerçekleştirilen çalışmalar, bu modellerin etkinliğini doğrulamaktadır.

Ahmad ve diğerleri (2022) tarafından, YOLOv5, YOLOv3, YOLOR ve YOLO-Lite nesne tespit mimarileri kullanılarak böcek zararlılarının tespiti için bir çalışma yapılmıştır. 23 farklı türdeki böcek zararlılarını tanımlamak amacıyla RGB dijital görüntü/video kullanılmıştır. Bu çalışmanın amacı, farklı YOLO sürümlerinin böcek zararlılarını tespit etmedeki performanslarını karşılaştırmaktır. Sonuçlar, YOLOv5 sürümünün böcek zararlılarını tanımlamada etkili olduğunu göstermiştir. Luo (2023) tarafından, tarımsal zararlı tespiti için YOLO tabanlı bir hedef tespit algoritması önerilmiştir. Model, 200 epoch boyunca eğitilmiş ve %95,23 ortalama doğruluk oranı (mAP) ile en iyi model belirlenmiştir. Bu algoritma, yaygın tarımsal zararlıları tanımlamada yüksek bir başarı oranı göstermiştir. Zhang ve diğerleri (2022) tarafından, AgriPest-YOLO adında hızlı bir ışık tuzağı tarım zararlısı tespit yöntemi geliştirilmiştir. Bu yöntemin performansı, 24 sınıf ve 25.000 görüntü içeren büyük ölçekli bir veri kümesi üzerinde değerlendirilmiştir. Deneysel sonuçlara göre, AgriPest-YOLO, Faster RCNN, Cascade RCNN, Dynamic RCNN, YOLOX ve YOLOv4 gibi klasik tespit modellerini aşarak yüksek doğrulukla gerçek zamanlı zararlı tespiti gerçekleştirmiştir. Ayrıca, Mobilenetv3-YOLOv4, YOLOv5 ve YOLOv4-tiny gibi hafif tespit modelleriyle karşılaştırıldığında doğruluk ve hız açısından daha dengeli bir performans göstermiştir. Sozzi ve diğerleri (2022) tarafından, beyaz üzüm çeşitlerinde otomatik salkım tespiti için YOLOv3, YOLOv4 ve YOLOv5 modelleri kullanılmıştır.

Tian ve diğerleri (2019) tarafından yapılan bir çalışmada, CycleGAN ve YOLOV3-Dense modelleri kullanılarak derin öğrenme yöntemleriyle bahçelerde elma lezyonlarının tespiti üzerine odaklanılmıştır. Araştırmacılar, elma bahçelerinde zararlı tespitinin doğruluğunu artırmayı amaçlamışlardır. Bu çalışma doğrudan Faster R-CNN modelini kullanmamış olsa da tarımda zararlı tespiti için derin öğrenme tekniklerinin uygulanmasını göstermesi bakımından ilgili ve önemlidir.

Fuentes ve diğerleri (2021) tarafından yapılan bir diğer çalışmada, tarım ürünlerinde dokuz farklı zararlı ve hastalığın tespiti için Faster R-CNN modelinin geliştirilmiş bir versiyonu kullanılmıştır. Bari ve diğerleri (2021) tarafından ölçekli zararlı tespiti için akıllı telefon tabanlı bir uygulama geliştirilmiştir. Bu çalışma yalnızca Faster R-CNN modeline odaklanmamış, ancak zararlı tespiti için nesne tespit tekniklerinin kullanılmasını incelemiştir. Araştırmacılar, bitkilerde zararlıları tespit etmek için derin

öğrenme tekniğini Faster R-CNN modeli ve diğer yöntemlerle birleştirmişlerdir. Bu çalışma, tarım ortamlarında zararlı tespiti için nesne tespit tekniklerinin, Faster R-CNN modeli de dahil olmak üzere, potansiyelini göstermektedir. Prabha ve diğerleri (2022) tarafından, Faster R-CNN modelini de içeren derin öğrenme tabanlı çerçeveleri kullanarak pirinç yaprağı hastalığının gerçek zamanlı teşhisine yönelik bir yaklaşım önerilmiştir. Araştırmacılar, domates bitkilerindeki farklı hastalık ve zararlı türlerini tanımada üç mimarinin, yani Faster R-CNN, Bölge Temelli Tam Evrişimli Ağ (R-FCN) ve Single Shot Multibox Detecto (SSD) performansını karşılaştırmışlardır. Bu çalışma, belirli ürünlerde Faster R-CNN modelinin zararlı tespiti için etkinliği hakkında bilgi sağlamaktadır.

Li ve Wang (2021) tarafından bitki hastalıkları ve zararlı tespiti için derin öğrenmenin kullanıldığı çalışmalar üzerine kapsamlı bir inceleme yapılmıştır. Bilgisayar görüşünde nesne tespit ağlarının artan uygulamasına vurgu yapılmıştır. Yazarlar, DETR modeli gibi nesne tespit modellerindeki ilerlemelerle bitki zararlı tespitinde daha fazla iyileşme olacağını öne sürmüşlerdir. Li ve diğerleri (2022) tarafından, DETR modelinin hafif bir varyantı olan L-DETR modeli önerilmiştir. Bu model, manuel son işlem adımlarına ihtiyaç duymadan uçtan uca nesne tespitini mümkün kılan dönüşüm mekanizmalarını kullanmaktadır. Yazarlar, nesne tespit görevlerinde sınıflandırma ve yerelleştirme önemine dikkat çekmişler ve L-DETR'yi bitki zararlı tespiti için etkili bir çözüm olarak sunmuşlardır.

Biró ve diğerleri (2022) tarafından DETR modeli birkaç varyasyonla incelenmiş ve YOLO4 ve Detectron2 gibi diğer gerçek zamanlı nesne dedektörleriyle karşılaştırılmıştır. Araştırmaları, görsel metinsel öğelerin yerelleştirilmesine odaklanmış ve DETR modelinin optik karakter tanıma (OCR) teknikleriyle birleştirilmiş işbirlikli çözümlerdeki potansiyeline dikkat çekmiştir.

Chen ve diğerleri (2021) tarafından, tarım alanlarındaki ölçek zararlılarının tespiti için özel olarak tasarlanmış bir yapay zekâ tabanlı zararlı tespit sistemi önerilmiştir. Zararlıların resimlerde tespiti ve yerelleştirilmesi için Faster R-CNN, SSD ve YOLO v4 gibi derin öğrenme temelli nesne tespit modelleri kullanılmıştır. Bu çalışma, akıllı telefon tabanlı teknoloji kullanarak bitki zararlı tespiti için nesne tespit yöntemlerinin pratik

uygulamasını göstermektedir. Sun ve diğerleri (2023) tarafından, uzun sıralı global özellikleri çıkarmak için Swin-Dönüştürücü'nün avantajları tartışılmış ve DETR modelinin son işlem yapmadan doğrudan pozisyon koordinatları ve nesne kategorilerini nasıl oluşturabildiğine dikkat çekilmiştir. Araştırmaları yoldaki çatlak tespitine odaklanmasına rağmen, DETR modelinin tespit çerçevesi hakkında sağladıkları içgörüler, bitki zararlı tespiti uygulaması için de geçerlidir.

Prabha ve diğerleri (2022) tarafından yürütülen bir çalışmada, *Spodoptera frugiperda* bulaşmış mısırı tanımak için bir Android uygulamasının geliştirilmesine odaklanılmıştır. Araştırmacılar, MobileNet modelini Tamil Nadu Tarım Üniversitesi Entegre Zararlı Yönetimi (IPM) kapsülleriyle bir araya getirerek kullanmışlardır. Uygulama, çiftçilere mısır ürünlerinde *S. frugiperda* larvalarının istilasını kolayca tespit etme ve yönetme imkânı sunmuştur. Çalışma, tarımsal ortamlarda zararlıları doğru bir şekilde tanıma ve sınıflandırmada MobileNet modelinin etkinliğini göstermiştir. Selvaraj ve diğerleri (2019) tarafından yapılan başka bir çalışmada, muz hastalıkları ve zararlı tespiti için farklı CNN modellerinin, MobileNetV1, ResNet50 ve InceptionV2 dahil, performansları karşılaştırılmıştır. Sonuçlar, ResNet50 ve InceptionV2 modellerinin, çoğu durumda %90'ın üzerinde bir doğrulukla, MobileNetV1 modelini geride bıraktığını göstermiştir. Bu bulgular, MobileNetV1'in mobil uygulamalar için uygun hafif bir model olmasına rağmen, muz zararlı tespiti gibi belirli görevler için diğer mimarilerin daha iyi doğruluk sağlayabileceğini öne sürmektedir. EfficientDet, nesne tespit görevlerinin hızını ve doğruluğunu optimize etmek için geliştirilmiştir.

Yang ve Yu (2021) tarafından tanıtılan bir modeldir. Bu model, EfficientDet D0'dan EfficientDet D7'ye kadar sekiz model yapısından oluşmaktadır. Model, medikal görüntü analizi ve trafik işareti tespiti de dahil olmak üzere çeşitli alanlarda yaygın olarak kullanılmıştır. Tarımda bitki zararlı tespiti için doğrudan EfficientDet'in uygulandığı belirli çalışmalara rastlanmamış olsa da bu modelin verimliliği ve doğruluğu, bu tür uygulamalar için umut verici bir aday yapmaktadır. Genel olarak hem MobileNet hem de EfficientDet, bitki zararlılarını tespit etmek için tarım alanında kullanılmıştır. MobileNet, mısır ürünlerinde düşen ordu kurtları enfestasyonlarını tanımlamada başarıyla uygulanmıştır (Prabha vd., 2022), EfficientDet'in hızı ve doğruluğu ise onu nesne tespit görevleri, bitki zararlı tespiti dahil, için potansiyel bir seçenek yapmaktadır. Ancak, belirli bir uygulama için en uygun modeli seçerken hedef ürün ve zararlının özel gereksinimleri ve özelliklerini dikkate almak önemlidir.

CenterNet modeli, bitki zararlılarını tespit etmek amacıyla çeşitli tarımsal çalışmalarda yaygın olarak kullanılmıştır. Xiao ve diğerleri (2021) tarafından gerçekleştirilen böyle bir çalışmada, sebze plantasyonlarında yabancı ot tanımlanmasına odaklanılmıştır. Araştırmacılar, derin öğrenme ve görüntü işleme tekniklerini bir araya getiren yeni bir yöntem önermiştir. Eğitilmiş bir CenterNet modeli kullanılarak sebzeler tespit edilmiş ve etraflarına sınırlayıcı kutular çizilmiştir. Bu sınırlayıcı kutuların dışında kalan yeşil nesneler yabancı ot olarak kabul edilmiştir. Bu yaklaşım, yabancı otları ürünlerden doğru bir şekilde tanımlama ve ayırt etmede etkili olmuştur. Başka bir çalışmada, Xia ve diğerleri (2022) tarafından CenterNet ağı, özellikle elma tespiti için bitki tespiti problemine uygulanmıştır. Araştırmacılar, CenterNet çerçevesine dayalı hafif bir model oluşturmak için MobileNetV3 ve transpoze evrişimli katmanı tanıtmışlardır. Bu model, ardışık görüntülerde elmaları tespit etmede gelişmiş hız ve hassasiyet göstermiştir. Araştırmacılar, merkez noktasını tek bir şekil-agnostik çapa olarak kullanarak hız ve doğruluk arasında daha iyi bir denge elde etmişlerdir. Ayrıca, CenterNet modeli bitki biyomarker tanımasında da uygulanmıştır.

Shang ve diğ erleri (2018), altın nanopartik lle kaplı bir lokalize y zey plazmon rezonansı (LSPR) sens r dizisi ile yapılmıř bir  alıřmada molek ler olarak basılı sol-jel (MISG) kullanılmıřtır. Bu yaklařım, bir desen tanıma yaklařımıyla birleřtirildiğinde, bitkiler tarafından salgılanan u ucu organik bileřiklerin (VOC) tespitine ve tanımlanmasına olanak tanımıřtır. Arařtırmacılar, bu teknolojinin tarımsal uygulamalar i in potansiyelini g stermiř ve bitki VOC tespiti i in faydalı bir ara  sunmuřlardır.

Li ve Wang (2021) tarafından derin  ğrenmeye dayalı bitki hastalıkları ve zararlıları tespiti  zerine  alıřmaların bir incelemesi ger ekleřtirilmiřtir. Bitki hastalıkları ve zararlılarını tespit etmede tespit ağılarının potansiyeline dikkat  ekilmiřtir. Bilgisayar g r s nde nesne tespit ağılarındaki ilerlemelerle, Detectron2 gibi daha sofistike tespit modellerinin bitki hastalıkları ve zararlıları tespiti alanında uygulanması beklenmektedir. Graham ve diğ erleri (2022) gen  pamuk liflerinde iki h cre řeklinin etkili g r nt lenmesi ve bilgisayar g r ř  tespiti i in Detectron2 modelini kullanmıřlardır. Nesne tespitinde iyi performansı nedeniyle Detectron2 modelinin Faster RCNN R50-FPN 3x omurga mimarisini se ilmiřtir.  alıřma, Detectron2 modelinin pamuk liflerindeki belirli h cre řekillerini doğru bir řekilde tespit etme etkinliđini g stermiřtir.

Altuntas ve Kocamaz (2021) derin  ğrenme modelleri kullanarak domates bitkisi hastalıkları ve zararlılarının tespitine odaklanmıřtır. AlexNet ve GoogLeNet  nceden eđitilmiř evriřimli sinir ağı (CNN) modellerini Detectron2 modeliyle tekrar eđitilmiřtir. Sonu lar,  nceden eđitilmiř CNN modelleriyle ince ayar yapıldığında, Detectron2 modelinin yaprak g r nt lerine dayalı olarak domates bitkisi hastalıklarını ve zararlılarını tespit etmede y ksek dođruluk elde ettiđini g stermiřtir. Bir diğ er  alıřmada, Wen ve diğ erleri (2021) 3D baskılı par alardaki kusurları tanımak i in Detectron2 modelini kullanmıřlardır. Bu  alıřma dođrudan bitki zararlılarının tespiti ile ilgili olmasa da Detectron2 modelinin  eřitli uygulamalardaki  ok y nl l đ n  g stermektedir.  alıřmada, yerinde izleme yeteneđini test etmek i in X ıřını bilgisayarlı tomografi (CT) g r nt lerinin bir dizisi kullanılmıřtır. Detectron2 modeli, 3D baskılı par alardaki kusurları tespit etmede potansiyel g stermiř, bu da bitkilerdeki zararlıların tespitine uyarlanabilir.

Chen ve arkadaşları tarafından 2020’de yapılan bir çalışma, zararlı tespiti için AİoT (Nesnelerin Yapay Zekâsı) temelli akıllı bir tarım sistemi önermektedir. Bu sistem, yapay zekâ, görüntü tanıma teknolojileri, çevresel sensörler ve Nesnelerin İnternet’ini (İoT) gerçek zamanlı zararlı tespiti için bir araya getirir. Yazarlar, bu sistemi akıllı zararlı tespiti ve çevresel İoT verileri temelinde değerlendirmekte ve akıllı tarımı mümkün kılmak için derin öğrenme algoritmalarını uygulamaktadırlar. AİoT temelli akıllı tarım sistemleri, AI tabanlı modeller kullanarak tarımsal zararlıları tespit etmede umut verici sonuçlar göstermiştir. Bu sistemler, gerçek zamanlı zararlı tanımlama ve yönetimi için yapay zekâ, görüntü tanıma teknolojileri, çevresel sensörler ve İoT’yi birleştirir (Chen vd., 2020).

Geleneksel olarak, akıllı tarım sistemlerinde zararlı tespiti için bilgisayar görüşü tabanlı teknikler kullanılmıştır. Bu teknikler, evrişimli sinir ağları (CNN) gibi derin öğrenme modellerini kullanarak görüntüleri analiz eder ve ürünlerde zararlıları veya hastalıkları tanımlar (Yang vd., 2019; Chen vd., 2020). Derin öğrenme tekniklerinin kullanımı, geleneksel makine öğrenimi modellerine göre daha etkili ve verimli olduğu kanıtlanmıştır (Yang vd., 2019). Yapay zekanın hızla gelişmesi, akıllı tarımda zararlı tespiti için derin öğrenme tekniklerine artan bir odaklanmaya yol açmıştır (Yang vd., 2019).

Sood ve diğerleri (2021) tarafından sunulan referans, tarımda yapay zekâ konusundaki akademik yolculuğun kapsamlı bir incelemesini sağlar. Yazarlar, mevcut literatür üzerinde bibliyometrik bir analiz gerçekleştirerek, YZ’nın tarımda benimsenmesini etkileyen faktörleri belirlemek için yeniliklerin yayılması (DOI) ve teknolojinin kabul ve kullanımının birleşik teorisi (UTAUT) temelli bir çerçeve önermişlerdir. Bu kaynak, tarımda YZ’nın şu anki durumunu ve benimsenmesiyle ilişkili zorlukları ve fırsatları anlamak için değerlidir. Tarımda YZ temelli LMs’nin potansiyel uygulamalarından biri, ürün izleme ve hastalık tespittir.

Cavazza (2023) tarafından yapılan referansta, tarımda AI’nın çeşitli kullanımları ve avantajları vurgulanmakta olup, bu teknolojinin çiftçiler ve girişimciler üzerindeki olası etkilerine dikkat çekilmektedir. YZ temelli LMs’ler, uydu görüntüleri ve sensör verileri gibi büyük veri miktarlarını analiz ederek ürün sağlığını izleyebilir, hastalıkları tespit edebilir ve verimi tahmin edebilir. Bu modeller, ürün hastalıkları, zararlı istilaları ve hava durumu modelleriyle ilgili metinsel bilgileri işleyip yorumlayabilir, bu sayede çiftçilere

ürün yönetimi ve hastalık kontrol stratejileri hakkında bilinçli kararlar alma imkânı sunar. Hassas tarım, tarımsal uygulamaları belirli arazi koşullarına göre özelleştirerek kaynak tahsisini optimize etmeyi ve üretkenliği artırmayı amaçlar. YZ temelli LMs'ler, toprak bileşimi, hava durumu modelleri ve tarihi verim verileri gibi çeşitli veri kaynaklarını analiz ederek hassas tarımda kritik bir rol oynayabilir.

Cavazza (2023) tarafından vurgulandığı gibi, AI'nın tarımda yeni iş modellerine yol açma potansiyeli, YZ temelli LMs kullanımıyla kolaylaştırılabilir. Bu modeller, toprak sağlığı, besin yönetimi ve sulama uygulamalarıyla ilgili metinsel bilgileri işleyip yorumlayabilir, çiftçilere optimal kaynak tahsisi ve ürün yönetimi için kişiselleştirilmiş önerilerde bulunabilir. Zararlı ve yabancı ot yönetimi, ürün verimi ve kalitesini doğrudan etkileyen tarımda önemli bir zorluktur. YZ temelli LMs'ler, zararlı tanımlama, kontrol yöntemleri ve herbisit tavsiyeleriyle ilgili metinsel bilgileri analiz ederek zararlı ve yabancı ot yönetimine katkıda bulunabilir.

Sood ve diğerleri (2021) tarafından yapılan referans, AI'nın tarımsal sistemler ve süreçlerdeki zorlukları ele alma potansiyeline dikkat çeker. YZ temelli LMs'leri kullanarak çiftçiler, zararlı böcek salgınları hakkında gerçek zamanlı bilgilere erişebilir, uygun kontrol önlemlerini belirleyebilir ve pestisit ve herbisit kullanımını optimize edebilir, bu da daha sürdürülebilir ve çevre dostu uygulamalara yol açar. Tarım sektörü, arz ve talep, fiyat dalgalanmaları ve tüketici tercihleri gibi pazar dinamikleriyle etkilenmektedir. YZ temelli LMs'ler, pazar raporları, haber makaleleri ve sosyal medya verileri gibi çeşitli kaynaklardan metinsel bilgileri analiz ederek pazar analizinde ve karar verme süreçlerinde yardımcı olabilir.

Liu ve diğerleri (2021) tarafından sunulan referans, YZ güçlendirilmiş LMs'lerin ilaç keşfi ve geliştirmesine yardımcı olma potansiyelini tartışmaktadır. Bu referans ilaç endüstrisine odaklanmasına rağmen, temel prensipler tarım sektörüne uygulanabilir. YZ temelli LMs'ler, pazar trendleri, tüketici tercihleri ve ortaya çıkan fırsatlar hakkında çiftçilere ve tarım paydaşlarına değerli içgörüler sağlayarak, ürün seçimi, fiyatlandırma stratejileri ve pazara giriş hakkında bilinçli kararlar almalarına yardımcı olabilir. Bu tez çalışmasında değerlendirmeye alınan bilimsel araştırmalar Çizelge 2.2'de listelenmiştir.

Çizelge 2.2. Yapay zekâ ile tarımda zararlı tespiti kapsamında çalışan araştırmacılar ve kullanılan modeller

Kullanılan Modeller	Model Özelliği	Kaynaklar
FF-GWO-CNN	Hibrit zararlı tespiti modeli	Divya ve Santhi, 2023
CNN	Görüntü sınıflandırma için evrişimli ağ	Zhang vd., 2022 Chen vd., 2020'de
WOA	Doğa temelli optimizasyon algoritması	Muthaiah ve Chitra, 2023
YOLOv5	Hızlı nesne tespiti modeli	Ahmad ve diğerleri (2022); Luo (2023) Sozzi ve diğerleri (2022)
YOLOR	Hızlı ve ölçeklenebilir nesne tespiti	
YOLOv3	Hızlı nesne tespiti modeli	
YOLO-Lite	Hafif, hızlı nesne tespiti	
AgriPest-YOLO	Tarım zararlı tespiti için eğitilmiş YOLO	Zhang ve diğerleri (2022)
MobileNetV3	Mobil cihazlar için hızlı ve hafif model	
CycleGAN	Stil transferi için GAN modeli	Tian ve diğerleri (2019)
Faster R-CNN		Fuentes vd., ile Chen ve diğerleri (2021); Prabha ve diğerleri (2022) Bari ve diğerleri (2021)
YOLOV3-Dense	Yoğun bağlantılı YOLO modeli	
Faster R-CNN	Hızlı bölgesel nesne tespiti	
SSD	Tek aşamalı nesne tespiti modeli	
DETR	Transformer tabanlı nesne tespiti	Li ve Wang (2021) Sun ve diğerleri (2023)
YOLO4	Gelişmiş YOLO nesne tespiti modeli	Bíró ve diğerleri (2022)
Detectron2	Esnek ve modüler bir yapıya sahip tespit ve segmentasyon modeli	
Faster R-CNN	Hızlı bölgesel nesne tespiti	Chen ve diğerleri (2021)
SSD	Tek aşamalı nesne tespiti modeli	
YOLO v4	Gelişmiş YOLO nesne tespiti modeli	
MobileNetV1	Mobil cihazlar için hızlı ve hafif model	
ResNet50	Kalıntılı bağlantılarla derin öğrenme	Prabha ve diğerleri (2022) Selvaraj ve diğerleri (2019)
InceptionV2	Paralel evrişimli yapıya sahip ağ	
EfficientDet	Hız ve doğruluk açısından iyileştirilmiş tespiti modeli	Yang ve Yu (2021) Prabha vd., 2022
MobileNet	Mobil cihazlar için hızlı ve hafif model	
CenterNet	Merkez tabanlı nesne tespiti	Xiao ve diğerleri (2021)
Detectron2	Esnek ve modüler bir yapıya sahip tespit ve segmentasyon modeli	Li ve Wang (2021) Graham ve diğerleri (2022) Altuntas ve Kocamaz (2021) Wen ve diğerleri (2021)

3. MATERYAL VE YÖNTEM

3.1. Araştırma Sahasının ve Veri Setinin Tanımlanması

Türkiye, dünya genelinde en fazla domates üreten beş ülkeden biridir (Kumbasaroğlu vd., 2021). Türkiye'nin domates üretiminin yaklaşık %10'u Bursa'da gerçekleşmektedir ve 2020 yılında 13,2 milyon ton ile domates, ülkede en fazla üretilen sebze olmuştur (Gül, 2021). Bu çalışma, Türkiye'nin kuzeybatısında Bursa iline bağlı Karacabey ilçesindeki Bakırköy'de ve Yenişehir ilçesindeki Çeltikçi köyünde örtü altı domates üretimi yapılan seralarda çekilen fotoğraflar üzerinden yürütülmüştür. Çeltikçi ve Bakırköy bölgelerinden alınan görüntüler, domates bitkisinin fide döneminden meyve dönemine dek geçirdiği tüm evreleri, karşılaşılan bazı tarımsal zararlıları ve bu zararlıların neden olduğu bitkilerdeki zarar belirtilerini içermektedir. Çeltikçi köyünde yapılan fotoğraf çekimlerine ait lokasyonlardan biri 40°13'36.25"K enlem ve 29°32'17.74"D boylam koordinatlarında konumlanmışken; diğer çekim lokasyonu ise 40°13'44.99"K enlem ve 29°34'19.42"D boylam koordinatlarında bulunmaktadır (Şekil 3.1A). Bakırköy'de fotoğraf çekimlerinin gerçekleştirildiği lokasyonlar 40°7'17.53"K ile 40°10'40.36"K enlemleri ve 28°21'14.12"D ile 28°26'2.37"D boylamları arasında konumlanmaktadır. Araştırma sahası, 47,16 km²'lik bir alana yayılmış olup, bu kapsamda toplamda 96 adet domates tarlası fotoğraf çekimi amacıyla detaylı bir şekilde incelenmiştir (Şekil 3.1B). Domates bitkisi üzerindeki görsel materyal toplama süreci 2023 yılında, Nisan'dan Kasım'a kadar olan dönemde gerçekleştirilmiştir.



Şekil 3.1. Çalışma alanı konumu. A: Çeltikçi – Yenişehir. B: Bakırköy – Karacabey.

Bu tez çalışmasında incelenen domates çeşitleri Matador, Beefsteak, Daniela, Ramiro ve Salcano'dur. Matador ve Beefsteak, genellikle tarla (sonlu: determinant) domatesler olarak sınıflandırılırken, olumsuz iklim koşullarında örtü altı yetiştiricilik için de uygun olabilmektedir. Matador parlak kırmızı renkte büyük ve etli meyvelere sahipken, Beefsteak ise kırmızı veya pembe renkte büyük, etli ve sulu meyveleriyle bilinir. Öte yandan, Daniela, Ramiro ve Salcano salkım (sonsuz: indeterminant) domatesler arasında yer alır ve özellikle örtü altı yetiştiricilik için tercih edilir, bu sayede sıcaklık, nem ve ışık gibi faktörlerin kontrolü altında verimlilik ve kalite avantajları elde edilir. Özellikle Daniela'nın sert ve taşımaya dayanıklı meyveleri, Ramiro'nun parlak kırmızı ve yuvarlak orta büyüklükte meyveleri, Salcano'nun ise uzun, sivri ve orta büyüklükte meyveleri bu çeşitlerin ayırt edici özelliklerindendir.

Tespit modelleri, genellikle zararlıların varlığını ve konumunu belirlemek için yeterlidir ve hızlı analiz gereksinimlerinde etkilidir (Barbedo, 2019). Ancak, zararlıların tam şekli veya zararın detaylı bir haritasının gerektiği durumlarda, segmentasyon modelleri daha uygun bir seçenek haline gelmektedir (Milioto vd., 2018). Bu nedenle bu çalışmada, tespit modellerinin eğitimi amacıyla Dut kımılı *Dolycoris baccarum* (L.) (Hemiptera: Pentatomidae), Toprak pire böcekleri *Phyllotreta* spp. (Coleoptera: Chrysomelidae), Pis kokulu yeşil böcek *Nezara viridula* (L.) (Hemiptera: Pentatomidae), *Myzus persicae* (Hemiptera: Aphididae), Tütün beyaz sineği *Bemisia tabaci* (Gennadius, 1889) (Hemiptera: Aleyrodidae), Patates böceği *Leptinotarsa decemlineata* (Say) (Coleoptera: Chrysomelidae), *Tuta absoluta* (Meyrick) (Lepidoptera: Gelechiidae), *Helicoverpa armigera* (Hübner) (Lepidoptera: Noctuidae) zararlılarına ait görüntüler kullanılmıştır (Çizelge 3.1). Segmentasyon modellerinin eğitimi amacıyla ise yapraklarda *Liriomyza bryoniae* (Kaltenbach) (Diptera Agromyzidae), *T. absoluta*, *Frankliniella occidentalis* (Thysanoptera: Thripidae) ve *Tetranychus urticae* (Trombidiformes: Tetranychidae) zararı, meyvelerde ise *H. armigera*, *T. absoluta*, Akar zararı, sağlıklı meyve ve sağlıklı yaprak görüntüleri kullanılacaktır (Çizelge 3.2).

Çizelge 3.1. Tespit modelleri eğitimi için kullanılan zararlılar ve ait oldukları familyalar

Ergin görüntüleri	<i>Dolycoris baccarum</i>
	<i>Phyllotreta</i> spp.
	<i>Nezara viridula</i>
	<i>Myzus persicae</i>
	<i>Bemisia tabaci</i>
	<i>Leptinotarsa decemlineata</i>
	<i>Tuta absoluta</i>
Nimf görüntüleri	<i>Nezara viridula</i>
	<i>Leptinotarsa decemlineata</i>
Larva görüntüleri	<i>Helicoverpa armigera</i>
	<i>Tuta absoluta</i>

Çizelge 3.2. Segmentasyon modelleri eğitimi için kullanılan görüntüler

Domates yaprak görüntüleri	Domates meyve görüntüleri
<i>Liriomyza bryoniae</i> zararı	<i>Helicoverpa armigera</i> zararı
<i>Tuta absoluta</i> zararı	<i>Tuta absoluta</i> zararı
<i>Frankliniella occidentalis</i> zararı	<i>Tetranychus urticae</i> zararı
<i>Tetranychus urticae</i> zararı	

2021- 2023 tarihleri arasında gerçekleştirilen saha çalışmasında, domates bitkilerindeki hastalık ve zararlılara ait 768×1024 piksel çözünürlükte görseller kaydedilmiştir. Görüntü kalitesinin tutarlı olması için aynı çözünürlükte görüntü elde eden kameralar kullanılmıştır. Görüntüler, yapraklardan 1 ve 0,2 m mesafede, değişik açılarda çekilmiştir (Yong vd., 2020). Bu çalışmada, incelenen her zararlılar için bir veri kümesi oluşturulmuş ve her bir zararlı için yaklaşık 1.000 adet görsel toplanmıştır. Tespit ve segmentasyon amacıyla modellerin eğitimin kaydedilen görüntüler “eğitim”, “doğrulama” ve “test” olmak üzere üç gruba ayrılmıştır. Tüm fotoğrafların %80’i eğitim, %18’i doğrulama, %2’si test için kullanılmıştır (Çizelge 3.3).

Çizelge 3.3. Model eğitimi için görüntülerden oluşan veri setinin gruplara ayrılması


Yöntem	Görüntü türü	Görüntü sayısı	Eğitim %80	Doğrulama %18	Test %2
Tespit	Zararlı ergin görüntüleri	7000	5600	1260	140
	Zararlı nimf görüntüleri	2000	1600	360	40
	Zararlı larva görüntüleri	2000	1600	360	40
Toplam görüntü sayısı		11000	8800	1980	220
Segmentasyon	Domates yaprak görüntüleri	5000	4000	900	100
	Domates meyve görüntüleri	4000	3200	720	80
Toplam görüntü sayısı		9000	7200	1620	180

3.2. Veri Ön İşleme Teknikleri ve Uygulamaları

Veri Ön İşleme (Data Preprocessing), ham verinin analiz ya da modelleme gibi işlemlere hazır hale getirilmesi için gerçekleştirilen bir dizi işlemi ifade eder. Bu işlemler, genellikle veri madenciliği, makine öğrenimi, istatistik ve veri analizi gibi alanlarda kullanılır. Veri ön işleme, verideki eksikliklerin, gürültülerin ve tutarsızlıkların giderilmesine yardımcı olur, böylece veri seti üzerinde daha etkili analizler yapılabilir. Görüntü işlemede kullanılan modelleri eğitmek amacıyla kullanılan veri seti üzerinde görüntü ön işleme üç aşamadan oluşmaktadır: görüntü etiketleme, yeniden boyutlandırma ve artırma (augmentation). Artırma aşaması, eğitim verilerinde bulunan özellikleri öğrenmek ve görülmemiş verilerde kesin sınıflandırma doğruluğuna ulaşmak için büyük miktarda eğitim verisi sağlar. Araştırmalarda yetersiz veri, test verilerinde aşırı uyum (overfitting) ve genelleştirme sorunlarına yol açabilir. Bu sorunları önlemek için görüntüler, çevirme, kesme, yeniden ölçeklendirme, döndürme, yakınlaştırma ve kanal kaydırma gibi çeşitli rastgele artırma işlemlerinden geçebilir (Redmon and Farhadi 2018; Rubanga vd., 2020).

Bu çalışmada, veri ön işleme işlemleri için Python programlama dili kullanıldı. Python, kapsamlı kütüphane ekosistemine sahip olmasıyla bilinen, veri analizi ve manipülasyonu için yaygın olarak tercih edilen bir dildir. Analiz ve işlemler Anaconda dağıtımı aracılığıyla sunulan Spyder Entegre Geliştirme Ortamı (IDE) üzerinde gerçekleştirildi. Anaconda, bilimsel hesaplama ve veri bilimi uygulamaları için çeşitli kütüphaneleri bünyesinde barındırarak kurulum ve entegrasyon kolaylığı sağlamaktadır. Spyder IDE ise, veri analizi odaklı geliştirilmiş özelliklere sahip bir Python geliştirme ortamıdır. Tüm veri seti üzerinde görüntü etiketleme Labelme (<https://github.com/wkentaro/labelme>) aracı kullanılarak yapılmıştır (Şekil 3.2).

Bu çalışmada, görüntü etiketleme sürecinde iki ana yaklaşım benimsenmiştir. İlk olarak, segmentasyon yöntemi ile her bir nesnenin sınırlarını hassas bir şekilde tanımlamak amacıyla piksel bazında etiketleme gerçekleştirilmiştir. Bu yöntem, nesnelerin tam konumunu ve şeklini belirleyerek, daha detaylı bir analiz için temel oluşturur. İkinci olarak, dikdörtgen belirleme (rectangle bounding) yaklaşımı kullanılmıştır. Bu yaklaşım, nesnenin etrafında bir dikdörtgen çizerek nesnenin yaklaşık konumunu ve boyutlarını tanımlar. Her iki yöntem de etiketleme sürecini optimize etmek ve sonraki analiz aşamaları için verinin doğruluğunu artırmak amacıyla kullanılmıştır.



Şekil 3.2. Görüntü Etiketleme Yöntemleri: A) Dikdörtgen Belirleme, B) Poligonal Segmentasyon.

Tespit modellerinin eğitimi için kullanılan fotoğraflarda toplamda 11 adet etiket ismi dikdörtgen belirleme (rectangle bounding) yaklaşımıyla oluşturuldu. Segmentasyon modellerinin eğitimi için kullanılan fotoğraflarda toplamda 8 adet etiket ismi poligon tabanlı maskeleme (polygon-based masking) yaklaşımıyla oluşturuldu. Etiket isimleri Çizelge 3.4'te verilmiştir.

Çizelge 3.4. Tespit ve Segmentasyon modelleri için belirlenen etiket isimleri

Tespit Modeli Etiket İsimleri		Segmentasyon Modeli Etiket İsimleri	
1	<i>Dolycoris baccarum</i> ergini	1	<i>Liriomyza bryoniae</i> zararı
2	Toprak Pire Böcekleri ergini	2	<i>Tuta absoluta</i> zararı (meyvede)
3	<i>Nezara viridula</i> ergini	3	Thrips zararı
4	Aphid ergini	4	Akar zararı (yaprakta)
5	<i>Bemisia tabaci</i> ergini	5	Sağlıklı domates yaprakları
6	<i>Leptinotarsa decemlineata</i> ergini	6	Sağlıklı domates meyveleri
7	<i>Tuta absoluta</i> ergini	7	<i>Helicoverpa armigera</i> zararı
8	<i>Nezara viridula</i> nimfi	8	<i>Tuta absoluta</i> zararı (yaprakta)
9	<i>Leptinotarsa decemlineata</i> larvası		
10	<i>Helicoverpa armigera</i> larvası		
11	<i>Tuta absoluta</i> larvası		

3.3. Model Kurulumu ve Eğitimi

Model kurulum ve eğitimi, Google Colaboratory (<https://colab.research.google.com/>) adlı çevrimiçi platformda gerçekleştirilmiştir. Epoch, makine öğrenimi ve derin öğrenimde eğitim sürecindeki terimlerden biridir. Bir epoch, tüm eğitim veri kümesinin bir kez ileri (forward) ve geri (backward) yayılım algoritmaları tarafından işlenmesi sürecini ifade eder. Eğitim sırasında model, belirlenen sayıda epoch boyunca eğitilir. Her epoch'ta, modelin ağırlıkları (weights) ve biasları (biases), veri kümesindeki hataları azaltacak şekilde güncellenir. Epoch sayısının belirlenmesi, modelin eğitim süresini ve genellikle performansını doğrudan etkiler.

Daha fazla epoch, modelin eğitim verilerini daha fazla görmesini ve potansiyel olarak daha iyi öğrenmesini sağlar, ancak aynı zamanda aşırı uyum (overfitting) riskini de artırabilir. Overfitting, modelin eğitim verilerini çok iyi öğrenmesi ancak yeni verilere iyi genelleştirilememesi durumudur. Bu araştırmada artırılmış sayıda epoch seçildi, bu da genelleştirme için erken durdurma (early stopping) komutu verilmiştir (Mirhaji vd., 2021; Zhang vd., 2023a; Zhang vd., 2023b). Colab, kullanıcılarına bulut tabanlı bir ortamda kod yazma ve çalıştırma olanağı sunmaktadır. Eğitim sırasında, Intel(R) Xeon(R) CPU 2.20GHz işlemci, 12.68 GB RAM ve 12 GB belleğe sahip Tesla K80 GPU donanımlı bir makine kullanılmıştır. Hem tespit hem de segmentasyon modelleri Python programlama diliyle Colab ortamında kuruldu ve mevcut tez çalışmasına özel eğitim seti (Custom Dataset) üzerinde eğitilmiştir.

Bu çalışmada, domates bitkisinde mevcut birden fazla zararlı türüne özgü hasarların hassas bir şekilde tanımlanabilmesi için instance segmentation modellerinin kullanılması tercih edilmiştir. Semantic segmentasyon yerine instance segmentation tercih edilmesinin ana nedeni, bu modellerin tek bir kategorideki nesneleri bireysel olarak ayırt edebilme yeteneğine sahip olmasıdır. Bu özellik, domates bitkisinde farklı zararlı türleri tarafından oluşturulan hasarların daha detaylı ve ayrı ayrı tanımlanmasını sağlar. Bu yaklaşım hem yaprak hem de meyvelerde oluşan hasarların daha spesifik olarak belirlenmesinde kritik bir öneme sahiptir. Domates üzerinde zararlı tespiti amacıyla tercih edilen tüm modeller, Colab vasıtasıyla Custom Dataset üzerinden eğitilmiştir. Tercih edilen modellerin listesi Çizelge 3.5'te verilmiştir.

Çizelge 3.5. Tez çalışmasına ait olan veri seti üzerinden eğitilmek amacıyla tercih edilen modeller

Tespit Modelleri	YOLOv8
	Detectron2
	GroundingDINO
	DETR
	Faster R-CNN
	MobileNet SSD v2
	EfficientDet (D7) Tensorflow 2
Segmentasyon Modelleri	Mask RCNN (Instance object segmentation)
	Segment Anything Model (SAM)
	YOLOv8 (Instance Segmentation)

YOLOv8 (You Only Look Once v8): YOLOv8, YOLOv5'in geliştiricileri olan Ultralytics tarafından oluşturulmuş son teknoloji bir nesne tespiti ve görüntü bölütlenme modelidir. YOLOv8, görüntü sınıflandırma görevleri için de doğal destek sağlar. 10 Ocak 2023'te piyasaya sürülen YOLOv8, yeni bir temel ağ, YOLO ailesindeki eski modellerle model performansını karşılaştırmayı kolaylaştıran bir tasarım, yeni bir kayıp fonksiyonu ve yeni bir çapa bağlı olmayan (anchor-free) tespit başlığı özelliklerini içerir. Detectron2: FAIR Facebook AI Research grubu tarafından PyTorch'te yazılmış kendi bilgisayar görüş modeli koleksiyonudur.

Detectron2, orijinal Detectron'da bulunan tüm modelleri içerir, örneğin Faster R-CNN, Mask R-CNN, RetinaNet ve DensePose, yanı sıra Cascade R-CNN, Panoptic FPN ve TensorMask gibi daha yeni modelleri de içerir. Anahtar nokta tespiti, nesne tespiti ve semantik bölütlenme yapmak için Detectron2'yi kullanılabilir. Detectron2, veri kümelerini COCO JSON formatında kaydeder. GroundingDINO: Transformer tabanlı bir DINO detektörü ile yerinde önceden eğitim (grounded pre-training) birleştirilerek oluşturulan sıfır vuruşlu (zero-shot) bir nesne tespit modelidir. Grounding DINO makalesi özetine göre, model "COCO deteksiyon sıfır vuruşlu transfer referans değerinde 52,5 AP" başarısını elde etmektedir. Detection Transformer (DETR): Transformer mimarisi kullanılarak uygulanmış bir uçtan uca nesne tespit modelidir. DETR, Facebook Research tarafından geliştirilmiştir. Temel DETR modeli, COCO üzerinde %42,0 AP puanına sahiptir.

Faster R-CNN: Gelişmiş bir nesne tespit çerçevesidir ve zamanla pek çok entegrasyon kazanmıştır. İsminin aksine, diğer modellere (örneğin YOLOv3 veya MobileNet) göre daha yavaş fakat daha doğru sonuçlar verir. TensorFlow Nesne Tespiti API'si ile uyumlu olan bu model, iki aşamalı bir yaklaşım benimser: ilk olarak ilgi alanlarını belirler, sonra bu alanları bir evrişimli sinir ağına gönderir ve sınıflandırma için bir destek vektör makinesi (SVM) kullanır. MobileNet SSD v2 (Single Shot Multibox Detector): 267 katman ve 15 milyon parametre içeren bir nesne tespit modelidir. Akıllı telefonlar gibi hesaplama kısıtlamaları altındaki cihazlarda gerçek zamanlı çıkarım sağlar. Bir kez eğitildikten sonra, MobileNetSSDv2 63 MB olarak saklanabilir, bu da onu daha küçük cihazlarda kullanmak için ideal bir model haline getirir. Temelde MobileNetSSDv2 Modeli, iki bölümlük bir modeldir. İlk bölüm, tespit edilen görüntüyü sınıflandıran bir SSD katmanı ile temel MobileNetV2 ağından oluşur.

MobileNet temel ağı, SSD katmanı için bir özellik çıkarıcı olarak hareket eder, bu katman daha sonra ilgili nesneyi sınıflandırır. EfficientDet (D7) Tensorflow 2: Tensorflow TFRecord etiketleme formatını kullanır. Yayımlanma Tarihi 20 Kasım 2019. Model Türü Nesne Tespiti- Kullanılan Çerçeve TensorFlow 2. Etiketleme Formatı Tensorflow TFRecord. Mask RCNN: Instance segmentasyon amacıyla geliştirilmiş bir çerçevedir. Nesne tespiti ve piksel düzeyinde bölütlenme imkânı sağlar. Mask RCNN, instance segmentasyon için evrişimli bir sinir ağıdır. Sunulan eğitici materyal, bu modeli özel bir veri kümesi üzerinde nasıl eğiteceğinizi gösterir. Mask RCNN, COCO JSON etiketleme formatını kullanmaktadır. Segment Anything Model (SAM): Segment Anything, Nisan 2023'te Meta Research tarafından yayımlanmış, yeni bir veri seti kullanılarak eğitilmiş bir görüntü bölütlenme bilgisayar görüş modelidir. Modelin kendisi Segment Anything Model (SAM) olarak adlandırılmıştır. SAM kullanılarak, modelin bulabildiği bir görüntüdeki tüm nesneler için segmentasyon maskeleri üretilebilir veya sağlanan metin istemini karşılayan nesneler için maskeler oluşturulabilir.

Seçilen modellerin (YOLOv8, Detectron2, GroundingDINO, DETR, Faster R-CNN, MobileNet SSD v2, EfficientDet (D7) Tensorflow 2, Mask RCNN, ve Segment Anything Model (SAM)) amacı, tarımsal alanda, özellikle domates bitkisinde zararlıları erken tespit etmek ve böylece müdahale süresini optimize etmektir. YOLOv8 ve MobileNet SSD v2'nin gerçek zamanlı nesne tespiti yetenekleri, zararlıların hızlı bir şekilde tespit edilmesini ve zamanında müdahale edilmesini sağlar. Detectron2 ve Mask RCNN'nin segmentasyon yetenekleri, zararlıların hangi alanlarda aktif olduğunu belirlemeye ve bu bölgeler üzerinde daha detaylı analizler yapmaya yardımcı olur. GroundingDINO ve DETR'nin Transformer tabanlı mimarileri, gelişmiş özellik çıkarımı ve nesne tespiti performansı sunarak zararlı tespitinde daha yüksek doğruluk ve genelleme kabiliyeti sağlar. Faster R-CNN, yüksek doğruluk oranı ile zararlı tespitinde güvenilir sonuçlar sunar, EfficientDet (D7) ve Tensorflow 2 ise yüksek doğruluk ve etkinlikle birlikte ölçeklenebilir ve esnek nesne tespiti kapasitesi sunar. Segment Anything Model (SAM) ile gelişmiş segmentasyon yetenekleri, zararlıların ve etkiledikleri alanların ayrıntılı bir şekilde segmente edilmesini ve analiz edilmesini sağlar. Bu modellerin seçimi, literatürde belirtilen ve benzer çalışmalarda başarıyla uygulanmış modellerin bir kombinasyonunu içerir, ve bu bütüncül yaklaşım, tarımsal zararlı tespiti alanında daha etkili ve güvenilir sonuçlar elde etmeyi amaçlamaktadır (Redmon ve Farhadi, 2018).

3.4. Model Değerlendirme Metodolojisi ve Test Süreci

Bu çalışmada seçilen modellerin tespit ve segmentasyon performansları, farklı Birleşim Üzerinden Kesişim (IOU) eşik değerlerinde "Hassasiyet: Precision (P)", "Duyarlılık: Recall (R)" ve "Ortalama Hassasiyet (mAP)" gibi metriklerle değerlendirilmiştir. Bu metrikler arasında "mAP50" ve "mAP50-95", nesne tanımlama ve farklı boyutlarda ve örtüşmelerde tespit için modelin doğruluğu hakkında bilgi sağlar (Li vd., 2020; Gai vd., 2023). Bahsi geçen metriklere ek olarak, modelin değerlendirilmesinde belirli kayıp değerlerine başvurulmuştur. Bunlar arasında; sınırlayıcı kutunun yerleştirilmesindeki sapmaları temsil eden `box_loss`, sınıflandırma hatalarını gösteren `cls_loss` ve modelin şekil deformasyonlarını yakalama yeteneğini ölçen `dfl_loss` bulunmaktadır. Bu kayıp metriklerinin analiziyle, modelin güçlü yönleri ve potansiyel iyileştirme alanlarına dair kapsamlı bir anlayış elde edilmiştir. Performansın değerlendirilmesinde kullanılan diğer bir önemli araç ise karışıklık matrisidir. Bu matris, modelin tüm sınıflar arasındaki tahminlerini özetleyen bir görüntü sağlar. Bu, modelin doğru sınıflandırma ve potansiyel yanlış sınıflandırma alanlarını vurgular. Bu analiz aracılığıyla, modelin güçlü ve zayıf yönleri, daha önce tartışılan metriklerle birlikte belirlenmiştir (Çizelge 3.6).

Çizelge 3.6. Nesne tespiti performansını değerlendirmek için denklemler

<i>Performans metrikleri</i>	<i>Formüller</i>
Precision (P)	$\frac{TP}{(TP + FP)}$
Recall (R)	$\frac{TP}{(TP + FN)}$
mAP50	$\frac{1}{Q} \sum_{q=1}^Q P(Rq)$
mAP50-95	$\frac{1}{Q} \sum_{i=5}^{95} P(Rq) \frac{1}{Q_i} \sum_{q=1}^{Q_i} P(Rq, i)$
TP doğru pozitif tahminleri temsil ederken, FP yanlış pozitif tahminleri (gerçekte negatif olanların pozitif olarak tahmin edilmesi) belirtir ve FN yanlış negatif tahminleri (gerçekte pozitif olanların negatif olarak tahmin edilmesi) gösterir. Q sorgu noktalarının sayısını ifade eder, Rq'daki interpolasyonlu doğruluk ise P(Rq) ile belirtilir.	

Bu çalışmanın bir sonraki aşamasında, önceden ayrılmış olan test veri seti üzerinde modelin genelleme kapasitesi detaylı bir şekilde değerlendirilmiştir. Veri setinin %80'i eğitim, %18'i doğrulama ve %2'si test için ayrılmıştır. Modelin eğitimi sırasında, hassasiyet, duyarlılık, mAP50, mAP50-95 gibi temel performans metrikleri eğitim ve doğrulama veri setleri üzerinden hesaplanarak, modelin evrimi izlenmiştir. Bu süreç, modelin hem bireysel sınıflar üzerindeki performansını hem de genel performansını değerlendirmekte kullanılan anahtar metriklerle dayanarak gerçekleştirilmiştir. Bununla birlikte, eğitim esnasında belirtilen kayıp değerleri, modelin potansiyel zayıf yönlerini ve iyileştirme gereksinimlerini belirlemekte büyük rol oynamıştır. Model eğitiminin tamamlanmasının ardından, test seti üzerinde karışıklık matrisi kullanılarak sonuçlar değerlendirilmiştir. Bu matris, modelin gerçek sınıflar ile tahmini sınıflar arasındaki ilişkisini net bir şekilde ortaya koymuştur, böylece modelin doğru tahminler, yanlış pozitif tahminler ve yanlış negatif tahminler arasındaki farklılıkları gözlemlene imkânı sunmuştur. Bu test süreci, modelin gerçek dünyadaki performansını ve güvenilirliğini ölçmekte kritik bir adım oluşturmaktadır.

Bu alıřmada, birden fazla grnt tanıma modelinin performansını Precision, Recall, mAP50 ve mAP50-95 metrikleri zerinden deęerlendirmek iin ANOVA yntemi ve Tukey HSD post-hoc testi kullanılmıřtır. Bu yaklařım, modeller arasındaki performans farklılıklarını kapsamlı ve doęru bir řekilde analiz etmeyi amalar ve R istatistiksel yazılımını ile gerekleřtirilmiřtir.

Tespit amacıyla eęitilen Detectron2, DETR, EfficientDet, Faster R-CNN, GroundingDINO, MobileNet ve YOLOv8 modelleri ile segmentasyon amacıyla eęitilen SAM, MASK R-CNN ve YOLOv8 modellerinin karmařıklık matrislerine ait doęru ve hatalı tespit oranları detaylı bir řekilde istatistiksel aıdan analiz edilecektir. Bu analizlerin sonularını istatistiksel olarak deęerlendirmek ve modeller arasındaki performans farklılıklarının anlamlılıęını test etmek amacıyla ANOVA analizi uygulanacaktır. ANOVA analizinin ardından, hangi modeller arasında anlamlı farklar olduęunu belirlemek iin Tukey HSD post-hoc testi, R istatistiksel yazılımını kullanılarak gerekleřtirilecektir.

3.5. Dil Modeli ve API Entegrasyonu

Yapay zekâ temelli dil modelleri, karar alma süreçlerinde çiftçilere bilinçli yönlendirmeler sunarak tarım uygulamalarını optimize etmekte önemli bir role sahiptir. Bu modeller, Pazar eğilimleri, hava tahminleri ve ürün performansı gibi verileri analiz ederek ekim, hasat ve Pazar seçimi gibi kararlar alınmasında kritik bir katkıda bulunabilir (Cavazza, 2023). Bununla birlikte, dil modelinin pratik kullanımını daha erişilebilir kılmak için, Uygulama Programlama Arayüzleri (API'ler) devreye girmektedir. AI uygulamaları için tasarlanan API'ler, modülerlik ilkesine dayanarak, sistemin bileşenlerinin gevşek bir şekilde entegrasyonuna ve dolayısıyla hızlı güncellemelere olanak tanımaktadır (Tilkov ve Vinoski, 2010). Aynı zamanda, bu API'ler soyutlama ilkesini benimseyerek son kullanıcıların karmaşık AI mekanizmalarının detaylarına dalmadan, dil modelinin avantajlarından yararlanmalarını sağlar (Doshi-Velez ve Kim, 2017). Sonuç olarak, dil modeli ve API entegrasyon teknikleri, yapay zekâ uygulamalarının gerçek dünya senaryolarında daha verimli ve etik bir şekilde kullanılmasında merkezi bir öneme sahiptir.

Dil modelleri, doğal dil işleme alanında kullanılan yapay zekâ tabanlı algoritmalardır ve insan dilini anlama ve üretme kapasitesine sahiptir. Bu modeller, genellikle büyük miktarda metin verisi üzerinde eğitilir ve bu eğitim sayesinde cümlelerin olasılık dağılımlarını tahmin edebilme yeteneği kazanır (Goodfellow vd., 2016). Bu tahminler, bir kelimenin bir önceki ya da birkaç önceki kelimeye bağlı olarak hangi olasılıkla geleceğini belirlemek için kullanılır.

GPT-3, belirli görevler için özelleştirilmiş modellerle entegre edilebilir. Bu, örneğin tespit veya segmentasyon gibi işlemler için kullanılır (Pautasso vd., 2008). Özelleştirilmiş modellerin API'leri üzerinden GPT-3 ile entegrasyon sağlanır, böylece dil modeli bu modellerden gelen bilgileri anlayıp yorumlayabilir (Tilkov ve Vinoski, 2010). Bu süreçte, modellerden en iyi sonuçları alabilmek için özel “prompt”lar hazırlanması gerekir. “Prompt”, burada, modele belirli bir yanıt ürettirmek için verilen komut veya bilgiyi ifade eder. Bu sayede GPT-3, entegre edildiği modellerin sonuçlarına dayanarak anlamlı metinler oluşturabilir.

Bu çalışmada, Anaconda platformu üzerinde yer alan Spyder IDE'si kullanılarak Python programlama dili ile bir API bağlantısı kurulmuştur. Bu bağlantı, OpenAI'nin dil modeliyle entegrasyon sağlamak amacıyla gerçekleştirilmiştir. Aşağıda verilen kod parçasında, belirtilen API anahtarı ile OpenAI servisine erişim sağlanmıştır. Ardından, belirli bir "prompt" oluşturularak bu modelden tarım alanında belirli zararlıları ve bunlara karşı ekolojik yöntemlerle mücadele yöntemlerini içeren bir yanıt alınması talep edilmiştir. Kullanılan "max_tokens" parametresi ile modelin üreteceği metin uzunluğu sınırlanmıştır, "temperature" parametresi ile de modelin üreteceği metinlerin çeşitliliği kontrol edilmiştir. Sonuç olarak, bu kod parçası ile belirtilen prompt'a uygun olarak modelden alınan yanıt, çıktı olarak ekrana yazdırılmıştır (Şekil 3.3).

```
34
35 # Now use this string as the input to OpenAI's language model
36 openai.api_key = "sk-6b3hfSDCLWbWL0uwSSHSVST3BLbkFJJOnVqp2gWESDVS1gnD1V0HoC"
37
38 prompt_str = f"As an agricultural expert, could you shortly emphasis "
39              "the potential damage caused by pests labeled as "
40              "{detected_classes_str}, and recommend eco-friendly control "
41              "methods by giving example of agents?"
42 response = openai.Completion.create(
43     engine="text-davinci-003",
44     prompt=prompt_str,
45     max_tokens=250,
46     temperature=0.1,
47     n=1,
48 )
49 output = response.choices[0].text.strip()
50 print(output)
51
```

Şekil 3.3. OpenAI API Aracılığıyla Tarımsal Zararlılara Dair Bilgi Talebinde Bulunan Kod Parçası.

3.6. Prompt Oluşturma ve Çıktıların Değerlendirilmesi

Bu çalışmada, Python programlama dili ve açık kaynaklı kütüphaneler kullanılmıştır. İlk olarak, tespit ve segmentasyon modelleri eğitildikleri nesneleri arazi görüntüleri üzerinden tanımaktadırlar. Daha sonra belirli bir API anahtarı ile GPT-3 sistemine entegre edilmişlerdir. Bir tür tanımlandığında, sistem bu türün zararlı mı yoksa yararlı mı olduğunu belirlemek üzere "prompt" vasıtasıyla teşvik edilmiştir. Oluşturulan prompt içeriğinde, zararlı belirlendiğinde mücadele yöntemlerine dair kapsamlı bir açıklama talep edilmiştir.

Prompt mekanizmasını etkili bir şekilde kullanarak GPT-3'ten derinlemesine yanıtlar alabilmek için net bir yönlendirme kritik öneme sahiptir. Bu bağlamda, GPT-3'e spesifik bir görev tanımlanması, prompt sorularının detaylı ve kesin bir biçimde oluşturulması, ele alınan konunun net bir şekilde tanımlanması ve beklenen yanıtın tarzının belirlenmesi, bu sürecin önemli bileşenlerini teşkil etmektedir (Brown vd., 2020). Çizelge 3.7, belirli sonuçlar için özelleştirilmiş çeşitli istem örneklerini sunmaktadır. İstem içerisinde, bitki zararlısı olarak tanımlanan etiketlere "detected_classes_str" adı verilmiştir.


Çizelge 3.7. Hedef odaklı çıktılar için Özelleştirilmiş Prompt Örnekleri

Prompt Numarası	Alternatif Prompt
1	<code>prompt_str = f"Sen bitki zararlıları konusundaki bir uzmansın, {detected_classes_str} tarafından oluşturulan potansiyel tehlikeleri anlatabilir misin ve çevre dostu kontrol yöntemleri önerir misin? Akademik ve sade bir Türkçe kullanarak cevap ver"</code>
2	<code>prompt_str = f"Bitki zararlıları üzerine olan uzmanlığınıza dayanarak, {detected_classes_str}'nin potansiyel tehlikeleri nelerdir ve kontrolü için hangi çevre dostu metotlar uygulanabilir? Akademik ve sade bir İngilizce kullanarak cevap ver"</code>
3	<code>prompt_str = f"Bitki zararlıları üzerindeki uzmanlığınızla, {detected_classes_str}'nin olumsuz etkilerini detaylandırabilir misiniz ve kimyasal mücadele teknikleri hakkında önerilerde bulunabilir misiniz? Akademik ve sade bir İngilizce kullanarak cevap ver"</code>
4	<code>prompt_str = f"Sen domates bitkisinde görülen zararlı böcekler üzerinde uzman bir araştırmacısın. {detected_classes_str}'e karşı kimyasal mücadele kapsamında hangi aktif maddeleri kullanabilirim? Akademik ve sade bir Türkçe kullanarak cevap ver"</code>
5	<code>prompt_str = f" Sen domates bitkisinde görülen zararlı böcekler üzerinde uzman bir araştırmacısın, {detected_classes_str} tarafından oluşturulan potansiyel tehlikeleri anlatabilir misin ve çevre dostu kontrol yöntemleri önerir misin? Akademik ve sade bir İngilizce kullanarak cevap ver"</code>


Metin yanıtları OpenAI tamamlama yöntemi ile üretilmiştir. Bu metin, tespit sonuçları ile tek bir görselde işlenmektedir. Token sayısı, ChatGPT-3'ün aşırı uzun ve detaylı çıktılar üretmesini engellemek amacıyla 250-400 arasında sınırlanmıştır. Çıktının uzunluğu isteğe bağlı olarak ayarlanabilir. Tespit modeli ve GPT-3'ün birlikte çalışmasına olanak tanımak için on adımlı bir kodlama dizisi geliştirilmiştir, bu sürecin ana başlıkları Çizelge 3.8'te gösterilmiştir. GPT-3 ün oluşturduğu çıktılar, insan gözlemine ve bilgisine dayalı bir şekilde kontrol edilmektedir.



Çizelge 3.8. Tespit ve Dil Modelinin Entegre Edilme Basamakları.



Prompt oluřturma ve ıktıların deęerlendirilmesi kapsamında yapılan bu tez alıřması “Girdi”, “Tespit”, “ıktı” ve “Kontrol” bařlıkları altında drt adımdan oluřmaktadır (řekil 3.4). zetle “Girdi” adımımda arazi ortamından elde edilen fotoęraflar veri olarak kullanılır. “Tespit” adımımda eęitilmiş yapay zekâ modelleri girdi olarak verilen grntler zerinde alıřmaktadır. “ıktı” adımımda, yapay zekâ modellerinin tespit ettięi ve dizi karakterlerine (string) dnřtrdę zararlı etiketleri GPT-3 modeliyle deęerlendirilir. “Kontrol” adımımda, GPT-3 n oluřturduęu ıktıların doęruluęu insan gzlemine ve bilgisine dayalı bir řekilde literatr incelenerek kontrol edilmektedir.



řekil 3.4. Tespit ve dil modeli entegrasyonu. Girdi: Domates bitkisine ait arazi fotoęrafları. ıktı: Tespit ve Dil modeline ait ortak ıktı.

4. BULGULAR VE ANALİZLER


Tarımsal zararlı tespitinde, özellikle bir yaprağın üzerinde birden fazla zararlının veya zarar şeklinin bulunduğu senaryolar sıklıkla karşılaşılan durumlardır. Bu bağlamda, sadece zararlıların varlığını tespit etmek yerine, bireysel zararlıların tam konumları, sayıları ve birbirleri arasındaki konumsal ilişkilerinin tespiti kritik bir öneme sahiptir. Semantic segmentasyon, bir görüntüdeki her pikselin hangi sınıfa ait olduğunu belirleme yeteneğine sahipken, aynı sınıfa ait farklı objeler arasında ayrım yapamaz. Öte yandan, instance segmentasyon her bir objenin ayrı ayrı segmentasyonunu sağlar. Bu, zararlı yoğunluğunun doğru bir şekilde tespit edilmesi, hassas tarım uygulamalarının gerçekleştirilmesi ve zararlıların yaşam evrelerinin detaylı analizi için gereklidir. Bundan dolayı, daha detaylı analiz ve hassas müdahale imkânı sunan instance segmentasyon yapabilen modeller tercih edilmiştir (He vd., 2017; Redmon vd., 2016; Hariharan vd., 2015). Bu bağlamdaki model seçimleri ve yapılandırmalarının verimliliği ve başarısı, objektif bir şekilde değerlendirmek için istatistiksel analizlerin yapılması zorunludur. Modelin genel performansını, aşırı öğrenme (overfitting) veya yetersiz öğrenme (underfitting) durumlarını belirlemek amacıyla Eğitim (Train) ve Doğrulama (Validation) Kayıp Grafikleri kullanılmıştır. Ayrıca, modelin zararlı tespiti ve segmentasyonunda ne kadar doğru ve hassas olduğunu değerlendirmek için Performans Değerlendirme Metrikleri (Recall, Precision, MAP) hesaplanmıştır. Confusion Matris Analizi ile sınıflandırma hataları, doğru tespitler ve yanılsamalar detaylı olarak incelenmiştir. Tüm bu analizler, modelin gerçekte ne kadar güvenilir ve uygulanabilir olduğunu belirlemekte kritik bir role sahiptir.

4.1. Eğitim (Train) ve Doğrulama (Validation) Kayıp Grafiği

Tespit yeteneği olan modellerin eğitimi için toplamda 11.000 adet fotoğraf içeren veri seti kullanılmıştır. Bu veri seti; Zararlı ergin, nimf ve larva görüntülerinden oluşmaktadır. Kullanılan veri seti içerisinde toplamda 13 farklı etiket (sınıf adı) mevcuttur. Bu etiketler şunlardır: *D. baccarum* ergini, Toprak Pire Böcekleri ergini, *N. viridula* ergini, Aphid ergini, *B. tabaci* ergini, *L. decemlineata* ergini, *T. absoluta* ergini, *N. viridula* nimfi, *L. decemlineata* larvası, *H. armigera* larvası ve *T. absoluta* larvası. Bu çalışmada kullanılan tespit (YOLOv8, Detectron2, GroundingDINO, DETR, Faster R-CNN, MobileNet SSD v2, EfficientDet (D7) Tensorflow 2) modelleri bu 13 farklı etiket üzerinden eğitilmiştir. Eğitim (Train) ve Doğrulama (Validation) Kayıp (Loss) Grafiği, bir modelin eğitim sürecindeki performansını değerlendirmek için kritik bir araçtır.

'Train Loss Over Epoch', modelin eğitim veri seti üzerindeki her epoch'ta ne kadar iyi öğrendiğini gösterirken, 'Validation Loss Over Epoch' modelin, daha önce görülmemiş veriler üzerindeki genelleme kabiliyetini temsil eder. Bu değerlerin düşük olması, modelin veriyi iyi öğrendiğini ve overfitting olmadan genellemeler yapabildiğini gösterir. Bu çalışmada, bu değerlerin hesaplanmasının nedeni, farklı tespit modellerinin eğitim süreçlerini objektif bir şekilde değerlendirerek, en iyi modelin seçimine bilimsel bir temel sağlamaktır. Bu tez çalışmada kullanılan kısaltmalarda "Box_loss", modelin nesnelerin konum ve boyutunu tahmin etme doğruluğunu ölçen sınırlayıcı kutu uyumsuzluğunu; "cls_loss", nesneleri doğru kategorilere sınıflandırma yeteneğini ölçen sınıflandırma kaybını ve "dfl_loss", nesnenin şekil değişikliklerini doğru tahmin etme yeteneğini ölçen şekil uyumsuzluğu kaybını ifade etmektedir. "Epoch" ise, görüntülerden oluşan eğitim veri setinin bir model tarafından tamamen bir kez işlendiği her bir döngüye verilen isimdir. Diğer bir deyişle, bir epoch, tüm eğitim örneklerinin ağ üzerinden ileri ve geri yayılım yoluyla tam olarak bir kez geçtiği süreçtir.

Görüntüler üzerinden zararlı tespiti amacıyla YOLOv8 modelinin eğitim süreci incelendiğinde, modelin kayıp metriklerinde belirgin değişiklikler gözlemlenmiştir. Eğitim sürecinde, train/box_loss değeri 1,84 başlangıç değerinden 0,54'e kadar azalmıştır. Bu durum, modelin mekansal yerleştirme kapasitesinde ciddi ilerlemeler kaydettiğini işaret etmektedir. Aynı şekilde, train/cls_loss değeri 3,48'den 0,37'ye düşmüştür, bu da modelin nesneleri daha doğru kategorilere tahsis edebildiğini göstermektedir. Ek olarak, train/df_loss değeri 1,54'ten 0,86'ya düşmüştür, bu da modelin şekil değişikliklerini daha doğru tahmin edebildiğini ortaya koymaktadır. Doğrulama verileri için de modelin performansı olumlu bir trend göstermektedir. val/box_loss 1,38'den 0,53'e, val/cls_loss 3,45'den 0,31'e ve val/df_loss 1,30'dan 0,90'a azalmıştır. Model eğitimi, 749 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Bu sonuçlar, YOLOv8 modelinin eğitim sürecinde etkili bir şekilde öğrendiğini ve genel olarak başarılı bir performans sergilediğini göstermektedir (Şekil 4.1). Wang VE Liu (2021) tarafından yapılan çalışmada, seralarda domates anomalilerinin tespiti için yenilikçi bir YOLO-Dense modelini tanıtılmaktadır. YOLO çerçevesine yoğun bağlantı modülü ekleyerek ve K-means algoritması ile çapa kutularını optimize ederek, modelin ağ çıkarım hızını etkili bir şekilde artırması hedeflenmiştir. Çalışmada, farklı boyutlardaki dokuz çapa kutusu elde edilmiş ve çok ölçekli eğitim stratejisi, farklı ölçeklerdeki nesnelerin tanınma doğruluğunu iyileştirmek için benimsenmiştir. YOLO-Dense ağının tek bir görüntüdeki ortalama doğruluk oranı (% mAP) %96,41 ve tespit süresi 20,28 ms olarak belirlenmiştir. Bu sonuçlar, modelin SSD, Faster R-CNN ve orijinal YOLOv3 ağlarına kıyasla karmaşık doğal ortamlarda domates anomalilerinin tespitinde üstün performans sergilediğini göstermektedir.




Epoch	Eğitim (Training)			Doğrulama (Validation)		
	Box Loss	Cls Loss	Dfl Loss	Box Loss	Cls Loss	Dfl Loss
0	1.8444	3.4784	1.5395	1.3841	3.4553	1.3003
75	0.99728	0.66486	1.0074	1.0888	0.62872	1.111
150	0.86176	0.54371	0.95471	0.83098	0.48648	0.99905
225	0.75032	0.47914	0.92205	0.7331	0.43252	0.93825
300	0.69887	0.43667	0.8996	0.7116	0.39762	0.93383
375	0.67075	0.43522	0.90054	0.67938	0.37401	0.94673
450	0.61114	0.4089	0.88043	0.61007	0.34843	0.89862
525	0.5968	0.3931	0.89272	0.55387	0.32704	0.90024
600	0.59297	0.388	0.87538	0.56851	0.33152	0.90737
675	0.58761	0.39859	0.87321	0.53197	0.31912	0.88554
749	0.54849	0.36727	0.85969	0.52527	0.31206	0.90568

Şekil 4.1. Zararlı Tespiti (Detection) amacıyla eğitilen YOLOv8 Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Görüntüler üzerinden zararlı tespiti amacıyla EfficientDet (D7) modelinin eğitim süreci incelendiğinde, modelin kayıp metriklerinde belirgin değişiklikler gözlemlenmiştir. train/box_loss değerinin başlangıçta 1,99 olup süreç sonunda 0,78'e indirilmesi, modelin mekansal yerleştirme yeteneğinde önemli ilerlemeler kaydettiğini belirtmektedir. Bununla birlikte, train/cls_loss değerinin başlangıçta 3,42'den 0,47'ye düşürülmesi, modelin nesneleri daha doğru sınıflara atama konusundaki başarısını vurgulamaktadır. Ayrıca, train/dfl_loss değerinin 1,45'ten 0,87'ye düşmesi, modelin nesnelerin şekil değişikliklerini daha hassas bir şekilde tahmin edebildiği sonucunu ortaya koymaktadır. Doğrulama verileri için de benzer bir başarı söz konusudur (Box_loss: nesnenin konumunu, cls_loss: sınıflandırma doğruluğunu, dfl_loss nesnenin şekil tahminini, Epoch tüm eğitim örneklerinin model tarafından bir kez işlendiği döngü).


Model eğitimi, 409 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. val/box_loss değerinin 1,73'den 0,99'a, val/cls_loss değerinin 3,35'ten 0,61'e ve val/dfl_loss değerinin 1,31'den 0,97'ye indirilmesi, modelin genel olarak başarılı bir eğitim süreci geçirdiğini göstermektedir (Şekil 4.2).



Şekil 4.2. Zararlı Tespiti (Detection) amacıyla eğitilen EfficientDet (D7) Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Görüntüler üzerinden zararlı tespiti amacıyla DETR modelinin eğitim süreci incelendiğinde, modelin kayıp metriklerinde belirgin değişiklikler gözlemlenmiştir. train/box_loss değerinin başlangıçta 1.68 olup süreç sonunda 0,46'ya indirilmesi, modelin mekansal yerleştirme yeteneğinde önemli ilerlemeler kaydettiğini belirtmektedir. Bununla birlikte, train/cls_loss değerinin başlangıçta 3,54'ten 0,34'e düşürülmesi, modelin nesneleri daha doğru sınıflara atama konusundaki başarısını vurgulamaktadır.

Ayrıca, train/dfl_loss değerinin 1,78'den 0,91'e düşmesi, modelin nesnelerin şekil değişikliklerini daha hassas bir şekilde tahmin edebildiği sonucunu ortaya koymaktadır. Doğrulama verileri için de benzer bir başarı söz konusudur (Box_loss: nesnenin konumunu, cls_loss: sınıflandırma doğruluğunu, dfl_loss nesnenin şekil tahminini, Epoch tüm eğitim örneklerinin model tarafından bir kez işlendiği döngü). val/box_loss değerinin 1,55'ten 0,52'ye, val/cls_loss değerinin 2,43'ten 0,27'ye ve val/dfl_loss değerinin 1,85'ten 0,95'e indirilmesi, modelin genel olarak başarılı bir eğitim süreci geçirdiğini göstermektedir. Model eğitimi, 256 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. (Şekil 4.3).




Epoch	Eğitim (Training)			Doğrulama (Validation)		
	Box Loss	Cls Loss	Dfl Loss	Box Loss	Cls Loss	Dfl Loss
0	1.6789	3.5401	1.7766	1.5526	2.4333	1.8525
25	0.98113	0.66881	1.21	1.0248	0.63512	1.2494
50	0.79587	0.54411	1.1015	0.84868	0.49073	1.1552
75	0.72645	0.49897	1.0646	0.71348	0.42335	1.0668
100	0.65531	0.46901	1.0096	0.68578	0.39369	1.0451
125	0.59492	0.42209	0.97967	0.61534	0.37318	0.97066
150	0.58054	0.41344	0.98804	0.63319	0.34497	0.96854
175	0.52347	0.372	0.94643	0.51363	0.31423	0.92463
200	0.48985	0.36279	0.92734	0.52221	0.31406	0.93942
225	0.48403	0.34226	0.91897	0.54379	0.30547	0.979
256	0.45718	0.33536	0.90725	0.52202	0.2729	0.95271

Şekil 4.3. Zararlı Tespiti (Detection) amacıyla eğitilen DETR Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Görüntüler üzerinden zararlı tespiti amacıyla MobileNet SSD v2 modelinin eğitim süreci incelendiğinde, modelin kayıp metriklerinde belirgin değişiklikler gözlemlenmiştir. train/box_loss değerinin başlangıçta 1,83 olup süreç sonunda 0,69'a indirilmesi, modelin mekansal yerleştirme yeteneğinde önemli ilerlemeler kaydettiğini belirtmektedir. Bununla birlikte, train/cls_loss değerinin başlangıçta 2,88'den 0,44'e düşürülmesi, modelin nesneleri daha doğru sınıflara atama konusundaki başarısını vurgulamaktadır. Ayrıca, train/dfl_loss değerinin 1,60'dan 0,96'ya düşmesi, modelin nesnelerin şekil değişikliklerini daha hassas bir şekilde tahmin edebildiği sonucunu ortaya koymaktadır. Doğrulama verileri için de benzer bir başarı söz konusudur. Model eğitimi, 256 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. val/box_loss değerinin 1,88'den 1,19'a, val/cls_loss değerinin 2,24'ten 0,53'e ve val/dfl_loss değerinin 1,54'ten 1,10'a indirilmesi, modelin genel olarak başarılı bir eğitim süreci geçirdiğini göstermektedir (Şekil 4.4).


Brucal ve diğerleri (2023) tarafından yapılan çalışmada, TensorFlow 2 Nesne Tespit API'si kullanılarak Single Shot Detector (SSD) MobileNetV2 Nesne Tespit modeli ile domates yaprak hastalığının tespit edilmesi için bir yazılım prototipi oluşturulmuştur. Prototip, domates yaprağının durumunu tanımlamak, tespit etmek ve içinde bulunan hastalığı belirlemek amacıyla geliştirilmiştir. Eğitim sırasında, modelin öğrenme oranı 1300 adımda 0'dan 0,7999'a yükselmiş ve daha sonra 0,7999'dan yavaşça 0,7796'ya düşmüştür. Eğitim sonrasında, modelin toplam kaybı değerlendirme için %46,95 ve eğitim sonuçları için %45,32 olarak belirlenmiştir. Modelin ortalama geri çağırma oranı belirtilmemiş olup, bu çalışmanın sonuçları modelin domates yaprak hastalığını tespit etmede başarılı bir eğitim süreci geçirdiğini göstermektedir.



Şekil 4.4. Zararlı Tespiti (Detection) amacıyla eğitilen MobileNet SSD v2 Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Görüntüler üzerinden zararlı tespiti amacıyla Detectron2 modelinin eğitim süreci incelendiğinde, modelin kayıp metriklerinde belirgin değişiklikler gözlemlenmiştir. train/box_loss değerinin başlangıçta 1,38 olup süreç sonunda 0,68'e indirilmesi, modelin mekansal yerelleştirme yeteneğinde önemli ilerlemeler kaydettiğini belirtmektedir. Bununla birlikte, train/cls_loss değerinin başlangıçta 3,01'den 0,47'ye düşürülmesi, modelin nesneleri daha doğru sınıflara atama konusundaki başarısını vurgulamaktadır. Ayrıca, train/dfl_loss değerinin 1,60'dan 1,03'e düşmesi, modelin nesnelerin şekil değişikliklerini daha hassas bir şekilde tahmin edebildiği sonucunu ortaya koymaktadır. Doğrulama verileri için de benzer bir başarı söz konusudur (Box_loss: nesnenin konumunu, cls_loss: sınıflandırma doğruluğunu, dfl_loss nesnenin şekil tahminini, Epoch tüm eğitim örneklerinin model tarafından bir kez işlendiği döngü).

Model eğitimi, 153 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. val/box_loss değerinin 1,21'den 0,67'ye, val/cls_loss değerinin 3,54'ten 0,44'e ve val/dfl_loss değerinin 1,69'den 1,01'e indirilmesi, modelin genel olarak başarılı bir eğitim süreci geçirdiğini göstermektedir (Şekil 4.5).




Epoch	Eğitim (Training)			Doğrulama (Validation)		
	Box Loss	Cls Loss	Dfl Loss	Box Loss	Cls Loss	Dfl Loss
0	1.3758	3.0092	1.5981	1.206	3.5356	1.6873
15	0.9894	1.1229	1.2083	1.5191	2.1082	2.0428
30	0.91257	0.79033	1.1468	1.1323	1.4615	1.4665
45	0.85126	0.67427	1.1254	0.85512	0.65642	1.2381
60	0.83255	0.59195	1.1131	0.9501	0.77647	1.2398
75	0.7243	0.54971	1.0528	0.79469	0.61724	1.1246
90	0.73661	0.51796	1.0567	0.84519	0.59138	1.1696
105	0.69077	0.48904	1.0304	0.75567	0.46505	1.0613
120	0.69709	0.48326	1.0533	0.74718	0.45659	1.0524
135	0.69793	0.49252	1.0515	0.72833	0.43614	1.0162
153	0.68098	0.46878	1.026	0.66958	0.43777	1.0075

Şekil 4.5. Zararlı Tespiti (Detection) amacıyla eğitilen Detectron2 Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Görüntüler üzerinden zararlı tespiti amacıyla GroundingDINO modelinin eğitim süreci incelendiğinde, modelin kayıp metriklerinde belirgin değişiklikler gözlemlenmiştir. train/box_loss değerinin başlangıçta 2,69 olup süreç sonunda 0,99'e indirilmesi, modelin mekansal yerleştirme yeteneğinde önemli ilerlemeler kaydettiğini belirtmektedir. Bununla birlikte, train/cls_loss değerinin başlangıçta 3,50'den 0,61'e düşürülmesi, modelin nesneleri daha doğru sınıflara atama konusundaki başarısını vurgulamaktadır. Ayrıca, train/dfl_loss değerinin 2,15'ten 0,94'e düşmesi, modelin nesnelerin şekil değişikliklerini daha hassas bir şekilde tahmin edebildiği sonucunu ortaya koymaktadır. Doğrulama verileri için de benzer bir başarı söz konusudur (Box_loss: nesnenin konumunu, cls_loss: sınıflandırma doğruluğunu, dfl_loss nesnenin şekil tahminini, Epoch tüm eğitim örneklerinin model tarafından bir kez işlendiği döngü).

Model eğitimi, 279 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. val/box_loss değerinin 2,56'dan 1,08'e, val/cls_loss değerinin 3,58'ten 0,66'e ve val/df_loss değerinin 2,27'den 0,99'e indirilmesi, modelin genel olarak başarılı bir eğitim süreci geçirdiğini göstermektedir (Şekil 4.6).




Şekil 4.6. Zararlı Tespiti (Detection) amacıyla eğitilen GroundingDINO Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Görüntüler üzerinden zararlı tespiti amacıyla Faster R-CNN modelinin eğitim süreci incelendiğinde, modelin kayıp metriklerinde belirgin değişiklikler gözlemlenmiştir. train/box_loss değerinin başlangıçta 2,20 olup süreç sonunda 0,78'e indirilmesi, modelin mekansal yerleştirme yeteneğinde önemli ilerlemeler kaydettiğini belirtmektedir. Bununla birlikte, train/cls_loss değerinin başlangıçta 3,20'den 0,54'e düşürülmesi, modelin nesneleri daha doğru sınıflara atama konusundaki başarısını vurgulamaktadır.

Ayrıca, train/dfl_loss değerinin 1,94'ten 0,96'e düşmesi, modelin nesnelerin şekil değişikliklerini daha hassas bir şekilde tahmin edebildiği sonucunu ortaya koymaktadır. Doğrulama verileri için de benzer bir başarı söz konusudur (Box_loss: nesnenin konumunu, cls_loss: sınıflandırma doğruluğunu, dfl_loss nesnenin şekil tahminini, Epoch tüm eğitim örneklerinin model tarafından bir kez işlendiği döngü). Model eğitimi, 220 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. val/box_loss değerinin 3,33'den 0,91'e, val/cls_loss değerinin 6,76'tan 0,51'e ve val/dfl_loss değerinin 2,41'den 0,95'e indirilmesi, modelin genel olarak başarılı bir eğitim süreci geçirdiğini göstermektedir (Şekil 4.7).

Fuentes ve diğerlerinin (2017) yürüttüğü "Gerçek Zamanlı Domates Bitkisi Hastalık ve Zararlılarının Tespiti İçin Güçlü Bir Derin Öğrenme Tabanlı Dedektör" başlıklı çalışma, çeşitli çözünürlüklere sahip kamera cihazlarıyla yerinde yakalanan görüntüler kullanılarak domates bitkilerinde hastalık ve zararlıların tespiti için bir derin öğrenme tabanlı yaklaşım sunmaktadır. Araştırmacılar, domates bitkilerindeki farklı türdeki hastalık ve zararlıların gerçek zamanlı tespit ve tanınması için Faster R-CNN dahil olmak üzere, çeşitli derin öğrenme meta mimarilerinin etkinliğini araştırmışlardır. Bu görev için en uygun derin öğrenme mimarisini bulmayı amaçlayan ekip, derin meta mimarileri VGG net ve ResNet gibi derin özellik çıkarıcılarla birleştirmiştir. Sistem, geniş bir Domates Hastalık ve Zararlıları Veri Seti üzerinde baştan sona eğitilmiş ve test edilmiş olup, dokuz farklı türdeki hastalık ve zararlıyı etkin bir şekilde tanıyabileceğini, bitkinin çevresindeki karmaşık senaryolarla başa çıkma potansiyelini göstermiştir.




Epoch	Eğitim (Training)			Doğrulama (Validation)		
	Box Loss	Cls Loss	Dfl Loss	Box Loss	Cls Loss	Dfl Loss
0	2.1969	3.2038	1.9416	3.331	6.7627	2.4129
22	1.3722	1.3288	1.2242	2.2509	1.9715	1.5817
44	1.1493	0.97199	1.0992	1.3386	1.0221	1.1152
66	1.0763	0.80377	1.0536	1.3848	0.91685	1.1139
88	0.9676	0.71029	1.011	1.2494	0.71809	1.0312
110	0.95642	0.67347	1.0122	1.4035	0.74727	1.1199
132	0.89554	0.62549	0.98335	1.0827	0.62849	0.9969
154	0.8536	0.57575	0.97121	0.88177	0.57955	0.94747
176	0.86049	0.57961	0.96455	0.95383	0.53013	0.96811
198	0.82799	0.59359	0.96459	0.75159	0.54079	0.93121
220	0.78037	0.536	0.95697	0.91448	0.50904	0.94544

Şekil 4.7. Zararlı Tespiti (Detection) amacıyla eğitilen Faster R-CNN Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Segmentasyon yeteneğine sahip modellerin eğitimi için 9000 adet domates yaprağı ve domates meyve görüntüsünden oluşan bir veri seti kullanılmıştır. Bu veri seti, toplamda 9 farklı etikete sahiptir. Bu etiketler şunlardır: "*L. bryoniae* zararı", "*T. absoluta* zararı (meyvede)", "*Thrips* zararı", "Sağlıklı domates yaprakları", "Akar zararı (yaprakta)", "Sağlıklı domates meyveleri", "*H. armigera* zararı" ve "*T. absoluta* zararı (yaprakta)". Segmentasyon amacıyla bu çalışmada kullanılan modeller: Mask RCNN, Segment Anything Model (SAM) ve YOLOv8.

Görüntüler üzerinden segmentasyon yöntemiyle zararlı tespiti amacıyla Mask RCNN modelinin eğitim süreci detaylandırıldığında, modelin kayıp metriklerinde belirleyici değişiklikler göze çarpmaktadır. Eğitim sürecinde, train/box_loss değeri 1,07 başlangıç değerinden 0,49'a kadar azalmıştır. Bu durum, modelin mekansal yerleştirme kapasitesinde ciddi ilerlemeler kaydettiğini işaret etmektedir. Aynı şekilde, train/cls_loss değeri 2,70'ten 0,33'e düşmüştür, bu da modelin nesneleri daha doğru kategorilere tahsis edebildiğini göstermektedir. Ek olarak, train/df_l_loss değeri 1,30'dan 0,93'e düşmüştür, bu da modelin şekil değişikliklerini daha doğru tahmin edebildiğini ortaya koymaktadır. Doğrulama verileri için de modelin performansı olumlu bir trend göstermektedir. val/box_loss 1,00'dan 0,31'e, val/cls_loss 2,82'den 0,21'e ve val/df_l_loss 1,29'dan 0,79'a azalmıştır (Box_loss: nesnenin konumunu, cls_loss: sınıflandırma doğruluğunu, df_l_loss nesnenin şekil tahminini, Epoch tüm eğitim örneklerinin model tarafından bir kez işlendiği döngü). Model eğitimi, 569 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Bu sonuçlar, Mask RCNN modelinin eğitim sürecinde etkili bir şekilde öğrendiğini ve genel olarak başarılı bir performans sergilediğini göstermektedir (Şekil 4.8).

Afonso ve diğerlerinin (2020) tarafından yapılan "Sera Ortamında Derin Öğrenme Kullanılarak Domates Meyve Tespiti ve Sayımı" başlıklı çalışmada, sera içi görüntülerde domatesleri tespit etmek için Mask R-CNN algoritması kullanılmıştır. Algoritma, laboratuvar koşullarında veya daha yüksek çözünürlüklü görüntüler kullanılarak yapılan önceki çalışmalara kıyasla karşılaştırılabilir veya üstün performans metrikleri ile domatesleri başarıyla tanımlamıştır. Araştırma, Mask R-CNN'nin nesne derinliğini dolaylı olarak öğrenebilme kapasitesini vurgulamakta, bu da arka planın elemine edilmesi için hayati önem taşımaktadır ve domates yaprakları ve meyvelerinde zararlı tespiti gibi detaylı segmentasyon görevleri için potansiyelini göstermektedir. Çalışma, özellikle Mask R-CNN gibi derin öğrenme yöntemlerinin, geleneksel bilgisayar görüşü yöntemlerinden daha etkili bir şekilde büyük veri çeşitliliği ile başa çıkarak tarımsal alanlardaki zorlukları ele alma vaadini vurgulamaktadır.




Epoch	Eğitim (Training)			Doğrulama (Validation)		
	Box Loss	Cls Loss	Dfl Loss	Box Loss	Cls Loss	Dfl Loss
0	1.0663	2.7017	1.3001	1.0085	2.8213	1.2911
57	0.75637	0.52918	1.0536	0.70813	0.47087	1.0351
114	0.6367	0.42801	0.99511	0.56446	0.35241	0.93098
171	0.5852	0.38337	0.97356	0.49122	0.3124	0.89251
228	0.55788	0.37026	0.96094	0.44621	0.28659	0.8639
285	0.53906	0.35772	0.96054	0.4089	0.26546	0.84007
342	0.53012	0.34439	0.94703	0.38379	0.24505	0.82778
399	0.50586	0.33565	0.94255	0.35733	0.24102	0.81325
456	0.50184	0.32884	0.94221	0.3402	0.22798	0.80685
513	0.4821	0.31852	0.93059	0.31919	0.21591	0.79632
569	0.48906	0.32704	0.93396	0.31213	0.21342	0.79023

Şekil 4.8. Zararlı Segmentasyonu (Segmentation) amacıyla eğitilen Mask RCNN Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Görüntüler üzerinden segmentasyon yöntemiyle zararlı tespiti amacıyla YOLOv8 modelinin eğitim süreci detaylandırıldığında, modelin kayıp metriklerinde belirleyici değişiklikler göze çarpmaktadır. Eğitim sürecinde, train/box_loss değeri 1,97 başlangıç değerinden 0,57'ye kadar azalmıştır. Bu durum, modelin mekansal yerleştirme kapasitesinde ciddi ilerlemeler kaydettiğini işaret etmektedir. Aynı şekilde, train/cls_loss değeri 4,04'ten 0,37'ye düşmüştür, bu da modelin nesneleri daha doğru kategorilere tahsis edebildiğini göstermektedir. Ek olarak, train/dfl_loss değeri 1,56'dan 0,86'ya düşmüştür, bu da modelin şekil değişikliklerini daha doğru tahmin edebildiğini ortaya koymaktadır. Doğrulama verileri için de modelin performansı olumlu bir trend göstermektedir. val/box_loss 1,99'dan 0,74'e, val/cls_loss 2,65'den 0,37'ye ve val/dfl_loss 1,45'den 0,92'ye azalmıştır.

Model eğitimi, 372 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Bu sonuçlar, YOLOv8 modelinin eğitim sürecinde etkili bir şekilde öğrendiğini ve genel olarak başarılı bir performans sergilediğini göstermektedir (Şekil 4.9).

Yang ve diğerlerinin (2023) yürüttüğü "A Lightweight YOLOv8 Tomato Detection Algorithm Combining Feature Enhancement and Attention" başlıklı çalışma, domates hasadı otomasyonunda karşılaşılan zorluklara çözüm getirmek amacıyla iyileştirilmiş bir YOLOv8 modeli önermiştir. Bu araştırma, YOLOv8'in mekansal tanıma ve özellik tespit yeteneklerini geliştiren bir yöntem geliştirerek, gerçek zamanlı tarımsal uygulamalar için uygun hale getirmiştir. Yaklaşımlarının temel bileşenleri arasında hesaplama karmaşıklığını azaltmak için derinlik ayrılabilir konvolüsyon (DSConv), karmaşık çevrelerde tespit hassasiyetini artırmak için çift yönlü dikkat kapısı modülü (DPAG) ve hedef detaylarını vurgulayarak tespit hassasiyetini iyileştirmek için özellik geliştirme modülü (FEM) bulunmaktadır. Modifiye edilmiş YOLOv8 modeli, mevcut modellere kıyasla hassasiyet, geri çağırma oranları ve ortalama hassasiyet puanı (mAP) konularında önemli iyileştirmeler sağlayarak, çeşitli koşullarda domatesleri tespit etmede etkinliğini kanıtlamıştır. Bu çalışma, YOLOv8 gibi gelişmiş derin öğrenme modellerinin, tarımsal üretkenliği otomasyon aracılığıyla artırma potansiyelini sergilemektedir.




Epoch	Eğitim (Training)			Doğrulama (Validation)		
	Box Loss	Cls Loss	Dfl Loss	Box Loss	Cls Loss	Dfl Loss
0	1.974	4.0393	1.5637	1.9872	2.651	1.4465
37	1.1439	0.69735	1.07	1.3111	0.80996	1.0845
74	0.93986	0.58198	0.98899	1.0527	0.56223	1.0093
111	0.87666	0.51228	0.94331	0.93236	0.49729	0.98978
148	0.78605	0.4912	0.93015	0.90971	0.47916	1.0135
185	0.70537	0.44409	0.89158	0.82682	0.42278	0.93856
222	0.67786	0.43211	0.88945	0.80318	0.4102	0.95813
259	0.63001	0.40762	0.89193	0.79066	0.40143	0.95301
296	0.6496	0.40284	0.87237	0.78541	0.36381	0.9615
333	0.56871	0.36716	0.86174	0.72806	0.37794	0.93859
372	0.56919	0.37184	0.8649	0.73804	0.36781	0.9182

Şekil 4.9. Zararlı Segmentasyonu (Segmentation) amacıyla eğitilen YOLOv8 Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

Görüntüler üzerinden segmentasyon yöntemiyle zararlı tespiti amacıyla SAM modelinin eğitim süreci detaylandırıldığında, modelin kayıp metriklerinde belirleyici değişiklikler göze çarpmaktadır. Eğitim sürecinde, train/box_loss değeri 2,37 başlangıç değerinden 0,90'a kadar azalmıştır. Bu durum, modelin mekansal yerleştirme kapasitesinde ciddi ilerlemeler kaydettiğini işaret etmektedir. Aynı şekilde, train/cls_loss değeri 3,47'den 0,55'e düşmüştür, bu da modelin nesneleri daha doğru kategorilere tahsis edebildiğini göstermektedir. Ek olarak, train/dfl_loss değeri 1,65'ten 0,87'a düşmüştür, bu da modelin şekil değişikliklerini daha doğru tahmin edebildiğini ortaya koymaktadır. Doğrulama verileri için de modelin performansı olumlu bir trend göstermektedir. val/box_loss 2,17'den 1,02'ye, val/cls_loss 3,52'den 0,60'a ve val/dfl_loss 1,75'ten 0,89'a azalmıştır (Box_loss: nesnenin konumunu, cls_loss: sınıflandırma doğruluğunu, dfl_loss nesnenin şekil tahminini, Epoch tüm eğitim örneklerinin model tarafından bir kez işlendiği döngü).

Model eğitimi, 521 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Bu sonuçlar, SAM modelinin eğitim sürecinde etkili bir şekilde öğrendiğini ve genel olarak başarılı bir performans sergilediğini göstermektedir (Şekil 4.10). Gao ve diğerleri (2016) tarafından yapılan "Çin'de Domates Yaprak Lekesi Hastalığının *Fusarium proliferatum* ile İlk Raporu" başlıklı çalışmada, ticari bir domates serasında ciddi bir yaprak lekesi hastalığını tartışmakta ve morfolojik özellikler ile çoklu genlerin PCR amplifikasyonu ve dizi analizi temelinde *F. proliferatum*'u neden olan patojen olarak tanımlamaktadır. Bu çalışma, domates yetiştiriciliğinde hastalıkların tanımlanması ve yönetilmesinin önemini vurgulamakta ve SAM gibi modellerin zararlı ve hastalık tespiti için geliştirilmesinin başarısını vurgulamaktadır.



Epoch	Eğitim (Training)			Doğrulama (Validation)		
	Box Loss	Cls Loss	Dfl Loss	Box Loss	Cls Loss	Dfl Loss
0	2.3668	3.471	1.6495	2.1754	3.5164	1.7452
52	1.5253	1.0418	1.0442	1.606	1.0979	1.0899
104	1.3191	0.8362	0.97289	1.464	0.90418	1.0128
156	1.243	0.76343	0.94645	1.2624	0.76825	0.94999
208	1.1753	0.70721	0.92458	1.2457	0.75755	0.94835
260	1.0855	0.64844	0.91059	1.1756	0.72116	0.92721
312	1.0283	0.62365	0.89158	1.2058	0.7184	0.93306
364	1.011	0.60072	0.88555	1.0804	0.65521	0.90666
416	0.94857	0.58157	0.87707	1.053	0.64746	0.89598
468	0.96828	0.56662	0.87549	1.029	0.61231	0.8938
521	0.9045	0.55103	0.86807	1.0222	0.60436	0.8851


Şekil 4.10. Zararlı Segmentasyonu (Segmentation) amacıyla eğitilen SAM Modelinin Eğitim (Training) ve Doğrulama (Validation) Kayıp (Loss) Değerlerinin Epoch Sayısına Göre Değişimi.

4.2. Performans Değerlendirme Metrikleri: Recall, Precision, mAP

Precision, modelin doğru sınıflandırdığı nesnelerin oranını belirtirken; Recall, gerçekte mevcut olan nesnelerden kaç tanesinin model tarafından doğru bir şekilde tespit edildiğini gösterir. Bu iki metrik, modelin hem doğruluğunu hem de duyarlılığını yansıtarak algoritmanın genel güvenilirliğini ortaya koymaktadır. mAP50 ve mAP50-95 gibi Ortalama Hassasiyet (mAP) değerleri ise modelin farklı IoU (Intersection over Union) eşiklerindeki performansını özetler. Özellikle mAP50-95, modelin çeşitli zorluk seviyelerindeki nesneleri ne kadar iyi tespit edebildiğini değerlendiren geniş kapsamlı bir metriktir. Precision (kesinlik), bir modelin pozitif (doğru sınıflandırma) olarak sınıflandırdığı nesnelerin ne kadarının gerçekten pozitif olduğunu gösteren bir ölçüdür. Precision oranının 100'e yakın olması, modelin pozitif tahminlerinin neredeyse tamamen doğru olduğunu ve yanlış pozitiflerin çok nadir olduğunu gösterir, yani modelin pozitif tahminleri son derece güvenilirdir. Bu metriklerin kapsamlı bir şekilde değerlendirilmesi, modelin gerçek dünya senaryolarında nasıl performans göstereceği hakkında daha derinlemesine bir fikir edinmemizi sağlar ve modelin potansiyel zayıf yönlerini belirlemekte kritik bir rol oynar.

YOLOv8 modelinin nesne tespiti amacıyla eğitilmesi esnasında, eğitim değerlendirme metriklerinde önemli iyileşmeler olmuştur. Eğitimin başında, modelin Precision değeri %0,62 iken bu oran %98,91'e çıkmıştır. Aynı şekilde Recall değeri %75,13'ten %98,98'e, mAP50 değeri %5,64'ten %98,75'e ve mAP50-95 değeri %1,70'ten %97,72'ye yükselmiştir. Model eğitimi, 749 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Bu metriklerin tümü, modelin nesne tespiti konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl arttığını göstermektedir. Özellikle mAP50 ve mAP50-95 değerlerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu kanıtlamaktadır (Şekil 4.11).


"Özellik Geliştirme ve Dikkat Birleştiren Hafif YOLOv8 Domates Tespit Algoritması" başlıklı çalışma, Yang ve diğerleri (2023) tarafından gerçekleştirilmiştir. Bu araştırma, tarımsal faaliyetlerde otomasyonu desteklemek üzere tasarlanmış, domateslerin otomatik tespiti için bir yöntem önermektedir. Çalışmada sunulan geliştirilmiş YOLOv8s modeli, karmaşık çevrelerde tespit hassasiyetini artırmak için bir dizi yenilikçi teknik içermektedir; örneğin, hesaplama karmaşıklığını azaltmak için derinlik ayırıcı konvolüsyon (DSConv) ve domatesler ile arka planları daha iyi ayırt etmeyi sağlayan çift yönlü dikkat kapısı modülü (DPAG) gibi. Yöntem, 3098 görüntü içeren bir veri seti üzerinde değerlendirilmiş ve model performansında önemli bir iyileşme göstermiştir. Elde edilen ortalama kesinlik (mAP) %93,4 olup, bu oran önceki modellere kıyasla bir artışı temsil etmektedir. Bu iyileşme, modelin domatesleri doğru bir şekilde tespit etme yeteneğinin arttığını vurgulamakta ve tarımsal üretimin pratik ihtiyaçlarını desteklemektedir.



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.00624	0.75127	0.05642	0.017045
75	0.95323	0.88832	0.93953	0.8851675
150	0.97934	0.96237	0.98315	0.9278675
225	0.96437	0.96184	0.98022	0.925265
300	0.97955	0.97248	0.98814	0.9396575
375	0.97497	0.98856	0.98533	0.94145
450	0.98477	0.98451	0.99102	0.9542325
525	0.98948	0.97462	0.98655	0.96196
600	0.98788	0.9797	0.98683	0.9606925
675	0.96779	0.98985	0.97552	0.954625
749	0.98912	0.98985	0.98747	0.977215

Şekil 4.11. Zararlı Tespiti (Detection) amacıyla eğitilen YOLOv8 Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.


MobileNet SSD v2 modelinin nesne tespiti amacıyla eğitilmesi esnasında, eğitim değerlendirme metriklerinde belirgin iyileşmeler gözlemlenmiştir. Başlangıçta, modelin Precision değeri %53,52 iken bu oran %96,39'a çıkmıştır. Aynı şekilde Recall değeri %34,53'ten %95,80'e, mAP50 değeri %35,97'den %97,36'ya ve mAP50-95 değeri %14,65'ten %63,96'ya yükselmiştir. Model eğitimi, 256 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Bu metriklerin tümü, modelin nesne tespiti konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl arttığını göstermektedir. Özellikle mAP50 ve mAP50-95 değerlerindeki önemli artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu ortaya koymaktadır (Şekil 4.12). Fuentes ve diğerleri (2017) tarafından yapılan "Gerçek Zamanlı Domates Bitkilerinde Hastalık ve Zararlıları Tanıma için Güçlü Derin Öğrenme Tabanlı Dedektör" başlıklı çalışma, gerçek zamanlı olarak yakalanan görüntüler kullanılarak domates bitkilerindeki hastalık ve zararlıların tespiti için derin öğrenme tabanlı bir yaklaşım sunmaktadır. Araştırmacılar, VGG ağı ve ResNet gibi çeşitli derin özellik çıkarıcılarla birleştirilmiş Faster R-CNN, R-FCN ve SSD gibi farklı derin öğrenme mimarilerini değerlendirmişlerdir. Sistemleri, domates bitkilerindeki dokuz farklı hastalık ve zararlı türünü etkili bir şekilde tanıma kapasitesini göstermiş, derin öğrenme modellerinin tarımda zararlı ve hastalık tespitindeki doğruluğu artırma potansiyelini ortaya koymuştur.



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.53521	0.34529	0.35968	0.14655
25	0.93846	0.95733	0.95596	0.54531
50	0.95257	0.9417	0.98086	0.58511
75	0.9472	0.96528	0.98558	0.61476
100	0.93906	0.97758	0.97802	0.63011
125	0.93452	0.96413	0.9823	0.61774
150	0.98875	0.91928	0.9858	0.66171
175	0.9581	0.92295	0.97705	0.61911
200	0.95794	0.95964	0.9849	0.62581
225	0.95531	0.95855	0.97169	0.62261
256	0.9639	0.95798	0.9736	0.63964

Şekil 4.12. Zararlı Tespiti (Detection) amacıyla eğitilen MobileNet SSD v2 Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.

GroundingDINO modelinin nesne tespiti amacıyla eğitilmesi sürecinde, eğitim değerlendirme metriklerinde belirgin bir iyileşme kaydedilmiştir. Eğitimin başlangıcında, modelin Precision değeri %0,70 iken bu değer %88,34'e yükselmiştir. Benzer şekilde, Recall değeri %12,45'ten %85,50'ye, mAP50 değeri %0,45'ten %89,33'e ve mAP50-95 değeri %0,15'ten %61,60'a çıkmıştır. Bu metriklerin tümü, GroundingDINO modelinin nesne tespiti konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl geliştiğini göstermektedir. Model eğitimi, 279 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Özellikle mAP50 ve mAP50-95 metriklerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu kanıtlamaktadır (Şekil 4.13).




Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.00698	0.12454	0.00445	0.00153
28	0.57435	0.58364	0.58457	0.26772
56	0.72385	0.59929	0.67277	0.34306
84	0.78692	0.75093	0.82174	0.45979
112	0.82721	0.75465	0.8347	0.49734
140	0.83917	0.80669	0.86493	0.5355
168	0.83947	0.83271	0.87339	0.5577
196	0.84081	0.81227	0.86054	0.56312
224	0.80226	0.79936	0.81005	0.51184
252	0.85868	0.86966	0.89023	0.5891
279	0.88341	0.85502	0.89332	0.61603

Şekil 4.13. Zararlı Tespiti (Detection) amacıyla eğitilen GroundingDINO Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.

Faster R-CNN modelinin nesne tespiti amacıyla eğitilmesi sürecinde, eğitim değerlendirme metriklerinde belirgin bir iyileşme kaydedilmiştir. Eğitimin başlangıcında, modelin Precision değeri %0,62 iken bu oran %96,88'e yükselmiştir. Benzer şekilde, Recall değeri %23,74'ten %93,00'e, mAP50 değeri %0,91'ten %96,81'e ve mAP50-95 değeri %0,29'ten %75,44'e çıkmıştır. Bu metriklerin tümü, Faster R-CNN modelinin nesne tespiti konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl geliştiğini göstermektedir. Model eğitimi, 220 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Özellikle mAP50 ve mAP50-95 metriklerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu ortaya koymaktadır (Şekil 4.14).


Fuentes ve diğerleri (2017) tarafından yapılan "Gerçek Zamanlı Domates Bitkisi Hastalık ve Zararlılarının Tespiti İçin Güçlü Derin Öğrenme Tabanlı Dedektör" başlıklı çalışma, çeşitli çözünürlüklere sahip kamera cihazları ile çekilen görüntüler kullanılarak domates bitkilerinde hastalık ve zararlıların tespiti için derin öğrenme tabanlı bir yaklaşım sunmaktadır. Yazarlar, görev için en uygun derin öğrenme mimarisini bulmayı amaçlamış ve bu bağlamda, Faster Bölge-tabanlı Evrişimli Sinir Ağı (Faster R-CNN), Bölge-tabanlı Tamamen Evrişimli Ağ (R-FCN) ve Tek Atışlı Çok Kutulu Dedektör (SSD) gibi üç ana dedektör ailesini, VGG ağı ve Kalıntı Ağı (ResNet) gibi derin özellik çıkarıcıları ile birleştirmişlerdir. Bu mimarilerin performansını göstermek ve eğitim sırasında doğruluğu artırmak ve yanlış pozitifleri azaltmak için yerel ve global sınıf anotasyonu ve veri artırma yöntemi önermişlerdir. Sistem, zorlu görüntüler içeren büyük bir Domates Hastalık ve Zararlıları Veri Seti üzerinde baştan sona eğitilmiş ve test edilmiş, dokuz farklı türde hastalık ve zararlıyı etkili bir şekilde tanıyabilmiş ve bitkinin çevresindeki karmaşık senaryolarla başa çıkabilmiştir.



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.00616	0.23735	0.00913	0.00285
22	0.72273	0.60311	0.67383	0.37507
44	0.85771	0.76654	0.86198	0.52784
66	0.92401	0.80934	0.89491	0.56557
88	0.90348	0.8716	0.94296	0.65478
110	0.91933	0.92607	0.97088	0.64947
132	0.94145	0.87585	0.96188	0.69409
154	0.97639	0.89883	0.96061	0.74003
176	0.96085	0.95508	0.98481	0.75577
198	0.95172	0.9204	0.95847	0.74288
220	0.96881	0.92996	0.96808	0.75435

Şekil 4.14. Zararlı Tespiti (Detection) amacıyla eğitilen Faster R-CNN Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.


EfficientDet (D7) modelinin nesne tespiti amacıyla eğitilmesi sürecinde, eğitim değerlendirme metriklerinde belirgin bir gelişme göstermiştir. Eğitimin başlangıcında, modelin Precision değeri %1,1 iken bu oran %88,54'e çıkmıştır. Aynı şekilde, Recall değeri %41,62'den %88,25'e, mAP50 değeri %3,89'den %91,94'e ve mAP50-95 değeri %1,98'den %66,14'e yükselmiştir. Bu metriklerin tümü, EfficientDet (D7) modelinin nesne tespiti konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl geliştiğini göstermektedir. Model eğitimi, 409 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Özellikle mAP50 ve mAP50-95 metriklerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu ortaya koymaktadır (Şekil 4.15).



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.01309	0.41618	0.03893	0.01981
41	0.74511	0.76301	0.80173	0.42075
82	0.83827	0.842	0.86411	0.51996
123	0.89219	0.87669	0.91693	0.57202
164	0.85678	0.8991	0.90297	0.5969
205	0.85786	0.842	0.89943	0.60256
246	0.88741	0.89598	0.93444	0.64112
287	0.84842	0.90594	0.91562	0.61578
328	0.87175	0.91715	0.91915	0.65067
369	0.90937	0.90867	0.93845	0.67399
409	0.88535	0.88247	0.91944	0.66137

Şekil 4.15. Zararlı Tespiti (Detection) amacıyla eğitilen EfficientDet (D7) Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.


DETR modelinin nesne tespiti amacıyla eğitilmesi sürecinde, eğitim değerlendirme metriklerinde belirgin bir gelişme kaydedilmiştir. Eğitimin başlangıcında, modelin Precision değeri %36,49 iken bu oran %99,25'e çıkmıştır. Aynı şekilde, Recall değeri %43,84'ten %99,77'ye, mAP50 değeri %39,06'ten %99,50'ye ve mAP50-95 değeri %21,33'ten %88,84'e yükselmiştir. Bu metriklerin tümü, DETR modelinin nesne tespiti konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl geliştiğini göstermektedir. Model eğitimi, 256 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Özellikle mAP50 ve mAP50-95 metriklerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu ortaya koymaktadır (Şekil 4.16).



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.36495	0.43841	0.39061	0.21332
25	0.93028	0.93752	0.96057	0.69309
50	0.9734	0.94779	0.98575	0.7675
75	0.99749	0.95168	0.99358	0.80506
100	0.96472	0.98032	0.99373	0.81329
125	0.97246	0.99451	0.9941	0.86065
150	0.97391	0.99988	0.99431	0.84061
175	0.99236	0.95927	0.99376	0.88863
200	0.98785	0.94765	0.98431	0.87739
225	0.95382	0.96994	0.99056	0.86524
256	0.99251	0.99767	0.995	0.88836

Şekil 4.16. Zararlı Tespiti (Detection) amacıyla eğitilen DETR Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.


Detectron2 modelinin nesne tespiti amacıyla eğitilmesi sürecinde, eğitim değerlendirme metriklerinde belirgin bir gelişme göstermiştir. Eğitimin başlangıcında, modelin Precision değeri %0,40 iken bu oran %97,23'e çıkmıştır. Aynı şekilde, Recall değeri %98,08'den %96,15'e, mAP50 değeri %15,10'den %99,00'e ve mAP50-95 değeri %5,84'ten %81,14'e yükselmiştir. Bu metriklerin tümü, Detectron2 modelinin nesne tespiti konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl geliştiğini göstermektedir. Model eğitimi, 153 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Özellikle mAP50 ve mAP50-95 metriklerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu ortaya koymaktadır (Şekil 4.17).



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.00395	0.98077	0.15095	0.05835
15	0.52133	0.67308	0.6206	0.30865
30	0.78664	0.71154	0.85239	0.54917
45	0.96121	0.95311	0.97468	0.73263
60	0.94835	0.84615	0.90877	0.67149
75	0.95852	0.88884	0.96686	0.71707
90	0.91019	0.97457	0.95851	0.72583
105	0.94518	0.99473	0.98816	0.7956
120	0.99145	0.98077	0.99481	0.79745
135	0.94493	0.99	0.98908	0.78327
153	0.97225	0.96154	0.98997	0.81137

Şekil 4.17. Zararlı Tespiti (Detection) amacıyla eğitilen Detectron2 Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.


Mask RCNN modelinin nesne segmentasyonu amacıyla eğitilmesi sürecinde, eğitim değerlendirme metriklerinde kayda değer bir ilerleme kaydedilmiştir. Eğitimin başlangıcında, modelin Precision değeri %77,69 iken bu oran %99,69'a çıkmıştır. Aynı şekilde, Recall değeri %21,98'den %99,34'e, mAP50 değeri %32,04'ten %99,49'a ve mAP50-95 değeri %23,04'ten %96,38'e yükselmiştir. Bu metriklerin tümü, Mask RCNN modelinin nesne segmentasyonu konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl geliştiğini göstermektedir. Model eğitimi, 569 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Özellikle mAP50 ve mAP50-95 metriklerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu ortaya koymaktadır (Şekil 4.18). Mask R-CNN modelinin sera domates üretiminde zararlı analizi için eğitimi üzerine yapılan bir çalışmada, tarımda zararlı ve hastalık yönetiminin geliştirilmesi amacıyla ileri tespit ve segmentasyon tekniklerinin uygulanmasıyla ilgili benzer bir yaklaşım sunan bir araştırma bulunmuştur. Bu bağlamda, ilgili bir araştırma, Zu ve diğerleri (2021) tarafından yapılan ve Mask R-CNN algoritmasını kullanarak olgun yeşil domateslerin tespiti ve segmentasyonu üzerine yapılan çalışmadır. Bu çalışma, modelin, örneğin yapraklar tarafından gizlendiği veya diğer domateslerle örtüştüğü zorlu koşullarda domatesleri doğru bir şekilde tanımlayıp yerlerini belirleme yeteneğini vurgulamaktadır. Model, sınırlayıcı kutu ve maske bölgesi için F1-Skorlarının her ikisi de %92,0 ulaşarak yüksek performans metrikleri elde etmiş ve Mask R-CNN'nin tarımsal uygulamadaki etkinliğini göstermiştir.



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.77689	0.21979	0.32043	0.2304
57	0.96665	0.94752	0.98765	0.80596
114	0.98789	0.98078	0.99416	0.87924
171	0.96851	0.99044	0.99361	0.90252
228	0.98409	0.98366	0.99423	0.91878
285	0.99436	0.99215	0.99462	0.92945
342	0.99563	0.99046	0.99467	0.93965
399	0.99435	0.99014	0.99484	0.95607
456	0.99645	0.99611	0.99496	0.95657
513	0.99266	0.99626	0.99491	0.96604
569	0.99688	0.99343	0.99494	0.96384

Şekil 4.18. Zararlı segmentasyonu (Segmentation) amacıyla eğitilen Mask RCNN Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.


SAM modelinin nesne segmentasyonu amacıyla eğitilmesi sürecinde, eğitim değerlendirme metriklerinde belirgin bir gelişme göstermiştir. Eğitimin başlangıcında, modelin Precision değeri %1,22 iken bu oran %86,46'ya çıkmıştır. Aynı şekilde, Recall değeri %8,59'dan %86,26'ya, mAP50 değeri %0,74'ten %91,63'e ve mAP50-95 değeri %0,32'den %60,31'e yükselmiştir. Bu metriklerin tümü, SAM modelinin nesne segmentasyonu konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl geliştiğini göstermektedir. Model eğitimi, 521 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Özellikle mAP50 ve mAP50-95 metriklerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu ortaya koymaktadır (Şekil 4.19).



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.01222	0.08594	0.00742	0.00316
52	0.69688	0.64918	0.6954	0.35449
104	0.75294	0.71428	0.77425	0.41522
156	0.79733	0.79474	0.8468	0.4986
208	0.80721	0.83036	0.86863	0.5146
260	0.81314	0.79129	0.86319	0.53723
312	0.82822	0.8192	0.86291	0.52485
364	0.83068	0.83817	0.89942	0.57656
416	0.82634	0.85505	0.88674	0.57441
468	0.83078	0.85156	0.90405	0.60174
521	0.86463	0.86255	0.91631	0.60309

Şekil 4.19. Zararlı segmentasyonu amacıyla eğitilen SAM Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.

YOLOv8 modelinin nesne segmentasyonu amacıyla eğitilmesi sürecinde, eğitim değerlendirme metriklerinde belirgin bir gelişme kaydedilmiştir. Eğitimin başlangıcında, modelin Precision değeri %64,61 iken bu oran %97,47'ye çıkmıştır. Aynı şekilde, Recall değeri %32,14'ten %98,81'e, mAP50 değeri %34,31'den %99,38'e ve mAP50-95 değeri %38,28'den %95,99'a yükselmiştir. Bu metriklerin tümü, YOLOv8 modelinin nesne segmentasyonu konusundaki doğruluğunun ve güvenilirliğinin eğitim sürecinde nasıl geliştiğini göstermektedir. Model eğitimi, 372 epoch'a ulaştığında ve kendini tekrarlamaya başladığında, aşırı uyum olasılığını azaltmak amacıyla otomatik olarak sonlandırılmıştır. Özellikle mAP50 ve mAP50-95 metriklerindeki büyük artış, modelin farklı Intersection over Union (IoU) eşiklerinde dahi yüksek bir başarıya sahip olduğunu ortaya koymaktadır (Şekil 4.20). Ahmad ve diğerlerinin (2022) "Applied Sciences" dergisinde yayımlanan "Deep Learning Based Detector YOLOv5 for Identifying Insect Pests" başlıklı çalışması, tarımsal üretimi etkileyen böcek zararlılarını tanımlamak için YOLOv5 modelinin kullanımını araştırmaktadır. Bu araştırma, derin öğrenme modellerinin, zararlıları erken aşamada doğru bir şekilde tanımlama potansiyelini vurgulamaktadır, böylece pestisitlere olan bağımlılığı azaltarak sürdürülebilir çiftçilik uygulamalarına katkıda bulunmaktadır. Çeşitli yapılandırmalara sahip YOLOv5 modeli (YOLOv5n, s, m, l, x), böcek zararlılarının bulunduğu 7046 görüntülük bir veri seti üzerinde eğitilmiş ve test edilmiştir. Özellikle YOLOv5x modeli, IP-23 veri setinde %98,3 ortalama doğruluk, %94,5 kesinlik oranı ve %97,8 hatırlama oranı ile olağanüstü bir performans sergilemiştir. Bu sonuçlar, modelin zararlı tespitindeki verimliliğini vurgulamakta ve çiftçilikte pratik uygulamalar için kullanılabileceğini göstermektedir.



Epoch	Performans Değerlendirme Metrikleri			
	Precision	Recall	mAP50	mAP50-95
0	0.64614	0.32143	0.34314	0.3828075
37	0.90293	0.88597	0.94932	0.8554625
74	0.94115	0.9881	0.9904	0.9377075
111	0.97635	0.98312	0.9927	0.94756875
148	0.9431	0.98657	0.98832	0.9411525
185	0.98711	1	0.99476	0.9657925
222	0.97415	1	0.99262	0.95955125
259	0.99802	1	0.995	0.9646275
296	0.99561	1	0.995	0.96813875
333	0.99826	1	0.995	0.9703675
372	0.97465	0.9881	0.99383	0.95990125

Şekil 4.20. Zararlı segmentasyonu amacıyla eğitilen YOLOv8 Modelinin Performans Değerlendirme Metrikleri. Metrics over epochs: Her eğitim dönemi boyunca modelin performans metrikleri. Metric Score: Performans metriklerinin % değeri.

4.3. Modellerin Performans Karşılaştırmaları

Çizelge 11 ve Çizelge 12, çeşitli tespit ve segmentasyon modellerinin eğitim süreçlerinin sonunda ulaştığı Precision, Recall, mAP50 ve mAP50-95 performans değerlerini sunmaktadır. Bu metrikler, bir modelin nesne tespiti veya segmentasyon konusundaki genel başarısını değerlendirmek için kullanılmaktadır. Precision, Recall ve mAP50, modelin performansını değerlendirmede önemli metriklerdir; ancak mAP50-95, modelin farklı Intersection over Union (IoU) eşiklerindeki performansını geniş bir aralıkta değerlendirir. Bu, modelin genel başarısını daha kapsamlı bir şekilde ölçmeye olanak tanır. Özellikle nesne tespiti ve segmentasyon görevlerinde, modelin farklı IoU eşiklerinde nasıl performans gösterdiğini bilmek, modelin gerçek dünya senaryolarında nasıl çalışacağına dair daha geniş bir perspektif sunmaktadır.

Genel olarak Çizelge 11'de, mAP50-95 değerine göre tespit modelleri arasında en yüksek performansı gösteren modelin YOLOv8 olduğunu ve ardından DETR'nin geldiği görülmektedir. Çizelge 12'da ise, segmentasyon modelleri arasında Mask RCNN modeli mAP50-95 metriğiyle en yüksek skora sahip olup, ardından YOLOv8 modeli gelmektedir. Sonuç olarak, bir modelin genel başarısını değerlendirmek için mAP50-95 metriği en kapsamlı değerlendirmeyi sunar. Bu metriğe dayanarak hem tespit hem de segmentasyon modelleri arasında YOLOv8 iyi düzeyde performans gösterdiği söylenebilir.

Çizelge 4.1'deki verilere göre, tespit modellerinin performanslarının ANOVA analizi ve Tukey HSD post-hoc testi sonuçları, farklı modeller arasında istatistiksel olarak anlamlı farklılıkların olduğunu göstermektedir ($F(27, 56) = 100.69, p < .0001$). Bu, test edilen modellerin performanslarının genel olarak birbiriyle karşılaştırılabilir olmadığını, yani bazı modellerin diğerlerinden istatistiksel olarak anlamlı derecede daha iyi veya daha kötü performans gösterdiğini işaret eder. YOLOv8 modeli, mAP50-95 değerinde %97,72 ile en yüksek performansı sergileyerek, diğer tüm modellere kıyasla üstünlüğünü kanıtlar. Bu sonuç, YOLOv8'in hem precision (%98,60) hem de recall (%98,65) metriklerinde de yüksek puanlar alarak, tespit yeteneğinin geniş bir yelpazedeki nesneleri doğru bir şekilde tanıma ve sınıflandırma konusunda oldukça güçlü olduğunu gösterir.

DETR modeli ise mAP50-95'de %88,50 ile ikinci en yüksek performansı sergileyerek, YOLOv8'den sonra gelen en başarılı model olarak öne çıkar. Diğer yandan, EfficientDet ve GroundingDINO gibi modellerin mAP50-95 değerleri oldukça düşük (%65,80 ve %61,60, sırasıyla), bu da onların karşılaştırma setindeki diğer modellere göre göreceli olarak daha düşük performans sergilediklerini gösterir. Sonuç olarak, YOLOv8 modelinin, genel olarak tespit görevlerinde, özellikle de mAP50-95 metriği bazında, diğer modellere kıyasla istatistiksel olarak anlamlı derecede daha üstün olduğu söylenebilir.

Çizelge 4.1. Tespit Modellerinin Precision, Recall, mAP50, ve mAP50-95 Değerleri için ANOVA Analizi ve Tukey HSD post-hoc Testi Sonuçları ($F(27, 56) = 100.69$, $p < .0001$).

Tespit Modelleri				
Model Adı	Precision (%)	Recall (%)	mAP50 (%)	mAP50-95 (%)
Detectron2	97,48 (ab)	95,82 (ab)	98,66 (a)	80,80 (ef)
DETR	98,83 (a)	98,84 (a)	98,33 (ab)	88,50 (cd)
EfficientDet	88,86 (cd)	87,58 (cd)	92,27 (bc)	65,80 (g)
Faster R-CNN	96,54 (ab)	92,32 (bc)	96,80 (ab)	75,43 (f)
GroundingDINO	88 (cd)	85,50 (de)	89,33 (cd)	61,60 (g)
MobileNet SSD v2	97,05 (ab)	95,46 (ab)	97,36 (ab)	63,63 (g)
YOLOv8	98,60 (a)	98,65 (a)	98,49 (a)	97,72 (ab)

Çizelge 4.2'deki segmentasyon modellerinin performanslarını değerlendiren ANOVA analizi ve Tukey HSD post-hoc testi sonuçları, bu modeller arasında istatistiksel olarak anlamlı farklılıkların olduğunu göstermektedir ($F(11, 24) = 112.0377$, $p < .0001$). Bu, segmentasyon alanında farklı yaklaşımların birbirinden önemli ölçüde farklı sonuçlar üretebileceğini işaret eder. Mask RCNN, mAP50-95 değerinde %96.71 ile Çizelgede yer alan segmentasyon modelleri arasında en yüksek performansa sahip model olarak öne çıkar. Bu modelin ayrıca precision (%99,12) ve recall (%98,22) metriklerinde de yüksek değerler alması, segmentasyon konusunda güçlü bir doğruluk ve duyarlılığa sahip olduğunu gösterir.

YOLOv8 ise segmentasyon görevinde de güçlü bir performans sergileyerek mAP50-95'de %95,65 ile Mask RCNN'nin hemen arkasından gelir. Bu, YOLOv8'in hem tespit hem de segmentasyon görevlerinde yüksek düzeyde etkili olduğunu gösteren bir bulgudur.

Diğer taraftan, SAM modeli mAP50-95 değerinde %59,97 ile segmentasyon modelleri arasında en düşük performansı sergileyen modeldir. Bu, SAM'in hem precision (%86,46) hem de recall (%86,26) metriklerinde de daha düşük skorlar alarak, genel olarak segmentasyon görevinde diğer modellere kıyasla daha az etkili olduğunu işaret eder. Bu analiz, segmentasyon görevlerinde Mask RCNN ve YOLOv8 modellerinin, genel olarak, diğer modellere kıyasla istatistiksel olarak anlamlı derecede daha üstün performans sergilediklerini gösterir. Özellikle Mask RCNN, yüksek precision ve recall değerleriyle segmentasyon alanında en etkili model olarak kabul edilebilir, ancak YOLOv8'in de segmentasyon görevinde oldukça rekabetçi bir performans sergilediği görülmektedir.

Çizelge 4.2. Segmentasyon Modellerinin Precision, Recall, mAP50, ve mAP50-95 Değerleri için ANOVA Analizi ve Tukey HSD post-hoc Testi Sonuçları ($F(11, 24) = 112.0377$, $p < .0001$).

Segmentasyon Modelleri				
Model Adı	Precision (%)	Recall (%)	mAP50 (%)	mAP50-95 (%)
Mask RCNN	99,12 (a)	98,22 (a)	98,66 (a)	96,71 (ab)
YOLOv8	96,80 (ab)	97,87 (a)	98,92 (a)	95,65 (ab)
SAM	86,46 (cd)	86,26 (d)	91,63 (bc)	59,97 (e)


4.4. Karmaşıklık (Confusion) Matris Analizi

Bir modelin doğruluğunun değerlendirilmesi bağlamında, karmaşıklık matrisi modelin performansı hakkında derinlemesine bilgi sunar, yanlış sınıflandırmaları belirlemeye yardımcı olur ve potansiyel modifikasyonları önerir (Jensen vd., 2017). Tespit kapasitesine sahip modellerin eğitimi amacıyla 11.000 adet görüntüyü kapsayan bir veri kümesi kullanılmıştır. Veri kümesi train (%80), validation (%18) ve test (%2) bölümlerine ayrılmıştır.

Karmaşıklık matrisi her bir model için, model eğitime dahil olmayan test veri seti üzerinden hesaplanmıştır. Bu veri kümesi, ergin böcek, nimf, larva görüntülerini içermektedir ve toplamda 13 farklı etiketle (sınıf adıyla) yapılandırılmıştır. Araştırmada ele alınan her bir model, bu 13 farklı sınıfı eğitim süreci boyunca öğrenmiştir. Bu sınıflar şöyledir: *Dolycoris baccarum* ergini, Toprak Pire Böcekleri ergini, *Nezara viridula* ergini, Aphid ergini, *Bemisia tabaci* ergini, *Leptinotarsa decemlineata* ergini, *Tuta absoluta* ergini, *Nezara viridula* nimfi, *L. decemlineata* larvası, *Helicoverpa armigera* larvası ve *Tuta absoluta* larvası.

YOLOv8 modelinin kurulumu ve eğitimi tamamlandıktan sonra, performansını değerlendirmek amacıyla eğitime dahil olmayan test veri seti üzerinden karmaşıklık matrisi hesaplanmıştır. Model, *D. baccarum* ergini'ni 890 defa doğru tahmin etmiş, 25 defa *N. viridula* ergini ve 1 defa Afid ergini olarak yanıltıcı tahminlerde bulunmuştur. Toprak Pire Böcekleri ergini için model 524 defa doğru tespit yapmış, fakat 5 defa bu sınıfı Aphid ergini olarak yanıltıcı tahminlerde bulunmuştur. *N. viridula* ergini'ni model 695 defa doğru tespit etmiş ve 15 defa *D. baccarum* ergini olarak yanıltmıştır. Aphid ergini'ni model 998 defa doğru tahmin etmiştir. *B. tabaci* ergini için model 1025 defa doğru tespit yapmıştır. *L. decemlineata* ergini'ni model 666 defa doğru tahmin ederken, 1 defa *T. absoluta* ergini olarak yanıltmıştır. *T. absoluta* ergini'ni model 345 defa doğru tahmin etmiştir. *N. viridula* nimfi için model 465 defa doğru tespit yapmış, 5 defa *L. decemlineata* larvası olarak yanıltıcı tahminlerde bulunmuştur. *L. decemlineata* larvası'nı model 343 defa doğru tahmin ederken, 2 defa *N. viridula* ergini ve 7 defa *N. viridula* nimfi olarak yanıltmıştır. *H. armigera* larvası için model 120 defa doğru tespit yapmış, 3 defa *T. absoluta* larvası olarak yanıltıcı tahminlerde bulunmuştur. *T. absoluta* larvası'nı model 640 defa doğru tahmin ederken, 10 defa *H. armigera* larvası olarak yanıltmıştır (Şekil 4.21).

YOLOv8 modelleri kullanılarak gerçekleştirilen zararlı analizlerinin eğitim değerlendirmeleri ve elde edilen karmaşıklık matrisi sonuçları, bu alandaki teknolojik ilerlemeyi ve modelin etkinliğini göstermektedir. Literatürde benzer çalışmalar, zararlı tanıma ve sınıflandırma konusunda derin öğrenme tekniklerinin kullanımının önemini vurgulamaktadır. Özellikle, Darwin ve diğerleri (2021) tarafından yapılan bir çalışma, tarımsal robotların zararlıları otomatik olarak tespit etme kapasitesini artırma üzerine odaklanmıştır. Bu çalışmada, farklı derin öğrenme modelleri kullanılarak, zararlıların ve hastalıkların tespiti için otomatik sistemler geliştirilmiştir. Bunun yanı sıra, Sharma ve diğerleri (2022) makalesinde tarımsal zararlı ve hastalık tespiti için otomatik sistemlerin geliştirilmesi üzerine yapılan çalışmalar incelenmiştir. Bu çalışmalar, yapay zekâ ve makine öğrenimi tekniklerinin tarımsal zararlı tespitinde nasıl kullanılabileceğine dair değerli bilgiler sunmaktadır.




Şekil 4.21. Zararlı Tespiti amacıyla eğitilen YOLOv8 Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

MobileNet modeli, *D. baccarum* ergini'ni 770 defa doğru tespit ederken, yanılıcı tahminlerle 5 defa Toprak Pire Böcekleri ergini, 55 defa *N. viridula* ergini, 1 defa Aphid ergini, 10 defa *N. viridula* nimfi ve 5 defa *L. decemlineata* larvası olarak sınıflandırmıştır. Toprak Pire Böcekleri ergini'ni 640 defa doğru tahmin ederken, 12 defa *N. viridula* ergini ve 11 defa *B. tabaci* ergini olarak yanılmıştır. *N. viridula* ergini'ni 695 defa doğru belirlerken, 25 defa *D. baccarum* ergini, 1 defa Toprak Pire Böcekleri ergini, 20 defa Aphid ergini ve 3 defa *N. viridula* nimfi olarak yanılıcı tahminlerde bulunmuştur. Aphid ergini'ni doğru olarak 550 defa tespit ederken, 2 defa *L. decemlineata* ergini olarak yanılıcı tahminler yapmıştır. *B. tabaci* ergini için 700 doğru tahminde bulunmuştur. *L. decemlineata* ergini'ni 343 defa doğru tahmin ederken, 1 defa Toprak Pire Böcekleri ergini, 5 defa Aphid ergini ve 1 defa *T. absoluta* ergini olarak yanılmıştır. *T. absoluta* ergini'ni 565 defa doğru sınıflandırırken, 1 defa *B. tabaci* ergini ve 2 defa *H. armigera* larvası olarak yanılıcı tahminler yapmıştır. *N. viridula* nimfi için 459 doğru tahmin yapmış, fakat 5 defa *L. decemlineata* larvası olarak yanılmıştır. *L. decemlineata* larvası'ni 255 defa doğru tahmin ederken, 2 defa *N. viridula* ergini, 2 defa Aphid ergini, 1 defa *L. decemlineata* ergini ve 7 defa *N. viridula* nimfi olarak yanılıcı tahminlerde bulunmuştur. *H. armigera* larvası'nı 320 defa doğru sınıflandırırken, 21 defa *T. absoluta* larvası olarak yanılmıştır. Son olarak, model *T. absoluta* larvası'nı 650 defa doğru tahmin ederken, 10 defa *H. armigera* larvası olarak yanılıcı tahminlerde bulunmuştur (Şekil 4.22).

Örtü altı domates üretiminde zararlı tespitinde MobileNet modellerinin kullanılması, yapay zekâ tabanlı çözümlerin tarımsal zararlı yönetimindeki potansiyelini ortaya koymaktadır. Elde edilen karmaşıklık matrisi sonuçları, modelin *D. baccarum* erginlerini yüksek doğrulukla tespit edebildiğini, ancak bazı durumlarda yanılıcı tahminler yapabildiğini göstermiştir. Özellikle, modelin toprak pire böcekleri, *N. viridula* erginleri ve diğer zararlı türlerini bazı durumlarda yanlış sınıflandırması, modelin doğruluğunu artırmak için daha fazla iyileştirme yapılması gerektiğini göstermektedir. Bu bulgular, Chouinard ve diğerleri (2021) tarafından yapılan ve benzer yaklaşımlar kullanılarak yüksek doğruluk oranları elde edilen çalışmalarla paralellik göstermektedir.


Chouinard ve diğerlerinin çalışması, yapay zekâ modellerinin tarımsal zararlı tespitindeki etkinliğini artırmaya yönelik önemli bir adım olarak kabul edilmektedir. Bu ve benzeri çalışmalar, yapay zekâ ve makine öğrenimi modellerinin tarımsal zararlı yönetiminde nasıl etkili bir şekilde kullanılabileceğini göstermektedir (Chouinard vd., 2021). Yapay zekâ tabanlı yöntemlerin tarımsal zararlı tespitindeki başarısı, bu teknolojilerin tarım sektöründe daha yaygın bir şekilde kabul görmesini sağlayabilir.



Şekil 4.22. Zararlı Tespiti amacıyla eğitilen MobileNet SSD v2 Modelinin Karmaşıklik Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

GroundingDINO modeli, *D. baccarum* ergini'ni 699 defa doğru tespit ederken, 2 defa Toprak Pire Böcekleri ergini, 55 defa *N. viridula* ergini, 6 defa Aphid ergini, 10 defa *L. decemlineata* ergini ve 1 defa *N. viridula* nimfi olarak yanılmıştır. Model, Toprak Pire Böcekleri ergini için 770 defa doğru tespit yapmış, ancak 5 defa *N. viridula* ergini olarak yanılmıştır. *N. viridula* ergini için model 255 defa doğru tespit yapmış, fakat 25 defa *D. baccarum* ergini, 1 defa Toprak Pire Böcekleri ergini, 8 defa *L. decemlineata* ergini ve 1 defa *L. decemlineata* larvası olarak yanılmıştır. Aphid ergini için model 880 defa doğru tespit yaparken, 10 defa *N. viridula* ergini ve 7 defa *N. viridula* nimfi olarak yanılmıştır.

B. tabaci ergini için model 990 defa doğru tahminde bulunmuştur. *L. decemlineata* ergini için model 880 defa doğru tahmin yaparken, 1 defa *T. absoluta* ergini, 10 defa *N. viridula* nimfi ve 2 defa *H. armigera* larvası olarak yanlışmıştır. *T. absoluta* ergini için model 345 defa doğru tespit yapmış, fakat 5 defa *N. viridula* ergini ve 9 defa *B. tabaci* ergini olarak yanlışmıştır. *N. viridula* nimfi için model 665 defa doğru tahmin yapmış, ancak 10 defa *T. absoluta* ergini ve 20 defa *L. decemlineata* larvası olarak yanlışmıştır. *L. decemlineata* larvası için model 350 defa doğru tespit yapmış, 2 defa *N. viridula* ergini ve 7 defa *N. viridula* nimfi olarak yanlışmıştır. *H. armigera* larvası için model 250 defa doğru tahmin yaparken, 4 defa *L. decemlineata* ergini, 3 defa *N. viridula* nimfi ve 30 defa *T. absoluta* larvası olarak yanlışmıştır. *T. absoluta* larvası için model 770 defa doğru tahmin yapmış, 2 defa *N. viridula* nimfi ve 25 defa *H. armigera* larvası olarak yanlışmıştır (Şekil 4.23).




Şekil 4.23. Zararlı Tespiti amacıyla eğitilen GroundingDINO Modelinin Karmaşıklik Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

Faster R-CNN modeli, *D. baccarum* ergini için 900 kez doğru tahminde bulunmuş, ancak bu sınıfı 1 kez Toprak Pire Böcekleri ergini, 20 kez *N. viridula* ergini, 20 kez Aphid ergini, 5 kez *B. tabaci* ergini, 2 kez *L. decemlineata* ergini, 3 kez *N. viridula* nimfi ve 6 kez *T. absoluta* larvası olarak yanlış tahmin etmiştir. Model, Toprak Pire Böcekleri ergini'ni 650 defa doğru tahmin etmiş, fakat bu sınıfı 5 kez *N. viridula* ergini olarak yanıltıcı tahminlerde bulunmuştur. *N. viridula* ergini'ni model 550 defa doğru tespit ederken, bu sınıfı 15 kez *D. baccarum* ergini olarak yanıltmıştır. Model, Aphid ergini için 880 defa doğru tahminde bulunmuş, ancak bu sınıfı 10 kez *N. viridula* ergini, 7 kez *N. viridula* nimfi, 2 kez *T. absoluta* ergini ve 8 kez *T. absoluta* larvası olarak yanlış sınıflandırmıştır. *B. tabaci* ergini için model 990 defa doğru tahmin yapmıştır. *L. decemlineata* ergini için model, bu sınıfı 880 defa doğru tahmin ederken, bu sınıfı 1 kez Toprak Pire Böcekleri ergini, 8 kez *N. viridula* ergini, 7 kez *B. tabaci* ergini, 51 kez *T. absoluta* ergini olarak yanıltmıştır. Model, *T. absoluta* ergini'ni 440 defa doğru tahmin ederken, bu sınıfı 1 kez Aphid ergini olarak yanıltıcı tahminlerde bulunmuştur. *N. viridula* nimfi için model 550 defa doğru tahmin yapmış, bu sınıfı 2 kez *D. baccarum* ergini, 9 kez Toprak Pire Böcekleri ergini, 2 kez Aphid ergini, 1 kez *B. tabaci* ergini, 7 kez *L. decemlineata* ergini, 65 kez *L. decemlineata* larvası olarak yanıltmıştır. *L. decemlineata* larvası için model 447 defa doğru tahmin yapmıştır. Model, *H. armigera* larvası için 250 defa doğru tahmin yaparken, bu sınıfı 3 kez *T. absoluta* larvası olarak yanıltıcı tahminlerde bulunmuştur. Son olarak, model *T. absoluta* larvası için 565 defa doğru tahmin yaparken, bu sınıfı 10 kez *H. armigera* larvası olarak yanıltmıştır (Şekil 4.24).

Domates bitki hastalıklarının CNN tabanlı modellerle tespiti üzerine yapılan güncel çalışmaların kapsamlı bir incelemesi, erken tanı ve teşhis için derin öğrenme yaklaşımlarının önemini vurgulamakta ve CNN'in tanı doğruluğunu artırarak sürdürülebilir bir şekilde domates ürün miktarını artırma konusundaki kritik rolünü belirtmektedir. Ancak, CNN tekniklerinin karmaşıklığı ve performans zamanı önemli endişeler olarak kalmakta, farklı koşullar altında zararlıların görünüşündeki değişkenliği idare edebilecek etkin modellere olan ihtiyacı vurgulamaktadır (Mudgil vd., 2022). RGB-D görüntülerine dayalı semantik segmentasyon nöral ağları kullanılarak domates emici böceklerinin hızlı tespiti üzerine yapılan başka bir çalışma, geleneksel olarak elle gerçekleştirilen görevleri otomatize edebilme potansiyelini göstermekte, böylece zaman ve iş gücünden tasarruf sağlarken doğruluk ve verimi artırmaktadır (Giang vd., 2022).


FASTER R-CNN KARMAŞIKLIK MATRİSİ



Şekil 4.24. Zararlı Tespiti amacıyla eğitilen FASTER R-CNN Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

EfficientDet (D7) modeli, *D. baccarum* ergini için 612 defa doğru tespit yapmıştır. Ancak, bu sınıfı 350 defa *N. viridula* ergini, 1 defa Aphid ergini, 7 defa *B. tabaci* ergini, 4 defa *T. absoluta* ergini, 8 defa *L. decemlineata* larvası ve 6 defa *T. absoluta* larvası olarak yanıltıcı tahminlerde bulunmuştur. Toprak Pire Böcekleri ergini'ni model 450 defa doğru tespit yapmış, fakat 5 defa *N. viridula* ergini olarak yanıltıcı tahminlerde bulunmuştur. *N. viridula* ergini için model 560 defa doğru tespit yaparken, bu sınıfı 120 defa *D. baccarum* ergini, 3 defa *B. tabaci* ergini ve 1 defa *T. absoluta* ergini olarak yanılmıştır. Aphid ergini için model 789 defa doğru tespit yapmış, ancak bu sınıfı 5 defa Toprak Pire Böcekleri ergini, 1 defa *L. decemlineata* larvası, 2 defa *T. absoluta* ergini ve 8 defa *T. absoluta* larvası olarak yanıltıcı tahminlerde bulunmuştur. *B. tabaci* ergini'ni model 989 defa doğru tespit yapmıştır. *L. decemlineata* ergini'ni model 780 defa doğru tespit yapmış, fakat bu sınıfı 1 defa Toprak Pire Böcekleri ergini, 8 defa *N. viridula* ergini, 7 defa *B. tabaci* ergini, 2 defa *H. armigera* larvası olarak yanıltıcı tahminlerde bulunmuştur. *T. absoluta* ergini için model 562 defa doğru tespit yapmış, bu sınıfı 1 defa Toprak Pire Böcekleri ergini olarak yanılmıştır. *N. viridula* nimfi'ni model 541 defa doğru tespit yapmış, bu sınıfı 2 defa *N. viridula* ergini, 3 defa Aphid ergini, 5 defa *L. decemlineata* larvası, 1 defa *H. armigera* larvası olarak yanılmıştır. *L. decemlineata* larvası için model 559 defa doğru tespit yaparken, bu sınıfı 2 defa *N. viridula* ergini, 125 defa *N. viridula* nimfi ve 1 defa *T. absoluta* larvası olarak yanılmıştır. *H. armigera* larvası için model 248 defa doğru tespit yapmış, bu sınıfı 1 defa *L. decemlineata* larvası, 21 defa *T. absoluta* larvası olarak yanılmıştır. Son olarak, *T. absoluta* larvası için model 458 defa doğru tespit yaparken, bu sınıfı 10 defa *H. armigera* larvası olarak yanılmıştır (Şekil 4.25).


EFFICIENTDET KARMAŞIKLIK MATRİSİ



Şekil 4.25. Zararlı Tespiti amacıyla eğitilen EfficientDet (D7) Modelinin Karmaşıklik Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.


DETR modeli, *D. baccarum* ergini'ni 770 defa doğru tespit yapmış, fakat bu sınıfı 350 defa *N. viridula* ergini, 1 defa Aphid ergini, 7 defa *B. tabaci* ergini, 8 defa *L. decemlineata* larvası ve 6 defa *T. absoluta* larvası olarak yanıltıcı tahminlerde bulunmuştur. Toprak Pire Böcekleri ergini için model 620 defa doğru tespit yapmış, bu sınıfı 5 defa *N. viridula* ergini olarak yanıltıcı tahminlerde bulunmuştur. *N. viridula* ergini'ni model 700 defa doğru tespit yaparken, bu sınıfı 120 defa *D. baccarum* ergini, 2 defa Toprak Pire Böcekleri ergini, 6 defa Aphid ergini, 5 defa *B. tabaci* ergini, 1 defa *L. decemlineata* ergini ve 2 defa *L. decemlineata* larvası olarak yanıltmıştır. Aphid ergini'ni model 880 defa doğru tahmin etmiştir. *B. tabaci* ergini'ni model 1200 defa doğru tahmin yaparken, bu sınıfı 1 defa *N. viridula* ergini, 1 defa Aphid ergini ve 2 defa *N. viridula* nimfi olarak yanıltmıştır. *L. decemlineata* ergini'ni model 731 defa doğru tespit yapmış, bu sınıfı 1 defa *T. absoluta* ergini olarak yanıltıcı tahminlerde bulunmuştur.

T. absoluta ergini'ni model 441 defa doğru tahmin etmiştir. *N. viridula* nimfi'ni model 365 defa doğru tespit yaparken, bu sınıfı 5 defa *L. decemlineata* larvası olarak yanıltmıştır. *L. decemlineata* larvası'nı model 456 defa doğru tespit yaparken, bu sınıfı 2 defa *N. viridula* ergini ve 7 defa *N. viridula* nimfi olarak yanıltmıştır. *H. armigera* larvası için model 150 defa doğru tespit yapmış, bu sınıfı 1 defa *L. decemlineata* larvası, 8 defa *T. absoluta* larvası olarak yanıltmıştır. Son olarak, *T. absoluta* larvası için model 255 defa doğru tespit yaparken, bu sınıfı 45 defa *H. armigera* larvası olarak yanıltmıştır. (Şekil 4.26).



Şekil 4.26. Zararlı Tespiti amacıyla eğitilen DETR Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

Detectron2 modeli, *D. baccarum* ergini'ni 650 defa doğru tespit yapmıştır, ancak bu sınıfı 335 defa *N. viridula* ergini, 1 defa Aphid ergini, 2 defa *B. tabaci* ergini olarak yanıltıcı tahminlerde bulunmuştur. Toprak Pire Böcekleri ergini için model 365 defa doğru tespit yapmış, ancak bu sınıfı 25 defa *N. viridula* ergini ve 1 defa *T. absoluta* ergini olarak yanıltmıştır. *N. viridula* ergini'ni model 356 defa doğru tespit yapmış, bu sınıfı 55 defa *D. baccarum* ergini olarak yanıltıcı tahminlerde bulunmuştur. Aphid ergini'ni model 556 defa doğru tahmin yaparken, bu sınıfı 2 defa *L. decemlineata* larvası olarak yanıltmıştır. *B. tabaci* ergini'ni model 774 defa doğru tespit yapmıştır. *L. decemlineata* ergini için model 445 defa doğru tespit yapmış, ancak bu sınıfı 1 defa *D. baccarum* ergini, 1 defa *N. viridula* ergini, 1 defa *T. absoluta* ergini ve 2 defa *L. decemlineata* larvası olarak yanıltıcı tahminlerde bulunmuştur. *T. absoluta* ergini'ni model 253 defa doğru tespit yaparken, bu sınıfı 1 defa *N. viridula* ergini ve 5 defa Aphid ergini olarak yanıltmıştır. *N. viridula* nimfi'ni model 265 defa doğru tespit yaparken, bu sınıfı 2 defa *B. tabaci* ergini ve 5 defa *L. decemlineata* larvası olarak yanıltıcı tahminlerde bulunmuştur. *L. decemlineata* larvası'nı model 255 defa doğru tespit yapmış, bu sınıfı 2 defa *N. viridula* ergini ve 140 defa *N. viridula* nimfi olarak yanıltmıştır. *H. armigera* larvası için model 185 defa doğru tespit yapmıştır. *T. absoluta* larvası için model 558 defa doğru tespit yapmış, bu sınıfı 10 defa *H. armigera* larvası olarak yanıltmıştır (Şekil 4.27).




Şekil 4.27. Zararlı Tespiti amacıyla eğitilen Detectron2 Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

Segmentasyon özellikli modellerin eğitimi için 9000 adet domates yaprağı ve domates meyve görüntüsünden oluşan bir veri seti kullanılmıştır. Bu veri seti, toplamda 9 farklı etikete sahiptir. Bu etiketler şunlardır: "*Liriomyza bryoniae* zararı", "*Tuta absoluta* zararı (yaprakta)", "*Thrips* zararı", "Akar zararı (yaprakta)", "Sağlıklı domates yaprakları", "Sağlıklı domates meyveleri", "*Helicoverpa armigera* zararı" ve "*Tuta absoluta* zararı (meyvede)".

YOLOv8 modeli, *L. bryoniae* zararı için 550 defa doğru tespit yapmıştır, ancak 18 defa *T. absoluta* zararı (yaprakta) olarak yanıltıcı tahminlerde bulunmuştur. *T. absoluta* zararı (meyvede) için model 345 defa doğru tespit yapmış, fakat 6 defa *H. armigera* zararı olarak yanıltmıştır. Thrips zararı için model 265 defa doğru tespit yapmış ve 15 defa Akar zararı (yaprakta) olarak yanıltıcı tahminlerde bulunmuştur. Akar zararı (yaprakta) için model 450 defa doğru tespit yapmış, ancak 35 defa Thrips zararı olarak yanıltmıştır. Sağlıklı domates yaprakları için model 565 defa doğru tespit yapmış, fakat 3 defa Thrips zararı ve 5 defa Akar zararı (yaprakta) olarak yanıltıcı tahminlerde bulunmuştur. Sağlıklı domates meyveleri için model 155 defa doğru tespit yapmıştır. *H. armigera* zararı için model 169 defa doğru tespit yapmış, fakat 25 defa *T. absoluta* zararı (yaprakta) olarak yanıltıcı tahminlerde bulunmuştur. Son olarak, *T. absoluta* zararı (yaprakta) için model 339 defa doğru tespit yapmış, ancak 15 defa *L. bryoniae* zararı olarak yanıltmıştır (Şekil 4.28).

Domates üretiminde zararlıların tespiti ve yönetimi, özellikle örtü altı tarım sistemlerinde büyük önem taşımaktadır. Yapay zekâ ve derin öğrenme tekniklerinin, bu alanda giderek artan bir şekilde kullanılmaya başlamasıyla, özellikle YOLO gibi modellerin zararlı tespitindeki başarısı dikkat çekmektedir. Bu teknolojik gelişmeler hem zararlıların erken tespitini hem de tarım ilaçlarının daha etkin ve doğru bir şekilde kullanılmasını sağlayarak, domates üretiminde verimliliği artırmakta ve sürdürülebilir tarım uygulamalarına katkıda bulunmaktadır. Literatürde, YOLO modelleri ve benzeri derin öğrenme tekniklerinin tarım zararlılarının tespiti konusunda kullanımıyla ilgili birçok çalışma bulunmaktadır. Örneğin, He ve diğerleri (2023) çalışmasında, tarım zararlıları ve hastalıklarının erken tespiti için gelişmiş biyosensör teknolojileri incelenmiş ve bu teknolojilerin, gerçek zamanlı ve otomatize izleme imkanları sunarak sürdürülebilir tarım koruma uygulamalarını destekleyebileceği vurgulanmıştır. Benzer şekilde, Urmashev ve diğerleri (2021) çalışmasında, YOLOv5 sinir ağı modeli kullanılarak yabancı otların tespiti için bir program geliştirilmiş ve bu yaklaşımın düşük çözünürlüklü görüntülerde bile iyi sonuçlar verebileceği belirtilmiştir.




Şekil 4.28. Zararlı Segmentasyonu amacıyla eğitilen YOLOv8 Modelinin Karmaşıklik Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

Mask RCNN modeli, *L. bryoniae* zararı için 440 defa doğru tespit yapmıştır. Ancak bu sınıfı 1 defa *T. absoluta* zararı (meyvede) olarak, 2 defa Akar zararı (yaprakta) olarak ve 15 defa *T. absoluta* zararı (yaprakta) olarak yanıltıcı tahminlerde bulunmuştur. *T. absoluta* zararı (meyvede) için model 345 defa doğru tespit yapmıştır, fakat 1 defa Sağlıklı domates meyveleri olarak yanıltıcı tahminlerde bulunmuştur. Thrips zararı için model 263 defa doğru tespit yapmıştır. Ancak bu sınıfı 2 defa *L. bryoniae* zararı olarak ve 3 defa Sağlıklı domates yaprakları olarak yanıltıcı tahminlerde bulunmuştur. Akar zararı (yaprakta) için model 442 defa doğru tespit yapmıştır. Ancak bu sınıfı 5 defa *T. absoluta* zararı (meyvede) olarak, 55 defa Thrips zararı olarak, 5 defa Sağlıklı domates yaprakları olarak, 1 defa Sağlıklı domates meyveleri olarak ve 2 defa *H. armigera* zararı olarak yanıltıcı tahminlerde bulunmuştur.


Sağlıklı domates yaprakları için model 398 defa doğru tespit yapmıştır, ancak 1 defa *L. bryoniae* zararı olarak yanıltıcı tahminlerde bulunmuştur. Sağlıklı domates meyveleri için model 122 defa doğru tahmin yapmıştır. *H. armigera* zararı için model 255 defa doğru tespit yapmıştır, fakat 6 defa *T. absoluta* zararı (meyvede) olarak yanıltıcı tahminlerde bulunmuştur. Son olarak, *T. absoluta* zararı (yaprakta) için model 421 defa doğru tespit yapmıştır. Ancak bu sınıfı 25 defa *L. bryoniae* zararı olarak, 35 defa Akar zararı (yaprakta) olarak ve 100 defa *H. armigera* zararı olarak yanıltıcı tahminlerde bulunmuştur (Şekil 4.29).

Örtü altı domates üretiminde zararlıların tespiti, ürün verimliliği ve kalitesi açısından hayati öneme sahiptir. Bu bağlamda, Mask R-CNN gibi derin öğrenme modellerinin kullanımı, yüksek doğruluk oranlarıyla zararlıları tanıma ve segmente etme imkânı sunmaktadır. Sharma ve diğerleri (2022) tarafından yapılan çalışmada, CNN'in bitki hastalıklarının tanımlanmasındaki zorlukların üstesinden gelmede son derece yararlı olduğu, ancak yeni sera koşullarında değerlendirildiğinde düşük performans gösterdiği belirtilmiştir. Bu nedenle, modelin genelleme kabiliyetini artırmak amacıyla çeşitli tekniklerin kullanılması önerilmiştir (Sharma, G. Sharma, & Menghani, 2022). Benzer şekilde, Mudgil ve diğerleri (2022) tarafından gerçekleştirilen bir diğer çalışmada, CNN tabanlı domates bitki hastalıklarının tanımlanmasında yüksek doğruluk oranları elde edildiği, ancak CNN tekniklerinin karmaşıklığı ve performans süresinin önemli bir endişe kaynağı olduğu vurgulanmıştır. Bu çalışma, büyük veri setlerinin kullanımı ve paylaşımının domates hastalık tespitinde yüksek doğruluk elde etmek için gerekliliğini ortaya koymaktadır (Mudgil, Garg, Singh, & Madhu, 2022).



Şekil 4.29. Zararlı Segmentasyonu amacıyla eğitilen Mask R-CNN Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

SAM modeli, *L. bryoniae* zararı için 500 defa doğru tespit yapmıştır fakat 55 defa *T. absoluta* zararı (yaprakta) olarak yanıltıcı tahminlerde bulunmuştur. *T. absoluta* zararını (meyvede) model 255 defa doğru tahmin etmiştir. Thrips zararı için model 223 defa doğru tespit yapmış, 1 defa Sağlıklı domates yaprakları ve 2 defa Sağlıklı domates meyveleri olarak yanıltıcı tahminlerde bulunmuştur. Akar zararı (yaprakta) için model 401 defa doğru tespit yapmıştır. Ancak 112 defa Thrips zararı ve 1 defa Sağlıklı domates yaprakları olarak yanıltıcı tahminlerde bulunmuştur. Sağlıklı domates yaprakları için model 503 defa doğru tespit yapmış, 1 defa *T. absoluta* zararı (meyvede) olarak yanıltıcı tahminlerde bulunmuştur. Sağlıklı domates meyveleri'ni model 122 defa doğru tahmin etmiştir. *H. armigera* zararı için model 112 defa doğru tespit yapmış, 1 defa Thrips zararı olarak yanıltıcı tahminlerde bulunmuştur. Son olarak, *T. absoluta* zararı (yaprakta) için model 330 defa doğru tespit yapmıştır. Ancak 55 defa *L. bryoniae* zararı, 65 defa Akar zararı (yaprakta), ve 78 defa *H. armigera* zararı olarak yanıltıcı tahminlerde bulunmuştur (Şekil 4.30).




Şekil 4.30. Zararlı Segmentasyonu amacıyla eğitilen Segment Anything Model (SAM) Modelinin Karmaşıklık Matrisi. True Labels: Gerçek zararlılar. Predicted Labels: Tahmin edilen zararlılar.

Segmentasyon ve tespit amacıyla eğitilen tüm modellerin Karmaşıklık Matris verileri incelendiğinde, çalışmada ele alınan domates zararlılarını doğru tahmin edebilme açısından en istikrarlı performansı YOLOv8 modeli göstermektedir. Tespit amacıyla eğitilen Detectron2, DETR, EfficientDet, Faster R-CNN, GroundingDINO, MobileNet ve YOLOv8 modellerinin Karmaşıklık Matris verileri kapsamında hatalı veya doğru tahmin edilen zararlıların tespit oranları Şekil 35 (A-B)'de verilmiştir. Segmentasyon amacıyla eğitilen SAM, MASK R-CNN ve YOLOv8 modellerinin Karmaşıklık Matris verileri kapsamında hatalı veya doğru tahmin edilen zararlıların tespit oranları Şekil 4.31 (A-B)'de verilmiştir.

Şekil 4.31 (A), domates zararlılarının tespiti amacıyla eğitilen çeşitli modellerin hatalı tespit oranlarının ANOVA analizi ve Tukey HSD post-hoc testi sonuçlarını göstermektedir. Sonuçlar, modellerin hatalı tespit oranları arasında istatistiksel olarak anlamlı farklılıklar olduğunu gösterir. Detectron2 ve EfficientDet modelleri "a" grubunda yer alarak, hatalı tespit oranlarının sırasıyla ortalama 11 ve 9.3333 olduğu belirlenmiş, bu da onları analiz edilen diğer modellere göre istatistiksel olarak daha yüksek hatalı tespit oranına sahip modeller olarak sınıflandırır. Öte yandan, YOLOv8 modeli "b" grubunda en düşük ortalama hatalı tespit oranı olan 1.6667 ile en iyi performansı sergileyen model olarak öne çıkar. Bu, YOLOv8'in domates zararlılarının tespitinde diğer modellere göre istatistiksel olarak anlamlı derecede daha az hata yaptığını gösterir. DETR, GroundingDINO ve Faster R-CNN gibi modeller de "b" grubunda yer alır ve hatalı tespit oranları sırasıyla 4.3333, 4.3333 ve 4 ile YOLOv8'den daha yüksek fakat Detectron2 ve EfficientDet'e göre daha düşük olduğu belirlenmiştir. MobileNet SSD v2, "b" grubunda 3 ortalama hatalı tespit oranı ile orta sıralarda yer alır. Bu sonuçlar, YOLOv8'in bu kontekstte en güvenilir model olduğunu ve hatalı tespit oranları açısından diğer modellere kıyasla istatistiksel olarak anlamlı derecede üstün performans sergilediğini gösterir ($F(6, 14) = 14.2885, p < .0001$).

Şekil 4.31 (B), domates zararlılarını tespit etmek için eğitilen çeşitli modellerin doğru tespit oranlarını karşılaştıran ANOVA analizi ve Tukey HSD post-hoc testinin sonuçlarını sunmaktadır. ANOVA testi sonuçları ($F(6, 14) = 32.7381, p < .0001$), modeller arasında doğru tespit oranları açısından istatistiksel olarak anlamlı farklılıklar olduğunu gösterir. Bu, modellerin performanslarının birbirinden önemli ölçüde farklı olduğunu ve bu farklılıkların tesadüfi olmadığını işaret eder. Tukey HSD post-hoc testi sonuçlarına göre, YOLOv8 %99,33'lük doğru tespit oranı ile en yüksek performansı sergileyen modeldir ve "A" grubunda yer alır. Bu sonuç, YOLOv8'in diğer tüm modellere göre istatistiksel olarak anlamlı derecede daha üstün olduğunu gösterir. MobileNet SSD v2 ve DETR, sırasıyla %97 ve %96,67'lik doğru tespit oranları ile "a" ve "b" gruplarında yer alır, bu da onların YOLOv8'e yakın ancak ondan istatistiksel olarak farklı bir performans sergilediklerini gösterir.

GroundingDINO ve Faster R-CNN, %96 ve %95,67'lik doğru tespit oranlarıyla "b" grubunda yer alır ve bu modeller de yüksek performans sergilemekle birlikte, en üst sıradaki modellerle aralarında belirgin performans farkları vardır. EfficientDet ve Detectron2, sırasıyla %91 ve %88,33'lük doğru tespit oranları ile "c" grubunda yer alarak, Çizelgedaki diğer modellere göre istatistiksel olarak anlamlı derecede daha düşük performans sergiledikleri görülür. Bu, EfficientDet ve Detectron2'nin domates zararlılarını tespit etme konusunda diğer modellere kıyasla daha az etkili olduğunu gösterir. Sonuç olarak, YOLOv8 modeli istatistiksel analizlere dayanarak domates zararlılarını tespit etme görevinde en üstün performansı sergilemiş, diğer modeller ise çeşitli performans seviyeleriyle onu takip etmiştir. Bu farklılıklar, modellerin yapısal özellikleri ve tespit algoritmalarının etkinliği gibi faktörlere bağlı olabilir.




Şekil 4.31. Karmaşıklık Matrisi verilerine göre, tespit amacıyla eğitilen modellerin domates zararlılarını hatalı (A) ve doğru (B) tahmin oranları için ANOVA Analizi ve Tukey HSD post-hoc Testi Sonuçları.

Şekil 4.32 (A), segmentasyon amaçlı eğitilen modellerin domates zararlılarını hatalı tespit oranları üzerine yapılan ANOVA analizi ve Tukey HSD post-hoc testi sonuçlarını göstermektedir. Analiz sonuçları, farklı segmentasyon modellerinin hatalı tespit oranları arasında istatistiksel olarak anlamlı farklılıklar olduğunu ortaya koymaktadır ($F(2, 6) = 46.4545$, $p < .0002$). Bu, test edilen modellerin performanslarının birbirinden önemli ölçüde farklı olduğunu gösterir. YOLOv8 modeli, ortalama hatalı tespit oranı %4.33333 ile segmentasyon modelleri arasında en düşük hatalı tespit oranına sahip modeldir, bu da onun domates zararlılarını diğer modellere kıyasla daha doğru bir şekilde tespit edebildiğini ve bu bağlamda en üstün performansı sergilediğini gösterir.

Mask RCNN modeli, ortalama hatalı tespit oranı %9.33333 ile YOLOv8'in ardından gelirken, SAM modeli %13 ile en yüksek hatalı tespit oranına sahip modeldir. Bu sonuçlar, YOLOv8'in segmentasyon görevlerinde, özellikle domates zararlılarının tespitinde, SAM ve Mask RCNN modellerine göre istatistiksel olarak anlamlı bir şekilde daha az hata yaptığını ve dolayısıyla daha etkili olduğunu gösterir. Mask RCNN modeli, YOLOv8'e göre daha yüksek hatalı tespit oranına sahip olmakla birlikte, SAM modeline göre daha iyi performans göstermiştir, bu da onun orta düzeyde bir performans sergilediğini işaret eder. Bu analiz, segmentasyon modellerinin domates zararlılarının tespitindeki başarılarının karşılaştırılmasında, YOLOv8'in açık bir şekilde öne çıktığını ve en düşük hatalı tespit oranına sahip olduğunu göstermektedir.

Şekil 4.32 (B), segmentasyon amaçlı eğitilen modellerin domates zararlılarını tespit oranları üzerine yapılan ANOVA analizi ve Tukey HSD post-hoc testinin sonuçlarını sunmaktadır. Analiz, farklı modellerin tespit oranları arasında istatistiksel olarak anlamlı farklar olduğunu göstermektedir ($F(2, 6) = 39.2667$, $p < .0004$), bu da incelenen modellerin performanslarının birbirinden önemli ölçüde farklı olduğunu işaret eder. YOLOv8 modeli, %96,66667'lik tespit oranı ile segmentasyon amacıyla eğitilen modeller arasında en yüksek doğrulukla zararlıları tespit eden model olarak öne çıkmaktadır. Bu sonuç, YOLOv8'in domates zararlılarının tespitinde istatistiksel olarak anlamlı bir şekilde Mask RCNN ve SAM modellerinden üstün olduğunu gösterir. Mask RCNN modeli %91,66667 tespit oranı ile ikinci sırada yer almakta, bu da onun yüksek, ancak YOLOv8'e kıyasla daha düşük bir tespit başarımı sergilediğini belirtir. SAM modeli ise %87,33333 tespit oranı ile bu üç model arasında en düşük tespit oranına sahip

model olarak saptanmıştır. Bu sonuçlar, segmentasyon amaçlı eğitilen modellerin domates zararlılarını tespit etme kabiliyetlerinin, YOLOv8'in liderliğinde, belirgin farklılıklar gösterdiğini ve YOLOv8'in bu özel görevde istatistiksel olarak anlamlı bir şekilde en iyi performansı sergilediğini ortaya koymaktadır.



Şekil 4.32. Karmaşıklık Matrisi verilerine göre, segmentasyon amacıyla eğitilen modellerin domates zararlılarını hatalı (A) ve doğru (B) tahmin oranları için ANOVA Analizi ve Tukey HSD post-hoc Testi Sonuçları.

Yapay zekâ (YZ) modellerinin örtü altı domates üretiminde zararlı analizi amacıyla kullanımı üzerine yapılan araştırmalarda, farklı YZ modellerinin performansları karşılaştırılmıştır. Özellikle YOLOv8 modeli, domates zararlılarının doğru tahmin edilmesi açısından istikrarlı bir performans sergilemiştir. Bu modelin, düşük otomasyon seviyesini artırarak tarımsal üretim faaliyetlerinde domatesin otomatik hasat ve sınıflandırılmasına teknik destek sağladığı belirtilmektedir. Modelin, karmaşık ortamlarda modelin tespit hassasiyetini artırarak ağırlığını ve tespit hızını dengede tuttuğu, bu sayede tarımsal domates tespit gereksinimlerini karşılayabilecek bir denge sağladığı görülmüştür (Yang vd., 2023). Diğer araştırmalarda ise, çeşitli YZ modelleri kullanılarak domates bitkilerindeki zararlı ve hastalıkların tespiti için gelişmiş algoritmalar önerilmiştir. Bu çalışmalar, YZ modellerinin domates üretiminde zararlı ve hastalık tespitinde etkili bir araç olabileceğini göstermektedir. Örneğin, YOLOv5 ve YOLOv4 temelli algoritmaların, domates bitkilerindeki zararlıların yanı sıra hastalıkların da tespitinde yüksek doğruluk oranları elde ettiği bildirilmiştir (Hu vd., 2023). Bu bulgular, YZ modellerinin, özellikle YOLOv8 gibi gelişmiş versiyonlarının, tarımsal zararlı tespitinde kritik bir rol oynayabileceğini ve tarımsal üretimde verimliliği artırarak kayıpları azaltabileceğini ortaya koymaktadır.

4.6. Dil Modeli Vasıtasıyla Elde Edilen Sonuçlar


Dil modellerinin tarımsal zararlıların analizi ve kontrolü üzerine yapılan çalışmalarda önemli bir potansiyel taşıdığı görülmektedir. Özellikle doğal pest kontrolü üzerine modellerin incelendiği ve tarımsal peyzajlar boyunca tahminler yapma potansiyeline odaklanan bir literatür incelemesi, doğal pest kontrolünün çeşitlilik ve bağlam hassasiyetini temsil etmede mekanistik modellerin korelatif modellere göre daha iyi konumlandırıldığını vurgulamaktadır (Alexandridis vd., 2020). Ayrıca, sürdürülebilir tarım peyzajlarındaki zararlı kontrolüne dair bir inceleme, tarımsal yoğunlaşmanın, tarımsal arazilerin genişlemesi, tarla boyutunun büyütülmesi ve tarım dışı habitatların kaldırılması gibi değişikliklerin sahadaki biyoçeşitliliğinin hızlı bir şekilde azalmasına neden olduğunu ve kalan biyoçeşitliliğin alan kenarları ve tarım dışı habitatlarda yoğunlaştığını belirtmektedir. Bu çalışma, çeşitlendirilmiş peyzajların biyoçeşitliliği korumak ve pest kontrol işlevini sürdürmek için en fazla potansiyele sahip olduğu sonucuna varmaktadır (Bianchi & Tschardtke, 2006).

Domates bitkisi zararlıları için gerçekleştirilen tespit ve segmentasyon çalışmalarında, çeşitli model performansları istatistiksel metriklerle değerlendirilmiştir. Tespit modelleri içerisinde YOLOv8, mAP50-95 metriği üzerinden %97,722 başarı oranıyla belirgin bir üstünlük gösterirken; Detectron2 ve DETR sırasıyla %81,137 ve %88,836 oranlarıyla performans sergilemiştir. Segmentasyon modellerinden MASK R-CNN'in mAP50-95 metriğiyle %96,38'lik başarısı öne çıkmakta; YOLOv8 ise bu alanda %95,99'luk benzer bir başarıyla dikkat çekmektedir. Karmaşıklık matrisi verileri incelendiğinde en düşük seviyede hatalı tespit oranının YOLOv8 modeline ait olduğu belirlenmiştir. Hassasiyet, duyarlılık ve karmaşıklık matrisi analizleri birlikte değerlendirildiğinde, YOLOv8 modelinin zararlı tespiti ve segmentasyon performansı diğer modellerden daha stabil ve üstün performans gösterdiği görülmektedir. Bu nedenle, dil modeli ile tespit modellerinin entegrasyonu süreçlerinde YOLOv8 modeli tercih edilmiştir.

Eđitim ve dođrulama veri setinin ierdiđi veriler zerinden zararlı tespiti amacıyla eđitilen YOLOv8 modelinin ađırlık dosyası (best.pt) kaydedilmiřtir. Eđitim ve dođrulama veri setinin ierdiđi *D. baccarum* ergini, Toprak Pire Bcekleri ergini, *N. viridula* ergini, Aphid ergini, *B. tabaci* ergini, *L. decemlineata* ergini, *T. absoluta* ergini, *N. viridula* nimfi, *L. decemlineata* larvası, *H. armigera* larvası ve *T. absoluta* larvası grntleri zerinden eđitilen YOLOv8 modelinin ađırlık dosyası, test veri setindeki resimler zerinden tahminler yrtmesi amacıyla kullanılmıřtır. API bađlantısı vasıtasıyla GPT-3 ve YOLOv8 modelleri entegre edilip, test veri setinde bulunan domates zararlılarına ait grseller girdi olarak kullanılmıřtır.




Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *D. baccarum* zararlısı incelenmiştir. *D. baccarum* zararlısını YOLOv8 modeli %92 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.33).




Şekil 4.5. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *D. baccarum* zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan Toprak Pire Böcekleri ergin zararlısı incelenmiştir. Toprak Pire Böcekleri ergin zararlısını YOLOv8 modeli %89 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.34).




Şekil 4.34. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonuyla Toprak Pire Böcekleri ergin zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *N. viridula* ergini zararlısı incelenmiştir. *N. viridula* ergin zararlısını YOLOv8 modeli %85 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.35).




Şekil 4.35. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonuyla *N. viridula* ergin zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan Aphid ergini zararlısı incelenmiştir. Aphid ergini zararlısını YOLOv8 modeli %98 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.36).




Şekil 4.36. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile Aphid ergini zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eđitim ve dođrulama veri setinin ierdiđi veriler zerinden eđitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bađlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *B. tabaci* ergini zararlısı incelenmiřtir. *B. tabaci* ergini zararlısını YOLOv8 modeli %89 olasılık dzeyiyle tespit etmiřtir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıřtır (řekil 4.37).




řekil 4.37. Zararlı tespiti amacıyla eđitilen YOLOv8 ve dil modeli GPT-3 entegrasyonuyla *B. tabaci* ergini zararlısına ait grntnn incelenmesi. Input: Girdi olarak kullanılan grnt.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *L. decemlineata* ergini zararlısı incelenmiştir. *L. decemlineata* ergini zararlısını YOLOv8 modeli %95 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.38).




Şekil 4.38. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *L. decemlineata* ergini zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *T. absoluta* ergini zararlısı incelenmiştir. *T. absoluta* ergini zararlısını YOLOv8 modeli %98 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.39).




Şekil 4.39. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonuyla *T. absoluta* ergini zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *N. viridula* nimfi zararlısı incelenmiştir. *N. viridula* nimfi zararlısını YOLOv8 modeli %82 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.40).




Şekil 4.40. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonuyla *N. viridula* nimfi zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *L. decemlineata* larvası zararlısı incelenmiştir. *L. decemlineata* larvası zararlısını YOLOv8 modeli %88 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.41).




Şekil 4.41. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *L. decemlineata* larvası zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *H. armigera* larvası zararlısı incelenmiştir. *H. armigera* larvası zararlısını YOLOv8 modeli %87 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.42).



Şekil 4.42. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *H. armigera* larvası zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *T. absoluta* larvası zararlısı incelenmiştir. *T. absoluta* larvası zararlısını YOLOv8 modeli %93 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.43).



Şekil 4.43. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *T. absoluta* larvası zararlısına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eđitim ve dođrulama veri setinin ierdiđi veriler zerinden zararlı segmentasyonu amacıyla eđitilen YOLOv8 modelinin ađırlık dosyası (best.pt) kaydedilmiřtir. Eđitim ve dođrulama veri setinin ierdiđi *L. bryoniae* zararı, *T. absoluta* zararı (meyvede), Thrips zararı Akar zararı (yaprakta), Sađlıklı domates yaprakları, Sađlıklı domates meyveleri, *H. armigera* zararı, *T. absoluta* zararı (yaprakta) grntleri zerinden eđitilen YOLOv8 modelinin ađırlık dosyası, test veri setindeki resimler zerinden tahminler yrtmesi amacıyla kullanılmıřtır. API bađlantısı vasıtasıyla GPT-3 ve YOLOv8 modelleri entegre edilip, test veri setinde bulunan domates zararlılarına ait grseller girdi olarak kullanılmıřtır.




Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *L. bryoniae* zararı (yaprakta) incelenmiştir. *L. bryoniae* zararı YOLOv8 modeli %88 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.44).




Şekil 4.44. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *L. bryoniae* zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *T. absoluta* zararı (meyvede) incelenmiştir. *T. absoluta* zararı YOLOv8 modeli %92 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.45).




Şekil 4.45. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *T. absoluta* zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan Thrips zararı (yaprakta) incelenmiştir. Thrips zararı YOLOv8 modeli %82 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.46).




Şekil 4.46. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile Thrips zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan Akar zararı (yaprakta) incelenmiştir. Akar zararı YOLOv8 modeli %88 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.47).




Şekil 4.47. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile Akar zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *H. armigera* zararı (meyvede) incelenmiştir. *H. armigera* zararı YOLOv8 modeli %88 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.48).



Şekil 4.48. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *H. armigera* zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

Eğitim ve doğrulama veri setinin içerdiği veriler üzerinden eğitilen YOLOv8 tespit modeli ve GPT-3 dil modeli, API bağlantısı vasıtasıyla entegre edilerek test veri setinde bulunan *T. absoluta* zararı (yaprakta) incelenmiştir. *T. absoluta* zararı YOLOv8 modeli %90-92 olasılık düzeyiyle tespit etmiştir. Tespit edilen zararlı, GPT-3 modeli tarafından yorumlanmıştır (Şekil 4.49).



Şekil 4.49. Zararlı tespiti amacıyla eğitilen YOLOv8 ve dil modeli GPT-3 entegrasyonu ile *T. absoluta* zararına ait görüntünün incelenmesi. Input: Girdi olarak kullanılan görüntü.

5. TARTIŞMA

Bu çalışmada kullanılan modeller arasından YOLOv8 ve Mask RCNN'nin domates bitkisi üzerindeki zararlıların tespitinde ve segmentasyonunda gösterdiği üstün performans, literatürdeki benzer çalışmalarla kıyaslandığında önemli bulgular sunmaktadır. Özellikle, YOLOv8 modelinin nesne tespitinde ve Mask RCNN modelinin nesne segmentasyonunda elde ettiği yüksek Precision, Recall ve mAP değerleri istatistiksel açıdan dikkat çekicidir. Bu modellerin eğitim sürecinde kaydedilen önemli iyileşmeler, yapay zekâ tabanlı tarımsal zararlı tespiti alanında önemli bir adımı temsil etmektedir.

YOLOv8 ve Mask R-CNN modellerinin eğitim süreçlerinde elde edilen yüksek Precision ve Recall değerleri, literatürdeki benzer çalışmalar tarafından vurgulamaktadır. Örneğin, Yue ve diğerlerinin (2023) tarafından gerçekleştirilen çalışma, geliştirilmiş YOLOv8s-Seg modelinin domateslerin gerçek zamanlı ve etkili bir şekilde segmentasyonunu yapabilme kapasitesini ortaya koymuş, F1 skoru %88,7 ve mAP50 değeri %92,2 olarak rapor edilmiştir. Bu sonuçlar, bu teknolojinin tarım sektöründe potansiyelini ve etkinliğini göstermektedir. Benzer şekilde, Lawal (2021) tarafından yapılan çalışma, YOLO-Tomato modellerinin karmaşık çevresel koşullarda etkili bir şekilde domates tespiti yapabilme kapasitesini vurgulamış ve mAP değerlerinin %98,3 ile %99,5 arasında değiştiğini belirtmiştir. Bu bulgular, YOLOv8 ve Mask R-CNN modellerinin, literatürdeki benzer çalışmalarla kıyaslandığında, zararlı tespiti konusunda önemli iyileşmeler sağladığını ve tarımsal üretimde verimliliği artırma ve hastalık yönetimini iyileştirme konusunda kritik roller üstlenebileceğini göstermektedir. Bu teknolojilerin geliştirilmesi ve başarılı bir şekilde uygulanması, tarım sektöründe sürdürülebilirliği ve verimliliği artırma yönünde önemli adımlar olarak değerlendirilebilir.

MobileNet SSD v2, Faster R-CNN ve EfficientDet D7 modelleri kullanılarak domates üzerindeki zararlıların tespiti için gerçekleştirilen nesne tespiti model eğitimlerinin sonuçları, literatürdeki benzer çalışmaların nesnel verileriyle kıyaslandığında önemli bir ilerleme görülmektedir. MobileNet SSD v2 modeli için başlangıçtaki %53,52'lik Precision değerinin %96,39'a, %34,53'lük Recall değerinin %95,80'e, mAP50 değerinin %35,97'den %97,36'ya ve mAP50-95 değerinin %14,65'ten %63,96'ya yükselmesi, Palwankar ve Kothari (2022) tarafından vurgulanan MobileNet ve SSD'nin kombinasyonunun etkinliğini doğrular niteliktedir. Faster R-CNN modeli için ise, %0,62 olan Precision değerinin %96,88'e, %23,74 olan Recall değerinin %93,00'e, mAP50 değerinin %0,91'den %96,81'e ve mAP50-95 değerinin %0,29'dan %75,44'e çıkması, Li ve diğerleri (2020) tarafından yapılan çalışmada shellfish tespitindeki başarısını yansıtan bir gelişim göstermektedir.

EfficientDet D7 modelinin başlangıçtaki %1,1 Precision değerinin %88,54'e, %41,62 Recall değerinin %88,25'e, mAP50 değerinin %3,89'dan %91,94'e ve mAP50-95 değerinin %1,98'den %66,14'e yükselmesi, Tan ve diğerlerinin (2019) EfficientDet modelinin ölçeklenebilir ve etkin nesne tespiti yetenekleri hakkında yaptığı çalışmayı destekler niteliktedir. Bu çalışmanın sonuçları, literatürdeki benzer çalışmalarla kıyaslandığında, özellikle tarımsal uygulamalarda derin öğrenme tabanlı nesne tespiti modellerinin doğruluğu ve hızında kaydedilen önemli ilerlemeleri göstermektedir. Bu gelişmeler, tarım alanında zararlı tespiti gibi spesifik uygulamalar için derin öğrenmenin potansiyelini ve etkinliğini vurgulamaktadır.

GroundingDINO, DETR, Detectron2 ve SAM modelleri, eğitim sürecinde belirgin performans artışları sergileyerek, nesne tespiti ve segmentasyonu konusunda etkileyici sonuçlar elde edilmiştir. Bu bulgular, literatürdeki benzer çalışmalarla kıyaslandığında, özellikle precision, recall, mAP50 ve mAP50-95 metriklerinde kaydedilen iyileşmeler açısından dikkat çekicidir. Örneğin, "AI-Powered Image-Based Tomato Leaf Disease Detection" çalışmasında, domates yaprak hastalığı tespit yöntemi önerilmiş ve %94,1 doğrulukla hastalıklar sınıflandırmıştır (Annabel & Muthulakshmi, 2019). Benzer şekilde, "Deep learning-based segmentation and classification of leaf images for detection of tomato plant disease" çalışması, Inception Net modeli kullanarak %99,95 doğrulukla ikili sınıflandırma problemlerini çözmüştür (Shoaib vd., 2022). Bu sonuçlar, sunulan çalışmanın sonuçları ile paralellik göstererek, yapay zekâ ve derin öğrenme teknolojilerinin tarımsal zararlıların tespiti ve segmentasyonunda önemli potansiyele sahip olduğunu kanıtlamaktadır.

Bu tez çalışması, literatürdeki benzer çalışmalarla karşılaştırıldığında her iki alanda da önemli metodolojik ve performans iyileştirmeleri sağladığı görülmektedir. Precision, recall, mAP50 ve mAP50-95 gibi temel performans metriklerinde kaydedilen ilerlemeler, bu teknolojilerin tarımsal uygulamalarda daha geniş kabul görmesi için güçlü bir temel oluşturmaktadır. Özellikle, DETR ve Detectron2 modellerinin sırasıyla %99,25 ve %97,23 gibi yüksek precision değerlerine ulaşması, nesne tespiti ve segmentasyonu konusunda yapay zekanın gücünü ve potansiyelini vurgulamaktadır. Bu gelişmeler, tarım sektöründe yapay zekanın uygulanabilirliğini ve etkinliğini artırarak, zararlıların erken tespiti ve yönetimi konusunda önemli katkılar sağlayabilir.

Yapay zekâ tabanlı domates üzerindeki zararlıların segmentasyon ve tespiti üzerine yapılan bu tez çalışmasında, karmaşıklık matrisi sonuçları incelendiğinde YOLOv8, SAM ve Mask RCNN modelleri arasında en düşük hata oranıyla (%4,333333) zararlı nesneleri tespit eden model olarak YOLOv8 belirlenmiştir. Ayrıca, YOLOv8 modeli, %96,666667 doğruluk oranı ile zararlı nesneleri en yüksek doğrulukla tespit eden model olarak öne çıkmıştır. Bu sonuçlar, YOLOv8 modelinin domates üzerindeki zararlıların tespitinde, özellikle görüntü açısından karmaşık tarım alanlarında, üstün performans sergileyebileceğini göstermektedir. Literatürdeki benzer çalışmalarla kıyaslandığında, YOLOv8 modelinin yüksek doğruluk oranları ve düşük hata payları ile dikkat çektiği görülmektedir. Örneğin, Liu ve diğerlerinin (2022) geliştirdiği YOLOv4 tabanlı bir model, domates zararlılarının tanımlanmasında %95,2 doğruluk sağlamıştır. Yang ve diğerlerinin (2023) YOLOv8 temelli modeli ise, domates hasadı sırasında %93,4 mAP ile teknik destek sunmuştur. Truong Thi Huong Giang ve diğerlerinin (2022) semantik segmentasyon sinir ağlarına dayanan çalışması ve Sundararaman ve diğerlerinin (2023) yapay zekâ tekniklerinin domates yaprak hastalıklarını sınıflandırmada nasıl kullanılabileceğini incelediği çalışması, YOLOv8'in zararlı ve hastalık tespitinde gösterdiği üstün performansın önemini destekleyen bulgular sunmaktadır. Bu bulgular ışığında, YOLOv8 modelinin domates zararlılarının tespitinde yüksek doğruluk oranı ve düşük hata payı ile literatürdeki benzer çalışmalar arasında öne çıktığı ve tarımsal zararlı tespitinde etkili bir araç olarak kullanılabileceği sonucuna ulaşılmaktadır.

Yapay zekâ ve derin öğrenme tabanlı nesne tespiti ve segmentasyon modellerinin, özellikle YOLOv8 ve Mask RCNN gibi öne çıkan sistemlerin domates bitkisi üzerindeki zararlıların tespitinde sergilediği üstün performans, bu teknolojilerin tarım sektöründeki potansiyelini belirgin bir şekilde göstermektedir. Bu modeller, sağladıkları yüksek doğruluk, hız ve verimlilik ile tarımsal zararlıların erken tespiti ve yönetimi açısından hayati öneme sahiptir (Mul vd., 2016; Kuzuhara vd., 2020). Ancak, bu ilerlemenin esas olarak görsel verilere dayanması, karmaşık tarım ekosistemlerinde gereken çok boyutlu analizler için yeterli olmayabilir. Bu bağlamda, dil modellerinin entegrasyonu, tespit modellerinin yeteneklerini genişletme ve tarımsal veri analizinin sınırlarını zorlama potansiyeline sahiptir. Dil modelleri, zararlı tespiti ve sınıflandırılmasında kullanılan terminolojinin anlaşılması, tarımsal raporların ve araştırma bulgularının sentezlenmesi gibi önemli katkılar sağlayabilir (Hernandez-Castillo vd., 2019; Yuan vd., 2023).

Örneğin, GPT serisi gibi ileri dil modelleri, metin tabanlı verilerden elde edilen görsel bulguları birleştirerek, zararlıların davranış kalıpları, yayılımı ve mücadele stratejileri hakkında kapsamlı bilgiler sunabilir. Bu entegrasyon, tarımsal zararlı yönetiminde karar destek sistemlerinin geliştirilmesinde yeni bir dönüm noktası oluşturarak, daha etkin ve sürdürülebilir tarım uygulamalarının önünü açabilir (Wang vd., 2020; Yuan vd., 2022). Literatürde bu tür entegrasyonların faydalarını vurgulayan çalışmalar henüz sınırlı olmakla birlikte, yapay zekâ ve dil modellerinin kombine edilmesi yönündeki ilerlemeler, bu alanda önemli fırsatlar sunmaktadır. Bu yaklaşımın potansiyel faydası, tarım sektöründe yapay zekanın uygulanabilirliğini ve zararlıların erken tespiti ve yönetimi konusunda sağlayabileceği önemli iyileştirmeler, tarım alanında sürdürülebilirliği ve verimliliği artırma yönünde önemli adımlar olarak değerlendirilebilir.

Bu tez çalışmasında gerçekleştirilen entegrasyon, YOLOv8 ve GPT-3 gibi iki güçlü yapay zekâ modelinin birleştirilmesiyle tarımsal zararlıların tespiti ve bu zararlılar hakkında detaylı analizler yapılması sürecini kapsamaktadır. Bu tez çalışmasında, YOLOv8 modelinin eğitim ve doğrulama veri setleri üzerindeki zararlı tespiti performansının incelenmesi ve GPT-3'ün entegrasyonu ile elde edilen çıktıların değerlendirilmesi, yapay zekâ ve dil modellerinin tarımsal alanlarda kullanımının önemini vurgulayan mevcut literatür ile paralellikler göstermektedir. Shutske'nin (2023) çalışması, büyük dil modellerinin tarım güvenliği ve sağlık alanındaki profesyonellere günlük işlerinde nasıl yardımcı olabileceğini vurgulayarak, bu tez çalışmasının sonuçlarını destekler bir perspektif sunar. Araştırma, eğitimcilerin, araştırmacıların ve klinisyenlerin tarımsal güvenlik ve sağlık konularında karşılaştıkları sorunlara çözüm bulmada büyük dil modellerinden faydalanabileceklerini öne sürmektedir. YOLOv8 modelinin, belirli zararlı türlerine ait görseller üzerinden eğitilmesi ve bu eğitimin sonucunda elde edilen ağırlık dosyasının, test veri setindeki görseller üzerinden tahminlerde bulunmak için kullanılması, görüntü işleme ve nesne tespiti alanındaki ilerlemeleri temsil etmektedir. Öte yandan, GPT-3'ün YOLO modeli tarafından tespit edilen zararlıların biyolojisi, zarar şekilleri ve mücadele yöntemleri hakkında bilgiler sunması, doğal dil işleme ve bilgi sentezleme konusundaki kapasiteleri göstermektedir.

Bu tez çalışmasında, GPT-3 çıktılarının genel olarak zararlıların biyolojisi ve zarar şekilleri hakkında detaylı ve doğru bilgiler verdiği, ancak entegre zararlı yönetimi gibi kimyasal mücadeleye alternatif çıktılarının zayıf kaldığı görülmektedir. Özellikle biyolojik mücadele konusunda verilen çıktıların zayıf düzeyde kalması, bu teknolojilerin tarımsal uygulamalarda daha kapsamlı bilgi sağlama potansiyelinin tam olarak kullanılmadığını göstermektedir.

Literatürde dil modellerinin tarımsal alanda kullanımı konusunda yapılan çalışmalar, bu teknolojilerin tarım sektöründe önemli bir potansiyele sahip olduğunu vurgulamaktadır. Örneğin, Hernandez-Castillo ve diğerlerinin (2019) geliştirdiği doğal dil işleme teknolojilerini kullanarak tarımsal zararlıları tanıma ve yönetim konusunda yardımcı olan web tabanlı bir uygulama, dil modellerinin zararlı tespiti ve yönetimi konusunda nasıl değerli bilgiler sağlayabileceğini göstermektedir. Ancak, bu entegrasyonların tam potansiyelini gerçekleştirebilmesi için, modellerin tarımsal zararlılarla mücadelede kimyasal yöntemlere alternatif olan biyolojik ve entegre yöntemler hakkında daha kapsamlı ve güçlü çıktılar üretebilmesi gerekmektedir.

Bu bağlamda, GPT-3 gibi dil modellerinin eğitim sürecinde, entegre zararlı yönetimi ve biyolojik mücadele gibi sürdürülebilir tarım uygulamaları üzerine daha fazla veri dahil edilerek, modelin bu konularda daha güçlü ve detaylı çıktılar üretebilmesi sağlanmalıdır. Ayrıca, modelin tarımsal zararlılar ve mücadele yöntemleri konusunda daha geniş bir bilgi tabanına erişimi olması, çıktılarının kapsamını ve doğruluğunu artırabilir.

Sonuç olarak, YOLOv8 ve GPT-3 gibi modellerin entegrasyonu, tarımsal zararlıların tespiti ve yönetimi alanında önemli bir yenilik sağlasa da, bu teknolojilerin tarım sektöründeki potansiyelini tam olarak gerçekleştirebilmeleri için, sürdürülebilir tarım uygulamaları ve alternatif mücadele yöntemleri hakkında daha kapsamlı bilgi sağlama kapasitelerinin geliştirilmesi gerekmektedir. Bu hem tarımsal üretimde verimliliği artıracak hem de çevresel ve sağlık üzerindeki olumsuz etkileri azaltacak sürdürülebilir mücadele yöntemlerinin benimsenmesine katkıda bulunacaktır.

YOLOv8 tespit modeliyle entegre edilen GPT-3 modelinin, tarımsal uygulamalarda kullanılan dil modelleri için belirgin bir örnek teşkil etmektedir. Ancak, çalışmada GPT-3 modelinin genel internet bilgisine dayalı eğitimi nedeniyle, spesifik tarımsal konulara yönelik güvenilir ve doğru bilgiler sağlamada bazı eksiklikler gösterdiği belirlenmiştir. Bu bağlamda, tarımsal uygulamalar gibi spesifik alanlarda daha başarılı çıktılar elde etmek için, sadece hedeflenen konuyla alakalı güvenilir kaynaklardan eğitilmiş, alan spesifik dil modellerinin kullanılabilir.

Literatürdeki benzer çalışmalar, tarımsal alanlarda kullanılan dil modellerinin spesifik eğitim gereksinimlerini desteklemektedir. Örneğin, Rezayi ve diğerlerinin (2022) geliştirdiği AgriBERT modeli, gıda ve tarım literatürü gibi spesifik metin korpuslarından faydalananarak eğitilmiş ve gıda tanımları ile beslenme verileri arasındaki semantik eşleşme gibi tarımsal alandaki uzun süreli bir zorluğu ele almıştır (Rezayi vd., 2022). Bu çalışma, spesifik alan bilgisi ile zenginleştirilmiş dil modellerinin, tarımsal uygulamalarda etkili çıktılar sunabileceğini göstermektedir. Zhao ve diğerlerinin (2023) yürüttüğü ChatAgri çalışması, tarımsal haber metinlerinin sınıflandırılmasında ChatGPT gibi dil modellerinin potansiyelini araştırmış ve bu modellerin tarımsal bilgi erişiminde yüksek verimlilik sağlayabileceğini ortaya koymuştur (Zhao vd., 2023). Bu, dil modellerinin tarımsal alanlarda bilgi erişimi ve sınıflandırma gibi görevlerde kullanımının önemini vurgulamaktadır.

Bu çalışmaların ışığında, tarımsal uygulamalar için dil modellerinin geliştirilmesinde, spesifik ve hedef odaklı eğitim yaklaşımlarının benimsenmesi gerektiği sonucuna varılabilir. Meta (Facebook) tarafından geliştirilen ve tarımsal uygulamalarda kullanılması potansiyelini taşıyan LLama (<https://llama.meta.com/>) dil modeli veya benzer açık kaynak kodlu modeller, özel olarak güvenilir kaynaklarla eğitilerek tarım sektöründe daha doğru ve güvenilir çıktılar elde etme imkânı sunabilir. Bu yaklaşım, zararlı tespiti, hastalık tanımlama ve mücadele yöntemleri gibi konularda daha doğru bilgiler sunarak tarımsal üretimde verimliliği ve sürdürülebilirliği artırma potansiyeline sahiptir.

Xie, ve diğerkleri (2023) tarafından geliştirilen FinPythia-6.9B ve Mazairac ve Beetz (2013) tarafından geliştirilen BIMQL, spesifik ve hedef odaklı güvenilir kaynaklarla eğitilen açık kaynak kodlu dil modellerinin, tarımsal uygulamalarda kullanıldığında daha doğru ve güvenilir çıktılar sağlayabileceğini destekleyen literatür örnekleridir.

Bu tez çalışması, YOLOv8 ve Mask RCNN gibi gelişmiş görüntü işleme modellerinin tarımsal zararlıların tespitindeki başarısını ve dil modellerinin bu süreçte nasıl etkili bir şekilde entegre edilebileceğini göstermektedir. Spesifik olarak eğitilmiş dil modellerinin kullanımı, tarımsal zararlıların tespiti ve yönetimi konusunda daha doğru ve güvenilir bilgiler sağlama potansiyeline sahiptir. Bu çalışma, yapay zekâ ve derin öğrenme teknolojilerinin tarım sektöründe nasıl yenilikçi çözümler sunabileceğine dair değerli içgörüler sağlamaktadır. İlerleyen araştırmaların, bu entegrasyonları daha da geliştirerek tarımsal uygulamalarda yapay zekanın potansiyelini maksimize etmesi beklenmektedir. Böylece, tarım sektörü, zararlı tespiti ve yönetimi konusunda daha etkin ve sürdürülebilir yöntemlere erişim sağlayarak üretim verimliliğini artırma ve çevresel etkiyi azaltma yolunda önemli adımlar atabilir.

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında ele alınan, YOLOv8 ve Mask RCNN modelleri üzerinden gerçekleştirilen domates üzerindeki zararlıların tespiti ve segmentasyonu çalışması, mevcut literatürdeki benzer çalışmalarla kıyaslandığında dikkate değer bulgular sunmaktadır. İlgili modellerin, nesne tespiti ve segmentasyonunda elde ettikleri yüksek Precision, Recall ve mAP değerleri, yapay zekâ tabanlı tarımsal zararlı tespiti alanında kaydedilen önemli ilerlemeleri temsil etmektedir. Bu teknolojik gelişmelerin, zararlı tespiti, hastalık tanımlama ve mücadele yöntemleri geliştirilmesine yönelik yeni perspektifler sunduğu açıktır.

Ayrıca, GPT-3 gibi ileri düzey dil modellerinin entegrasyonu, zararlıların biyolojisi, zarar şekilleri ve mücadele yöntemleri üzerine yapılacak analizlerin kapasitesini artırmaktadır. Bununla birlikte, dil modellerinin tarımsal uygulamalarda daha fazla etkinlik göstermesi için, spesifik ve hedef odaklı eğitim metodolojilerinin benimsenmesinin gerekliliği vurgulanmaktadır. Bu yaklaşım, AgriBERT ve ChatAgri gibi spesifik dil modeli uygulamaları ile literatürde desteklenmektedir.

Özetle, bu çalışma, YOLOv8 ve Mask RCNN gibi gelişmiş görüntü işleme modelleri ile GPT-3 gibi dil modellerinin entegrasyonunun, tarımsal zararlıların tespiti ve analizi konusunda büyük potansiyellere sahip olduğunu ortaya koymaktadır. Ancak, bu potansiyelin tam anlamıyla hayata geçirilmesi, bu modellerin tarımsal zararlılarla mücadelede alternatif olarak görülen biyolojik ve entegre yöntemler hakkında daha geniş ve güçlü bilgiler üretebilmesi için, daha odaklı ve hedefe yönelik eğitim stratejileri gerektirmektedir. İlerleyen araştırmaların, bu entegrasyonları daha da derinleştirerek tarımsal uygulamalarda yapay zekanın potansiyelini en üst düzeye çıkarması ve böylece tarım sektörünü zararlı tespiti ve yönetimi konusunda daha etkin ve sürdürülebilir yöntemlere yönlendirmesi beklenmektedir. Bu, tarımsal üretimde verimliliğin artırılmasının yanı sıra, çevresel ve sağlık üzerindeki olumsuz etkilerin azaltılmasına yönelik sürdürülebilir mücadele yöntemlerinin benimsenmesine önemli katkılarda bulunacaktır.

Bu tez çalışması, YOLOv8 ve Mask RCNN gibi gelişmiş görüntü işleme modelleri ile GPT-3 gibi dil modellerinin entegrasyonunun, tarımsal zararlıların tespiti ve analizinde büyük bir potansiyel taşıdığını göstermiştir. Çalışma, bu teknolojilerin tarım sektöründeki uygulamalarında zararlı tespiti, hastalık tanımlama ve mücadele yöntemlerinin geliştirilmesinde önemli roller üstlenebileceğini ortaya koymuştur. Ancak, elde edilen başarıların yanı sıra, karşılaşılan zorluklar ve eksiklikler, gelecekteki çalışmalara yönelik olarak spesifik eğitim setlerinin geliştirilmesi, biyolojik ve entegre mücadele yöntemlerine odaklanması, çok disiplinli yaklaşımların benimsenmesi, gerçek dünya uygulamaları üzerine odaklanması ve açık kaynak kodlu yazılım ve araçların geliştirilmesi gibi önemli öneriler sunmaktadır.

Bu öneriler doğrultusunda, gelecekteki araştırmaların, tarımsal zararlı tespiti ve yönetimi alanında yenilikçi çözümler üretme potansiyeline sahip olduğu açıktır. Yapay zekâ ve derin öğrenme teknolojilerinin etkin entegrasyonu, tarım sektöründe sürdürülebilir uygulamaları destekleyerek, üretim verimliliğini artırma ve çevresel etkiyi azaltma yolunda önemli adımlar atmamızı sağlayabilir. Bu çalışma, tarımsal zararlıların daha etkin tespiti ve yönetimi için yapay zekâ teknolojilerinin potansiyelinden yararlanılmasının önemini vurgulamakta ve ilerleyen araştırmalar için bir temel oluşturmaktadır.

KAYNAKLAR

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., & Zheng, X. (2016). TensorFlow: Large-scale machine learning on heterogeneous distributed systems. arXiv preprint arXiv:1603.04467.
- Abbas, G., Hassan, N., Farhan, M., Haq, I., & Karar, H. (2015). Effect of selected insecticides on *Helicoverpa armigera* Hubner (Lepidoptera: Noctuidae) on tomato (*Lycopersicon esculentum* Miller) and their successful management. *Advances in Entomology*, 3(1): 16-23. <https://doi.org/10.4236/ae.2015.31003>
- Abdel-Razek, A., El-Ghany, N., Djelouah, K., & Moussa, A. (2016). An evaluation of some eco-friendly biopesticides against *Bemisia tabaci* on two greenhouse tomato varieties in Egypt. *Journal of Plant Protection Research*, 57(1): 9-17. <https://doi.org/10.1515/jppr-2017-0002>
- Abe, Y. (2006). Exploitation of the serpentine leafminer *Liriomyza trifolii* and tomato leafminer *L. bryoniae* (Diptera: Agromyzidae) by the parasitoid *Gronotoma micromorpha* (Hymenoptera: Eulophidae). *European Journal of Entomology*, 103(1), 55-59. <https://doi.org/10.14411/eje.2006.009>
- Abe, Y., & Kawahara, T. (2001). Coexistence of the vegetable leafminer, *Liriomyza sativae* (Diptera: Agromyzidae), with *L. trifolii* and *L. bryoniae* on commercially grown tomato plants. *Applied Entomology and Zoology*, 36(3): 277-281. <https://doi.org/10.1303/aez.2001.277>
- Acharya, B., Ingram, T., Oh, Y., Adhikari, T., Dean, R., & Louws, F. (2020). Opportunities and challenges in studies of host-pathogen interactions and management of *Verticillium dahliae* in tomatoes. *Plants*, 9(11): 1622. <https://doi.org/10.3390/plants9111622>
- Adilkhankyzy, A., Alpysbayeva, K., Nurmanov, B., Naimanova, B., Bashkarayev, N., Kenzhegaliev, A., ... & Uspanov, A. (2022). Integrated protection of tomato crops against *Tuta absoluta* in open ground conditions in the south-east part of Kazakhstan. *Online Journal of Biological Sciences*, 22(4): 539-548. <https://doi.org/10.3844/ojbsci.2022.539.548>
- Afonso, M., Fonteijn, H., Fiorentin, F. S., Lensink, D., Mooij, M., Faber, N., Polder, G., & Wehrens, R. (2020). Tomato fruit detection and counting in greenhouses using deep learning. *Frontiers in Plant Science*, 11. <https://doi.org/10.3389/fpls.2020.571299>
- Agboka, K., Tonnang, H., Abdel-Rahman, E., Odindi, J., Mutanga, O., & Mohamed, S. (2022). A fuzzy-based model to predict the spatio-temporal performance of the *Dolichogenidea gelechiidivoris* natural enemy against *Tuta absoluta* under climate change. *Biology*, 11(9): 1280. <https://doi.org/10.3390/biology11091280>
- Agegnehu, E., Mulatu, B., Damte, T., & Wakgari, M. (2020). Host range of cotton flea beetle (*Podagrica puncticollis*) in a hot dry tropical environment of Ethiopia. *Uganda Journal of Agricultural Sciences*, 19(1): 21-31. <https://doi.org/10.4314/ujas.v19i1.3>
- Ahmad, I., Yang, Y., Yao, Y., Wang, H., Hassan, M., Cheng, X., Wu, Y., & Zhang, Y. (2022). Deep learning based detector YOLOv5 for identifying insect pests. *Applied Sciences*, 12(19): 10167. <https://doi.org/10.3390/app121910167>
- Akbudak, N., & Bicen, N. (2020). The effects of irrigation with reclaimed wastewater on heavy metal accumulation and plant development in lettuce. *Fresenius Environmental Bulletin*, 29(6).

- Akbudak, N., & Üstün, G. E. (2023). The effect of irrigation of pickling cucumber with urban wastewater on product quality and heavy metal accumulation. *Gesunde Pflanzen*, 75(3): 593-601.
- Akbudak, N., Zambı, O., & Duran, U. T. (2022). Evaluation of exogenous salicylic acid application on white mould disease (*Sclerotinia sclerotiorum*) and photosynthetic pigments in lettuce (*Lactuca sativa* L.). *Türkiye Tarımsal Araştırmalar Dergisi*, 9(1): 90-96.
- Alexandridis, N., Marion, G., Chaplin-Kramer, R., Dainese, M., Ekroos, J., Grab, H., Jonsson, M., Karp, D., Meyer, C., O'Rourke, M., Pontarp, M., Poveda, K., Seppelt, R., Smith, H. G., Martin, E. A., & Clough, Y. (2020). A review of models of natural pest control: toward predictions across agricultural landscapes. *bioRxiv*. <https://doi.org/10.1101/2020.03.13.990531>
- Alınç, T., Cusumano, A., Peri, E., Torta, L., & Colazza, S. (2021). Trichoderma harzianum strain T22 modulates direct defense of tomato plants in response to Nezara viridula feeding activity. *Journal of Chemical Ecology*, 47(4-5): 455-462. <https://doi.org/10.1007/s10886-021-01260-3>
- Alkan, M., Gökçe, A., & Kara, K. (2017). Contactotoxicity of six plant extracts to different larval stages of colorado potato beetle (*Leptinotarsa decemlineata* say (Col: Chrysomelidae)). *Tarım Bilimleri Dergisi*, 309-3316. <https://doi.org/10.15832/ankutbd.447616>
- Altuntaş, Y., & Kocamaz, A. (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. <https://doi.org/10.18466/cbayarfbe.812375>
- Amara, J., Bouaziz, B., & Algergawy, A. (2017). A deep learning-based approach for banana leaf diseases classification. *Datenbanksysteme für Business, Technologie und Web (BTW 2017)-Workshopband*.
- Anitha, J., & Saranya, N. (2022). Cassava leaf disease identification and detection using deep learning approach. *International Journal of Computers Communications & Control*, 17(2): 4356. <https://doi.org/10.15837/ijccc.2022.2.4356>
- Annabel, L. S. P., & Muthulakshmi, V. (2019). AI-powered image-based tomato leaf disease detection. *2019 Third International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, 506-511. <https://doi.org/10.1109/I-SMAC47947.2019.9032621>
- Atalan, A., Şahin, H., & Atalan, Y. A. (2022). Integration of machine learning algorithms and discrete-event simulation for the cost of healthcare resources. *Healthcare*, 10, 1920.
- Athey, K., Ruberson, J., Olson, D., & Harwood, J. (2019). Predation on stink bugs (Hemiptera: Pentatomidae) in cotton and soybean agroecosystems. *Plos One*, 14(3): e0214325. <https://doi.org/10.1371/journal.pone.0214325>
- Avila, C., Arevalo-Soliz, L., Jia, L., Navarre, D., Chen, Z., Howe, G., & Goggin, F. (2012). Loss of function of fatty acid desaturase7 in tomato enhances basal aphid resistance in a salicylate-dependent manner. *Plant Physiology*, 158(4): 2028-2041. <https://doi.org/10.1104/pp.111.191262>
- Azouz, H. (2016). The effect of intercropping tomato with garlic plants on the corresponding infestation with some pests at Beni-Suif governorate. *Egyptian Academic Journal of Biological Sciences A. Entomology*, 9(3): 1-6. <https://doi.org/10.21608/eajbsa.2016.12768>

- Baker, S., & Hassan, Z. (2019). Laboratory evaluation of the effectiveness of some chemical pesticide and biopesticides and their combinations in the control of tomato leafminer *Liriomyza bryoniae*. *Tikrit Journal of Pure Science*, 24(3): 1-10. <https://doi.org/10.25130/tjps.v24i3.362>
- Barbedo, J. G. A. (2016). A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems Engineering*, 144, 52-60.
- Kovançi, B., & Genç, N.S. (2009). Lycaenid butterflies (Lepidoptera: Lycaenidae) of northwestern Turkey with notes on their ecology and current status. *Revista Colombiana de Entomología*, 35(2): 275-282.
- Bari, B., Islam, N., Rashid, M., Hasan, J., Razman, M., Musa, R., & Majeed, A. (2021). A real-time approach of diagnosing rice leaf disease using deep learning-based faster r-cnn framework. *PeerJ Computer Science*, 7, e432. <https://doi.org/10.7717/peerj-cs.432>
- BaşTürk, F., & Şahin, H. (2022). Makine öğrenmesi sınıflandırma algoritmalarının karşılaştırması: Metinden dil tanıma örneği. *Electronic Letters on Science and Engineering*, 18(2): 68-78.
- Belder, E., Valcheva, R., & Guldmond, J. (1999). Increased damage by western flower thrips *Frankliniella occidentalis* in chrysanthemum intercropped with subterranean clover. *Entomologia Experimentalis et Applicata*, 91(2): 275-285. <https://doi.org/10.1046/j.1570-7458.1999.00494.x>
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8): 1798-1828.
- Bianchi, F., Booij, C., & Tscharrntke, T. (2006). Sustainable pest regulation in agricultural landscapes: A review on landscape composition, biodiversity and natural pest control. *Proceedings of the Royal Society B: Biological Sciences*, 273, 1715-1727. <https://doi.org/10.1098/rspb.2006.3530>
- Biró, A., Jánosi-Rancz, K., Szilágyi, L., Cuesta-Vargas, A., Martin-Martin, J., & Szilágyi, S. (2022). Visual object detection with DETR to support video-diagnosis using conference tools. *Applied Sciences*, 12(12): 5977. <https://doi.org/10.3390/app12125977>
- Bisong, E. (2019). Building machine learning and deep learning models on Google Cloud Platform. Berkeley, CA: Apress. pp. 59-64.
- Bleeker, P., Mirabella, R., Diergaarde, P., VanDoorn, A., Tissier, A., Kant, M., & Schuurink, R. (2012). Improved herbivore resistance in cultivated tomato with the sesquiterpene biosynthetic pathway from a wild relative. *Proceedings of the National Academy of Sciences*, 109(49): 20124-20129. <https://doi.org/10.1073/pnas.1208756109>
- Boavida, C., Giltrap, N., Cuthbertson, A., & Northing, P. (2013). *Epitrix similaris* and *Epitrix cucumeris* in Portugal: Damage patterns in potato and suitability of potential host plants for reproduction. *EPPO Bulletin*, 43(2): 323-333. <https://doi.org/10.1111/epp.12046>
- Bodino, N., Ferracini, C., & Tavella, L. (2018). Functional response and age-specific foraging behaviour of *Necremnus tutae* and *N. cosmopterix*, native natural enemies of the invasive pest *Tuta absoluta* in Mediterranean area. *Journal of Pest Science*, 92(4): 1467-1478. <https://doi.org/10.1007/s10340-018-1025-6>
- Bronson, K., & Knezevic, I. (2016). Big data in food and agriculture. *Big Data & Society*, 3(1): 2053951716648174.

- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., & Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877-1901.
- Brucal, S. G., De Jesus, L. C., De Los Santos, J., Mendoza, M. J., Harion, K., Reyes, G. A., Nevalasca, D., & Reyes, J. K. (2023). Development of tomato leaf disease detection using single shot detector (SSD) Mobilenet V2. *International Journal of Computing Sciences Research*.
- Būda, V., & Radžiutė, S. (2008). Kairomone attractant for the leafmining fly, *Liriomyza bryoniae* (Diptera, Agromyzidae). *Zeitschrift Für Naturforschung C*, 63(7-8): 615-618. <https://doi.org/10.1515/znc-2008-7-825>
- Buriak, J., Akinwande, D., Artzi, N., Brinker, C., Burrows, C., Chan, W., & Ye, J. (2023). Best practices for using AI when writing scientific manuscripts. *ACS Nano*, 17(5): 4091-4093. <https://doi.org/10.1021/acsnano.3c01544>
- Caciagli, P., Bosco, D., & Al-Bitar, L. (1995). Relationships of the Sardinian isolate of tomato yellow leaf curl geminivirus with its whitefly vector *Bemisia tabaci* gen. *European Journal of Plant Pathology*, 101(2): 163-170. <https://doi.org/10.1007/bf01874762>
- Calvo, F., Lorente, M., Stansly, P., & Belda, J. (2012). Preplant release of *nesidiocoris tenuis* and supplementary tactics for control of *Tuta absoluta* and *bemisia tabaci* in greenhouse tomato. *Entomologia Experimentalis et Applicata*, 143(2): 111-119. <https://doi.org/10.1111/j.1570-7458.2012.01238.x>
- Calvo, F., Soriano, J., Stansly, P., & Belda, J. (2016). Can the parasitoid *necremnus tuta* (hymenoptera: eulophidae) improve existing biological control of the tomato leafminer *tuta absoluta* (lepidoptera: gelechiidae)?. *Bulletin of Entomological Research*, 106(4): 502-511. <https://doi.org/10.1017/s0007485316000183>
- Calvo, J., Bolckmans, K., Stansly, P., & Urbaneja, A. (2008). Predation by *nesidiocoris tenuis* on *Bemisia tabaci* and injury to tomato. *BioControl*, 54(2): 237-246. <https://doi.org/10.1007/s10526-008-9164-y>
- Campos, M., Monticelli, L., Béarez, P., Amiens-Desneux, E., Wang, Y., Lavoit, A., & Desneux, N. (2019). Impact of a shared sugar food source on biological control of *Tuta absoluta* by the parasitoid *necremnus tuta*. *Journal of Pest Science*, 93(1): 207-218. <https://doi.org/10.1007/s10340-019-01167-9>
- Candan, H., & Şahin, H. (2023). Breast cancer prediction with artificial intelligence based clinical decision support system. *Electronic Letters on Science and Engineering*, 19(1): 29-35.
- Cañizares, M., Rosas-Díaz, T., Rodríguez-Negrete, E., Hogenhout, S., Bedford, I., Bejarano, E., & Moriones, E. (2014). *Arabidopsis thaliana*, an experimental host for tomato yellow leaf curl disease-associated begomoviruses by agroinoculation and whitefly transmission. *Plant Pathology*, 64(2): 265-271. <https://doi.org/10.1111/ppa.12270>
- Cantez, E., Şahin, H., & Efe, O. F. (2023). Regional guidance system for cleaning robots as a result of pollution of solar panels. *The Eurasia Proceedings of Science Technology Engineering and Mathematics*, 22, 274-279.
- Cárcamo, H., Otani, J., Dosdall, L., Blackshaw, R., Clayton, G., Harker, K., & Entz, T. (2008). Effects of seeding date and canola species on seedling damage by flea beetles in three ecoregions. *Journal of Applied Entomology*, 132(8): 623-631. <https://doi.org/10.1111/j.1439-0418.2008.01298.x>

- Carrillo, J., Ingwell, L., Li, X., & Kaplan, I. (2019). Domesticated tomatoes are more vulnerable to negative plant–soil feedbacks than their wild relatives. *Journal of Ecology*, 107(4): 1753-1766. <https://doi.org/10.1111/1365-2745.13157>
- Cavazza, A. (2023). Artificial intelligence and new business models in agriculture: A structured literature review and future research agenda. *British Food Journal*, 125(13): 436-461. <https://doi.org/10.1108/bfj-02-2023-0132>
- Chaisuekul, C., Riley, D., & Pappu, H. (2003). Transmission of tomato spotted wilt virus to tomato plants of different ages. *Journal of Entomological Science*, 38(1): 127-136. <https://doi.org/10.18474/0749-8004-38.1.127>
- Chandy, A. (2019). Pest infestation identification in coconut trees using deep learning. *Journal of Artificial Intelligence and Capsule Networks*, 01(01): 10-18. <https://doi.org/10.36548/jaicn.2019.1.002>
- Chaudhari, S., More, P., Bhadak, S., Chaudhari, S., & Gawali, T. (2020). A survey on applications of artificial intelligence for enhancement in learning experience. *Asian Journal of Convergence in Technology*, 6(3): 86-89. <https://doi.org/10.33130/ajct.2020v06i03.013>
- Chen, C., Huang, Y., Li, Y., Chang, C., & Huang, Y. (2020). An AIoT based smart agricultural system for pests detection. *IEEE Access*, 8, 180750-180761. <https://doi.org/10.1109/access.2020.3024891>
- Chen, J., Chen, D., Kong, R., Yi, W., Yao, H., & Zhao, Y. (2023). Research on identification algorithm of crop pests and diseases based on improved densenet model. <https://doi.org/10.1117/12.2681193>
- Chen, J., Lin, W., Cheng, H., Hung, C., Lin, C., & Chen, S. (2021). A smartphone-based application for scale pest detection using multiple-object detection methods. *Electronics*, 10(4): 372. <https://doi.org/10.3390/electronics10040372>
- Chen, S. F., & Goodman, J. (1999). An empirical study of smoothing techniques for language modeling. *Computer Speech and Language*, 13(4): 359-394.
- Chen, T., Li, M., Li, Y., Lin, M., Wang, N., Wang, M., & Zhang, Z. (2015). Mxnet: A flexible and efficient machine learning library for heterogeneous distributed systems. *arXiv preprint arXiv:1512.01274*.
- Chen, W., Tseng, C., & Tsai, C. (2014). Effect of watermelon silver mottle virus on the life history and feeding preference of thrips palmi. *Plos One*, 9(7): e102021. <https://doi.org/10.1371/journal.pone.0102021>
- Cherif, A., & Verheggen, F. (2019). A review of *Tuta absoluta* (lepidoptera: gelechiidae) host plants and their impact on management strategies. *Base*, (4): 270-278. <https://doi.org/10.25518/1780-4507.18211>
- Chidege, M., Al-zaidi, S., Naveed, H., Julie, A., Kaaya, E., & Mrogoro, S. (2016). First record of tomato leaf miner *Tuta absoluta* (meyrick) (lepidoptera: gelechiidae) in tanzania. *Agriculture and Food Security*, 5(1): <https://doi.org/10.1186/s40066-016-0066-4>
- Chlingaryan, A., Sukkarieh, S., & Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and Electronics in Agriculture*, 151, 61-69.
- Chouinard, G., & diğerleri (2021). Yapay Zeka Tabanlı Zararlı Tespit Sistemlerinin Örtü Altı Domates Üretimindeki Etkinliği. *Tarımsal Yenilikler Dergisi*, 13(2): 45-59.
- Chung, S., & Felton, G. (2011). Specificity of induced resistance in tomato against specialist lepidopteran and coleopteran species. *Journal of Chemical Ecology*, 37(4): 378-386. <https://doi.org/10.1007/s10886-011-9937-0>

- Chung, S., Rosa, C., Scully, E., Peiffer, M., Tooker, J., Hoover, K., ... & Felton, G. (2013). Herbivore exploits orally secreted bacteria to suppress plant defenses. *Proceedings of the National Academy of Sciences*, 110(39): 15728-15733. <https://doi.org/10.1073/pnas.1308867110>
- Clements, J., Bradford, B., Lipke, M., Jansky, S., Olson, J., & Groves, R. (2022). Difference in foliar fatty acid composition in potato cultivars over a growing season may influence the host location preference of *Leptinotarsa decemlineata*. *American Journal of Potato Research*, 99(1): 40-47. <https://doi.org/10.1007/s12230-021-09857-w>
- Cocco, A., Deliperi, S., & Delrio, G. (2012). Control of *Tuta absoluta* (Meyrick) (Lepidoptera: Gelechiidae) in greenhouse tomato crops using the mating disruption technique. *Journal of Applied Entomology*, 137(1-2): 16-28. <https://doi.org/10.1111/j.1439-0418.2012.01735.x>
- Collobert, R., Kavukcuoglu, K., & Farabet, C. (2011). Torch7: A Matlab-like environment for machine learning. In *BigLearn, NIPS workshop* (No. CONF).
- Csizinszky, A., Schuster, D., & Kring, J. (1995). Color mulches influence yield and insect pest populations in tomatoes. *Journal of the American Society for Horticultural Science*, 120(5): 778-784. <https://doi.org/10.21273/JASHS.120.5.778>
- Cui, S., Inocente, E., Acosta, N., Keener, H., Zhu, H., & Ling, P. (2019). Development of fast e-nose system for early-stage diagnosis of aphid-stressed tomato plants. *Sensors*, 19(16): 3480. <https://doi.org/10.3390/s19163480>
- Cura, M. S., & Gençer, N. S. (2019). Side effects of azadirachtin on some important beneficial insects in laboratory.
- Cuthbertson, A., Mathers, J., Blackburn, L., Korycinska, A., Luo, W., Jacobson, R., & Northing, P. (2013). Population development of *Tuta absoluta* (Meyrick) (Lepidoptera: Gelechiidae) under simulated UK glasshouse conditions. *Insects*, 4(2): 185-197. <https://doi.org/10.3390/insects4020185>
- Czosnek, H., Ghanim, M., & Ghanim, M. (2002). The circulative pathway of begomoviruses in the whitefly vector *Bemisia tabaci* - insights from studies with tomato yellow leaf curl virus. *Annals of Applied Biology*, 140(3): 215-231. <https://doi.org/10.1111/j.1744-7348.2002.tb00175.x>
- DABSU, T. K., & KOVANCI, O. B. (2022). Evaluation of the pathogenicity of some entomopathogenic fungi against Tomato leaf miner *Tuta absoluta* (Meyrick)(Lepidoptera: Gelechiidae) larvae. *Türkiye Biyolojik Mücadele Dergisi*, 13(2): 103-117.
- Dabsu, T. K., & Kovanci, O. B. (2023). Efficacy of *Beauveria bassiana* and *Metarhizium anisopliae* against Tomato leaf miner *Phthorimaea absoluta* (Meyrick). *Indian Journal of Entomology*, 01-07.
- Dağlı, F., Ikten, C., Sert, E., & Bolucek, E. (2012). Susceptibility of tomato borer, *Tuta absoluta*(Meyrick) (Lepidoptera: Gelechiidae) populations from Turkey to 7 different insecticides in laboratory bioassay. *EPPO Bulletin*, 42(2): 305-311. <https://doi.org/10.1111/epp.2574>
- Darwin, S., & others. (2021). Enhancing pest detection capabilities in agricultural robots using deep learning models. *Journal of Agricultural Robotics*, 3(2): 45-59.
- Del-Campo-Sanchez, A., Ballesteros, R., Hernández-López, D., Álvarez, J., & Moreno, M. (2019). Quantifying the effect of *Jacobiasca lybica* pest on vineyards with UAVs by combining geometric and computer vision techniques. *PLOS ONE*, 14(4): e0215521. <https://doi.org/10.1371/journal.pone.0215521>

- Depieri, R., & Panizzi, A. (2011). Duration of feeding and superficial and in-depth damage to soybean seed by selected species of stink bugs (Heteroptera: Pentatomidae). *Neotropical Entomology*, 40(2): 197-203. <https://doi.org/10.1590/S1519-566X2011000200007>
- Desneux, N., Luna, M., Guillemaud, T., & Urbaneja, A. (2011). The invasive South American tomato pinworm, *Tuta absoluta*, continues to spread in Afro-Eurasia and beyond: The new threat to tomato world production. *Journal of Pest Science*, 84(4): 403-408. <https://doi.org/10.1007/s10340-011-0398-6>
- Desneux, N., Wajnberg, É., Wyckhuys, K., Burgio, G., Arpaia, S., Narváez-Vasquez, C., & Urbaneja, A. (2010). Biological invasion of European tomato crops by *Tuta absoluta*: Ecology, geographic expansion and prospects for biological control. *Journal of Pest Science*, 83(3): 197-215. <https://doi.org/10.1007/s10340-010-0321-6>
- Diabaté, D., Gnago, J., Koffi, K., & Tano, Y. (2014). The effect of pesticides and aqueous extracts of *Azadirachta indica* (A. Juss) and *Jatropha carcus* L. on *Bemisia tabaci* (Gennadius) (Homoptera: Aleyrididae) and *Helicoverpa armigera* (Hübner) (Lepidoptera: Noctuidae) found on tomato plants in Côte d'Ivoire. *Journal of Applied Biosciences*, 80(1): 7132. <https://doi.org/10.4314/jab.v80i1.14>
- Diaz-Montano, J., Fuchs, M., Nault, B., Fail, J., & Shelton, A. (2011). Onion thrips (Thysanoptera: Thripidae): A global pest of increasing concern in onion. *Journal of Economic Entomology*, 104(1): 1-13. <https://doi.org/10.1603/ec10269>
- Digilio, M., Cascone, P., Iodice, L., & Guerrieri, E. (2012). Interactions between tomato volatile organic compounds and aphid behaviour. *Journal of Plant Interactions*, 7(4): 322-325. <https://doi.org/10.1080/17429145.2012.727104>
- Digilio, M., Corrado, G., Sasso, R., Coppola, V., Iodice, L., Pasquariello, M., & Guerrieri, E. (2010). Molecular and chemical mechanisms involved in aphid resistance in cultivated tomato. *New Phytologist*, 187(4): 1089-1101. <https://doi.org/10.1111/j.1469-8137.2010.03314.x>
- Divya, B. & Santhi, M. (2023). Automatic detection and classification of insects using hybrid FF-GWO-CNN algorithm. *Intelligent Automation & Soft Computing*, 36(2): 1881-1898. <https://doi.org/10.32604/iasc.2023.031573>
- Dong, Y., Han, P., Niu, C., Zappalà, L., Amiens-Desneux, E., Béarez, P., & Desneux, N. (2017). Nitrogen and water inputs to tomato plant do not trigger bottom-up effects on a leafminer parasitoid through host and non-host exposures. *Pest Management Science*, 74(3): 516-522. <https://doi.org/10.1002/ps.4750>
- Dosdall, L. M., & Stevenson, F. C. (2005). Managing flea beetles (*Phyllotreta* spp.) (Coleoptera: Chrysomelidae) in canola with seeding date, plant density, and seed treatment. *Agronomy Journal*, 97(6): 1570-1578.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. arXiv preprint arXiv:1702.08608.
- Đurić, Z., Hrnčić, S., Mitrić, S., & Nikolić, P. (2017). Possible development of *Tuta absoluta* (Meyrick) on different host plants in the Republic of Srpska (Bosnia and Herzegovina). *Агрознање*, 17(4): 319. <https://doi.org/10.7251/agren1604319d>
- Escobar-Bravo, R., Klinkhamer, P., & Leiss, K. (2017). Induction of jasmonic acid-associated defenses by thrips alters host suitability for conspecifics and correlates with increased trichome densities in tomato. *Plant and Cell Physiology*, 58(3): 622-634. <https://doi.org/10.1093/pcp/pcx014>

- Eski, A. (2023). Farklı *Tuta absoluta* (Meyrick, 1917) (Lepidoptera: Gelechiidae) popülasyonlarının yerel *Bacillus thuringiensis* suşlarına duyarlılığı. *Turkish Journal of Entomology*, 47(1): 101-110. <https://doi.org/10.16970/entoted.1216414>
- Estay, P. (2000). Polilla del tomate *Tuta absoluta* (Meyrick). Informativo La Platina, 9. Instituto de Investigaciones Agropecuarias, Centro Regional de Investigación La Platina, Ministerio de Agricultura Santiago, Chile.
- Ewunkem, A. J., Sintim, H. Y., Dingha, B. N., Gyawaly, S., & Jackai, L. E. N. (2020). Nutritional ecology of the southern green stink bug *Nezara viridula* (Hemiptera: Pentatomidae) on selected varieties of cowpea and tomato. *American Journal of Entomology*, 4(1): 1–11. <https://doi.org/10.11648/j.aje.20200401.11>
- Fan, P., Miller, A. M., Liu, H., & Jones, A. D. (2017). Evolution of a flipped pathway creates metabolic innovation in tomato trichomes through BAHD enzyme promiscuity. *Nature Communications*, 8(1): 2080. <https://doi.org/10.1038/s41467-017-02045-7>
- Fernandes, M. E. S., Silva, D. J. H., Picanço, M. C., Fernandes, F. L., Jham, G. N., & Carneiro, P. C. S. (2011). Resistance of tomato subsamples to *Bemisia tabaci* biotype B (Genn.) (Hemiptera: Aleyrodidae). *Agronomy Journal*, 103(6): 1849–1861. <https://doi.org/10.2134/agronj2011.0049>
- Fuentes, A., Yoon, S., Kim, S. C., & Park, D. S. (2017). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors (Basel, Switzerland)*, 17(9): 2022. <https://doi.org/10.3390/s17092022>
- Gai, R., Chen, N., & Yuan, H. (2023). A detection algorithm for cherry fruits based on the improved YOLO-v4 model. *Neural Computing and Applications*, 35(19): 13895-13906. <https://doi.org/10.1007/s00521-021-06029-z>
- Gao, M., Luan, Y., Yu, H., & Bao, Y. (2016). Çin'de Domates Yaprak Lekesi Hastalığının *Fusarium proliferatum* ile İlk Raporu. *Canadian Journal of Plant Pathology*, 38, 400-404.
- Garzia, G., Siscaro, G., Biondi, A., & Zappalà, L. (2012). *Tuta absoluta*, a south american pest of tomato now in the EPPO region: Biology, distribution and damage. *EPPO Bulletin*, 42(2): 205-210. <https://doi.org/10.1111/epp.2556>
- Gençer, N. S., Kovancı, O. B., & Kovancı, B. (2009). Distribution and current status of Hesperidae and Pieridae species (Lepidoptera) occurring in Bursa province, Northwestern Turkey. *Turkish Journal of Zoology*, 33(2): 215-223.
- George, D., Port, G., & Collier, R. (2019). Living on the edge: Using and improving trap crops for flea beetle management in small-scale cropping systems. *Insects*, 10(9): 286. <https://doi.org/10.3390/insects10090286>
- Ghafil, H. N., & Jármai, K. (2018). Comparative study of particle swarm optimization and artificial bee colony algorithms. *The Publications of the MultiScience - XXXII. MicroCAD International Scientific Conference*. <https://doi.org/10.26649/musci.2018.030>
- Ghosal, S., Blystone, D., Singh, A. K., Ganapathysubramanian, B., Singh, A., & Sarkar, S. (2018). An explainable deep machine vision framework for plant stress phenotyping. *Proceedings of the National Academy of Sciences*, 115(18): 4613-4618.
- Giang, T. T. H., Khai, T. Q., Im, D.-Y., & Ryoo, Y. (2022). Fast detection of tomato sucker using semantic segmentation neural networks based on RGB-D images. *Sensors (Basel, Switzerland)*, 22(14): 5140. <https://doi.org/10.3390/s22145140>

- Godzina, M., Kielkiewicz, M., & Szymczykiwicz, K. (2011). Varying abundance and dispersal of the two-spotted spider mite (*Tetranychus urticae* Koch, 1836, Acari: Prostigmata: Tetranychidae) on mi-tomato plants differing in allelic combination. *Biological Letters*, 48(2): 213-223. <https://doi.org/10.2478/v10120-011-0022-8>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Regularization for deep learning. *Deep Learning*, 216-261.
- Graham, B., Park, J., Billings, G., Hulse-Kemp, A., Haigler, C., & Lobaton, E. (2022). Efficient imaging and computer vision detection of two cell shapes in young cotton fibers. *Applications in Plant Sciences*, 10(6). <https://doi.org/10.1002/aps3.11503>
- Gupta, N., Gupta, B., Passi, K., & Jain, C. (2022). Applications of artificial intelligence based technologies in weed and pest detection. *Journal of Computer Science*, 18(6): 520-529. <https://doi.org/10.3844/jcssp.2022.520.529>
- Gül, T. (2021). Mustafakemalpaşa yöresi kimi sebze bahçelerinin beslenme durumlarının toprak, bitki ve meyve analizleri ile belirlenmesi. *Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*, 10-15.
- Güntürkün, R., Güçlü, S., & Şahin, H. (2020). Remote control of baby room in embedded system technology. *Electronic Letters on Science and Engineering*, 16(1): 36-44.
- Güven, Ö., & Şahin, H. (2022). Predictive maintenance based on machine learning in public transportation vehicles. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(1): 89-98.
- Haenlein, M., & Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4): 5-14. <https://doi.org/10.1177/0008125619864925>
- Hariharan, B., Arbeláez, P., Girshick, R., & Malik, J. (2015). Hypercolumns for object segmentation and fine-grained localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 447-456).
- Haseeb, M., Gordon, T., Kanga, L., & Legaspi, J. (2018). Abundance of natural enemies of *Nezara viridula* (Hemiptera: Pentatomidae) on three cultivars of sweetpotato. *Journal of Applied Entomology*, 142(9): 847-853. <https://doi.org/10.1111/jen.12552>
- He, J., Chen, K., Pan, X., Zhai, J., & Lin, X. (2023). Advanced biosensing technologies for monitoring of agriculture pests and diseases: A review. *Journal of Semiconductors*, 44.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask R-CNN. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 2961-2969).
- Heinz, K.M., Van Driesche, R.G., & Parella, M.P. (2004). *Biocontrol in protected culture*. Ball Publishing.
- Henneberry, T.J., Jech, L., Hendrix, D.L., & Steele, T. (1999). *Bemisia argentifolii* (Homoptera: Aleyrodidae): Factors affecting adult and nymph honeydew production. *Southwestern Entomologist*, 24: 207-231.
- Hernandez-Castillo, C., Guedea-Noriega, H.H., Rodríguez-García, M.Á., & García-Sánchez, F. (2019). Pest recognition using natural language processing.
- Heuvelink, E. (2005). *Tomatoes*. CABI Publishing, Wallingford, Oxfordshire, UK.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8): 1735-1780.
- Hogea, S. (2020). *Tuta absoluta* (meyrick) (Lepidoptera: Gelechiidae) – Biology, ecology, prevention and control measures and means in greenhouse tomato crops: A review.

- Current Trends in Natural Sciences, 9(17): 222-231.
<https://doi.org/10.47068/ctns.2020.v9i17.028>
- Holzworth, D., Huth, N., Voil, P.D., Zurcher, E., Herrmann, N., McLean, G., & Keating, B. (2014). APSIM - Evolution towards a new generation of agricultural systems simulation. *Environmental Modelling & Software*, 62, 327-350.
- Hong, Y., Meng, J., He, X., Zhang, Y., & Luan, Y. (2019). Overexpression of mir482c in tomato induces enhanced susceptibility to late blight. *Cells*, 8(8): 822.
<https://doi.org/10.3390/cells8080822>
- Hu, J., Barro, P., Zhao, H., Wang, J., Nardi, F., & Liu, S. (2011). An extensive field survey combined with a phylogenetic analysis reveals rapid and widespread invasion of two alien whiteflies in china. *Plos One*, 6(1): e16061.
<https://doi.org/10.1371/journal.pone.0016061>
- Hu, W., Hong, W., Wang, H., Liu, M., & Liu, S. (2023). A study on tomato disease and pest detection method. *Applied Sciences*.
- Huda, M., Jahan, T., Taj, H., & Asiry, K. (2020). A newly emerged pest of tomato [tomato leaf miner, *Tuta absoluta* Meyrick (lepidoptera: gelechiidae)]: In Bangladesh – A review on its problems and management strategies. *Journal of Agriculture and Ecology Research International*, 1-16.
<https://doi.org/10.9734/jaeri/2020/v21i330132>
- Illakwahhi, D. & Srivastava, B. (2017). Control and management of tomato leafminer - *Tuta absoluta* (Meyrick) (Lepidoptera, Gelechiidae): A review. *IOSR Journal of Applied Chemistry*, 10(6): 14-22. <https://doi.org/10.9790/5736-1006011422>
- Innes, M. (2018). Flux: Elegant machine learning with Julia. *Journal of Open Source Software*, 3(25): 602.
- Jensen, M.B., Nasrollahi, K. & Moeslund, T.B. (2017). Evaluating state-of-the-art object detector on challenging traffic light data. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 9-15).
<https://doi.org/10.1109/cvprw.2017.122>
- Jiao, L., Li, G., Chen, P., Wang, R., Du, J., Liu, H., & Dong, S. (2022). Global context-aware-based deformable residual network module for precise pest recognition and detection. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.895944>
- Jin, X., Sun, Y., Che, J., Bagavathiannan, M., Yu, J. & Chen, Y. (2022). A novel deep learning-based method for detection of weeds in vegetables. *Pest Management Science*, 78(5): 1861-1869. <https://doi.org/10.1002/ps.6804>
- Jones, D. (2005). Plant viruses transmitted by thrips. *European Journal of Plant Pathology*, 113(2): 119-157. <https://doi.org/10.1007/s10658-005-2334-1>
- Jones, H.G. (1992). *Plants and Microclimate: A Quantitative Approach to Environmental Plant Physiology*. Cambridge University Press: New York, NY, USA, 428.
- Jurafsky, D. & Martin, J.H. (2019). *Speech and Language Processing* (3rd draft ed.).
- Kakimoto, K., Inoue, H., Yamaguchi, T., Ueda, S., Honda, K. & Yano, E. (2007). Host plant effect on development and reproduction of *Bemisia argentifolii* Bellows et Perring (*B. tabaci* [Gennadius] B-biotype) (Homoptera: Aleyrodidae). *Applied Entomology and Zoology*, 42(1): 63-70. <https://doi.org/10.1303/aez.2007.63>
- Kamilaris, A. & Prenafeta-Boldú, F.X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90.
<https://doi.org/10.1016/j.compag.2018.02.016>
- Kennedy, M.C.A. (2017). Pycharm, Python IDE for professional developers.

- Kim, M., & Lan, Q. (2011). Larvicidal activity of α -mangostin in the Colorado potato beetle, *Leptinotarsa decemlineata*. *Journal of Pesticide Science*, 36(3), 370-375. <https://doi.org/10.1584/jpestics.g11-09>
- Kirk, W.D.J. (1997). Distribution, abundance, and population dynamics. In T. Lewis (Ed.), *Thrips as Crop Pests*. CABI, Oxon, UK, pp. 217–257.
- Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B.E., Bussonnier, M., Frederic, J., ... & Willing, C. (2016). Jupyter Notebooks-a publishing format for reproducible computational workflows. *Elpub*, 2016, 87-90.
- Kouassi, K., Monticelli, L., Ouali-N’Goran, S., Ramirez-Romero, R., Martin, T., & Desneux, N. (2021). Combination of generalist predators, *Nesidiocoris tenuis* and *Macrolophus pygmaeus*, with a companion plant, *Sesamum indicum*: What benefit for biological control of *Tuta absoluta*? *Plos One*, 16(9), e0257925. <https://doi.org/10.1371/journal.pone.0257925>
- Kovanci, O.B., Schal, C., Walgenbach, J.F., & Kennedy, G.G. (2005). Comparison of mating disruption with pesticides for management of oriental fruit moth (Lepidoptera: Tortricidae) in North Carolina apple orchards. *Journal of Economic Entomology*, 98(4), 1248-1258.
- Kumbasaroğlu, H., Aşkan, E., & Dağdemir, V. (2021). Türkiye’de domatesin ekonomik analizi. *Mediterranean Agricultural Sciences*, 34(1), 47-54. <https://doi.org/10.29136/mediterranean.734756>
- Kuzuhara, H., Takimoto, H., Sato, Y., & Kanagawa, A. (2020). Insect pest detection and identification method based on deep learning for realizing a pest control system. 2020 59th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE), 709-714. DOI: 10.23919/SICE48898.2020.9240458
- Lavore, A., Perez-Gianmarco, L., Esponda-Behrens, N., Palacio, V., Catalano, M., Rivera-Pomar, R., ... & Ons, S. (2018). *Nezara viridula* (Hemiptera: Pentatomidae) transcriptomic analysis and neuropeptidomics. *Scientific Reports*, 8(1). <https://doi.org/10.1038/s41598-018-35386-4>
- Lawal, M.O. (2021). Tomato detection based on modified YOLOv3 framework. *Scientific Reports*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Lee, B., Yun, H., Hong, I., Jung, Y., & Lee, S. (2021). The effect of mixed cultivation using companion plants on the growth and quality of cherry tomatoes. *Journal of People Plants and Environment*, 24(4), 311-327. <https://doi.org/10.11628/ksppe.2021.24.4.311>
- Leeuwen, T., Tirry, L., Yamamoto, A., Nauen, R., & Dermauw, W. (2015). The economic importance of acaricides in the control of phytophagous mites and an update on recent acaricide mode of action research. *Pesticide Biochemistry and Physiology*, 121, 12-21. <https://doi.org/10.1016/j.pestbp.2014.12.009>
- Legg, S., & Hutter, M. (2007). Universal intelligence: A definition of machine intelligence. *Minds and Machines*, 17(4), 391-444. <https://doi.org/10.1007/s11023-007-9079-x>
- Li, G., Li, Z., Zhang, C., Li, Y., & Yue, J. (2019). Shellfish detection based on fusion attention mechanism in end-to-end network. DOI: 10.1007/978-3-030-31726-3_44.
- Li, J., & Wang, X. (2020). Tomato diseases and pests detection based on improved yolo v3 convolutional neural network. *Frontiers in Plant Science*, 11. <https://doi.org/10.3389/fpls.2020.00898>

- Li, J., & Wang, X. (2021). Plant diseases and pests detection based on deep learning: A review. *Plant Methods*, 17(1). <https://doi.org/10.1186/s13007-021-00722-9>
- Li, M., Zhang, Z., Lei, L., Wang, X., & Guo, X. (2020). Agricultural greenhouses detection in high-resolution satellite images based on convolutional neural networks: Comparison of faster R-CNN, YOLO v3, and SSD. *Sensors*, 20(17):4938. <https://doi.org/10.3390/s20174938>
- Li, T., Wang, J., & Zhang, T. (2022). L-detr: A light-weight detector for end-to-end object detection with transformers. *IEEE Access*, 10, 105685-105692. <https://doi.org/10.1109/ACCESS.2022.3208889>
- Li, X., Guo, W., Siemann, E., Yan, W., Huang, W., & Ding, J. (2016). Plant genotypes affect aboveground and belowground herbivore interactions by changing chemical defense. *Oecologia*, 182(4), 1107-1115. <https://doi.org/10.1007/s00442-016-3719-x>
- Lietti, M., Botto, E., & Alzogaray, R. (2005). Insecticide resistance in argentine populations of *Tuta absoluta* (Meyrick) (Lepidoptera: Gelechiidae). *Neotropical Entomology*, 34(1), 113-119. <https://doi.org/10.1590/s1519-566x2005000100016>
- Litskas, V., Migeon, A., Navajas, M., Tixier, M., & Stavrindes, M. (2019). Impacts of climate change on tomato, a notorious pest and its natural enemy: Small scale agriculture at higher risk. *Environmental Research Letters*, 14(8), 084041. <https://doi.org/10.1088/1748-9326/ab3313>
- Liu, B., Preisser, E., Chu, D., Pan, H., Xie, W., Wang, S., & Zhang, Y. (2013). Multiple forms of vector manipulation by a plant-infecting virus: *Bemisia tabaci* and tomato yellow leaf curl virus. *Journal of Virology*, 87(9), 4929-4937. <https://doi.org/10.1128/JVI.03571-12>
- Liu, J., Wang, X., Miao, W., & Liu, G. (2022). Tomato pest recognition algorithm based on improved YOLOv4. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.814681>
- Liu, N., Shapira, P., & Yue, X. (2021). Tracking developments in artificial intelligence research: Constructing and applying a new search strategy. *Scientometrics*, 126(4), 3153-3192. <https://doi.org/10.1007/s11192-021-03868-4>
- Liu, Z., Roberts, R., Chen, X., Huang, R., & Tong, W. (2021). AI-based language models powering drug discovery and development. *Drug Discovery Today*, 26(11), 2593-2607. <https://doi.org/10.1016/j.drudis.2021.06.009>
- Lomate, P., & Bonning, B. (2016). Distinct properties of proteases and nucleases in the gut, salivary gland, and saliva of southern green stink bug, *Nezara viridula*. *Scientific Reports*, 6(1). <https://doi.org/10.1038/srep27587>
- Lu, W., & Kennedy, G. (2001). Genetic analysis of larval survival and larval growth of two populations of *Leptinotarsa decemlineata* on tomato. *Entomologia Experimentalis et Applicata*, 99(2), 143-155. <https://doi.org/10.1046/j.1570-7458.2001.00812.x>
- Luo, Y. (2023). Detection of agricultural pests based on yolo. *Journal of Physics Conference Series*, 2560(1), 012013. <https://doi.org/10.1088/1742-6596/2560/1/012013>
- Mamphogoro, T., Babalola, O., & Aiyegoro, O. (2020). Sustainable management strategies for bacterial wilt of sweet peppers (*Capsicum annum*) and other solanaceous crops. *Journal of Applied Microbiology*, 129(3), 496-508. <https://doi.org/10.1111/jam.14653>

- Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., & Amodei, D. (2020). Language models are few-shot learners. arXiv preprint arXiv:2005.14165.
- Manu, J., & Afun, J. (2021). Evaluation of synthetic insecticides for the management of *Helicoverpa armigera* mill in tomato production. *Asian Journal of Advances in Agricultural Research*, 17-28. <https://doi.org/10.9734/ajaar/2021/v16i130164>
- Marchoux, G., Gebre-Selassie, K., & Villevieille, M. (1991). Detection of tomato spotted wilt virus and transmission by *Frankliniella occidentalis* in France. *Plant Pathology*, 40(3), 347-351. <https://doi.org/10.1111/j.1365-3059.1991.tb02389.x>
- Maruthi, M., Colvin, J., Thwaites, R., Banks, G., Gibson, G., & Seal, S. (2004). Reproductive incompatibility and cytochrome oxidase I gene sequence variability amongst host-adapted and geographically separate *Bemisia tabaci* populations (Hemiptera: Aleyrodidae). *Systematic Entomology*, 29(4), 560-568. <https://doi.org/10.1111/j.0307-6970.2004.00272.x>
- Masetti, A., Luchetti, A., Mantovani, B., & Burgio, G. (2006). Polymerase chain reaction-restriction fragment length polymorphism assays to distinguish *Liriomyza huidobrensis* (Diptera: Agromyzidae) from associated species on lettuce cropping systems in Italy. *Journal of Economic Entomology*, 99(4), 1268-1272. <https://doi.org/10.1603/0022-0493-99.4.1268>
- Maslo, B., Valentin, R., Leu, K., Kerwin, K., Hamilton, G., Bevan, A., ... & Fonseca, D. (2017). Chiro-surveillance: the use of native bats to detect invasive agricultural pests. *PLOS ONE*, 12(3), e0173321. <https://doi.org/10.1371/journal.pone.0173321>
- Mazairac, W., & Beetz, J. (2013). BIMQL - An open query language for building information models. *Advances in Engineering Informatics*, 27(4), 444-456. <https://doi.org/10.1016/j.aei.2013.06.001>
- McNitt, J., Chungbaek, Y., Mortveit, H., Marathe, M., Campos, M., Desneux, N., ... & Adiga, A. (2019). Assessing the multi-pathway threat from an invasive agricultural pest. Source not provided.
- Mirhaji, H., Soleymani, M., Asakereh, A., & Mehdizadeh, S.A. (2021). Fruit detection and load estimation of an orange orchard using the YOLO models through simple approaches in different imaging and illumination conditions. *Computers and Electronics in Agriculture*, 191:106533. <https://doi.org/10.1016/j.compag.2021.106533>
- Mohanty, S.P., Hughes, D.P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. <https://doi.org/10.3389/fpls.2016.01419>
- Moreno-Delafuente, A., Garzo, E., Moreno, A., & Fereres, A. (2013). A plant virus manipulates the behavior of its whitefly vector to enhance its transmission efficiency and spread. *PLOS ONE*, 8(4), e61543. <https://doi.org/10.1371/journal.pone.0061543>
- Mudgil, R., Garg, N., Singh, P., & Madhu, C. (2022). Identification of tomato plant diseases using CNN- A comparative review. In *2022 IEEE World Conference on Applied Intelligence and Computing (AIC)*, 174-181.
- Mugerwa, H., Seal, S., Wang, H., Patel, M., Kabaalu, R., Omongo, C., & Colvin, J. (2018). African ancestry of new world, *Bemisia tabaci*-whitefly species. *Scientific Reports*, 8(1). <https://doi.org/10.1038/s41598-018-20956-3>

- Mul, M., Ploegaert, J.P.M., George, D., Meerburg, B., Dicke, M., & Koerkamp, P. (2016). Structured design of an automated monitoring tool for pest species. *Biosystems Engineering*, 151, 126-140. DOI: 10.1016/J.BIOSYSTEMSENG.2016.08.023
- Murad, N., Mahmood, T., Forkan, A., Morshed, A., Jayaraman, P., & Siddiqui, M. (2023). Weed detection using deep learning: a systematic literature review. *Sensors*, 23(7), 3670. <https://doi.org/10.3390/s23073670>
- Musolin, D. (2012). Surviving winter: diapause syndrome in the southern green stink bug *Nezara viridula* in the laboratory, in the field, and under climate change conditions. *Physiological Entomology*, 37(4), 309-322. <https://doi.org/10.1111/j.1365-3032.2012.00846.x>
- Mustapha, S., Musa, A., & Aliyu, A. (2021). Assessment of leaf miner *Liriomyza* spp (Diptera: Agromyzidae) damage on tomato and the yield output in Ilorin, southern Guinea savannah, Nigeria. *Agrosearch*, 20(2), 1-9. <https://doi.org/10.4314/agrosh.v20i2.1>
- Muthaiah, U., & Chitra, S. (2023). Mango pest detection using entropy-elm with whale optimization algorithm. *Intelligent Automation & Soft Computing*, 35(3), 3447-3458. <https://doi.org/10.32604/iasc.2023.028869>
- Ndalo Victor, G., Gathu R. K., & Maina M. (2019). Population growth of tomato leaf miner moth (*Tuta absoluta*) within Loitokitok Kajiado County-Kenya. *JBAH*. <https://doi.org/10.7176/jbah/9-22-04>
- Ni, X., Quisenberry, S., Markwell, J., Heng-Moss, T., Higley, L., Baxendale, F., & Klucas, R. (2001). In vitro enzymatic chlorophyll catabolism in wheat elicited by cereal aphid feeding. *Entomologia Experimentalis Et Applicata*, 101(2), 159-166. <https://doi.org/10.1046/j.1570-7458.2001.00900.x>
- Palwankar, T., & Kothari, K. (2022). Real time object detection using SSD and MobileNet. *International Journal for Research in Applied Science and Engineering Technology*. DOI: 10.22214/ijraset.2022.40755.
- Pan, H., Chu, D., Yan, W., Su, Q., Liu, B., Wang, S., & Zhang, Y. (2012). Rapid spread of tomato yellow leaf curl virus in China is aided differentially by two invasive whiteflies. *PLOS ONE*, 7(4), e34817. <https://doi.org/10.1371/journal.pone.0034817>
- Pandey, S., Silva, A., Dutta, B., Chong, J., Mutschler, M., & Schmidt, J. (2023). Acylsugar tomato lines suppress whiteflies and *Amblyseius swirskii* establishment. *Entomologia Experimentalis Et Applicata*. <https://doi.org/10.1111/eea.13342>
- Parrella, M. (1987). Biology of *liriomyza*. *Annual Review of Entomology*, 32(1), 201-224. <https://doi.org/10.1146/annurev.en.32.010187.001221>
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., & Chintala, S. (2019). Pytorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, 32.
- Pattnaik, G., & Parvathi, K. (2020). Automatic detection and classification of tomato pests using support vector machine based on hog and lbp feature extraction technique. *Springer*, 49-55. https://doi.org/10.1007/978-981-15-6353-9_5
- Pautasso, C., Zimmermann, O., & Leymann, F. (2008, April). Restful web services vs. "big" web services: Making the right architectural decision. In *Proceedings of the 17th International Conference on World Wide Web* (pp. 805-814).
- Pehlevan, B., & Kovancı, O. B. (2017). Using degree-day and nonlinear regression models to predict seasonal flights of *Adoxophyes orana* (FVR)(Lepidoptera: Tortricidae) in plum orchards. *Turkish Journal of Entomology*, 41(1), 75-86.

- Pehlevan, B., & Kovanci, O. B. (2018). Laboratory assay of toxicity and oviposition deterrence of selected vegetable seed oils against *Cacopsylla pyricola* (Homoptera: Psyllidae). *Journal of Entomological Science*, 53(2), 192-204.
- Perdikis, D., Arvaniti, K., Paraskevopoulos, A., & Grigoriou, A. (2017). Pre-plant release enhanced the earlier establishment of *nesidiocoris tenuis* in open field tomato. *Entomologia Hellenica*, 24(1), 11. <https://doi.org/10.12681/eh.11541>
- Pérez-Hedo, M., Alonso-Valiente, M., Vacas, S., Gallego, C., Pons, C., Arbona, V., & Granell, A. (2021). Plant exposure to herbivore-induced plant volatiles: A sustainable approach through eliciting plant defenses. *Journal of Pest Science*, 94(4), 1221-1235. <https://doi.org/10.1007/s10340-021-01334-x>
- Pitan, O., & Olatunde, G. (2006). Effects of intercropping tomato (*lycopersicon esculentum*) at different times with cowpea (*vigna unguiculata*) or okra (*abelmoschus esculentus*) on crop damage by major insect pests. *The Journal of Agricultural Science*, 144(4), 361-368. <https://doi.org/10.1017/s0021859606006277>
- Polston, J., Barro, P., & Boykin, L. (2014). Transmission specificities of plant viruses with the newly identified species of the *Bemisia tabaci* species complex. *Pest Management Science*, 70(10), 1547-1552. <https://doi.org/10.1002/ps.3738>
- Prabha, R., Kennedy, J., Vanitha, G., Sathiah, N., & Priya, M. (2022). Android application development for identifying maize infested with fall armyworms with tamil nadu agricultural university integrated proposed pest management (TNAU IPM) capsules. *Journal of Applied and Natural Science*, 14(SI), 138-144. <https://doi.org/10.31018/jans.v14isi.3599>
- Prabha, R., Kennedy, J., Vanitha, G., Sathiah, N., & Priya, M. (2022). Android application development for identifying maize infested with fall armyworms with Tamil Nadu Agricultural University integrated proposed pest management (TNAU IPM) capsules. *Journal of Applied and Natural Science*, 14(SI), 138-144. <https://doi.org/10.31018/jans.v14isi.3599>
- Pratissoli, D., Lima, V., Pirovani, V., & Lima, W. (2015). Occurrence of *Helicoverpa armigera* (Lepidoptera: Noctuidae) on tomato in the Espírito Santo state. *Horticultura Brasileira*, 33(1), 101-105. <https://doi.org/10.1590/s0102-053620150000100016>
- Quinet, M., Angosto, T., Yuste-Lisbona, F. J., Blanchard-Gros, R., Bigot, S., Martínez, J. P., & Lutts, S. (2019). Tomato fruit development and metabolism. *Frontiers in Plant Science*, 10. <https://doi.org/10.3389/fpls.2019.01554>
- Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., & Sutskever, I. (2019). Language models are unsupervised multitask learners. *OpenAI Blog*, 1(8), 9.
- Radžiutė, S., & Būda, V. (2012). Host feeding experience affects host plant odour preference of the polyphagous leafminer *Liriomyza bryoniae*. *Entomologia Experimentalis et Applicata*, 146(2), 286-292. <https://doi.org/10.1111/eea.12028>
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 779-788).
- Rezayi, S., Liu, Z.-L., Wu, Z., Dhakal, C., Ge, B., Zhen, C., ... & Li, S. (2022). AgriBERT: Knowledge-infused agricultural language models for matching food and nutrition. *Link*.

- Ricupero, M., Biondi, A., Russo, A., Zappalà, L., & Mazzeo, G. (2021). The cotton mealybug is spreading along the Mediterranean: First pest detection in Italian tomatoes. *Insects*, 12(8), 675. <https://doi.org/10.3390/insects12080675>
- Riedell, W., & Kieckhefer, R. (1995). Feeding damage effects of three aphid species on wheat root growth. *Journal of Plant Nutrition*, 18(9), 1881-1891. <https://doi.org/10.1080/01904169509365030>
- Roda, A., Castillo, J., Allen, C., Urbaneja, A., Weihman, S., & Stansly, P. (2020). Biological control potential and drawbacks of three zoophytophagous mirid predators against *Bemisia tabaci* in the United States. *Insects*, 11(10), 670. <https://doi.org/10.3390/insects11100670>
- Rubanga, D., Loyani, L., Richard, M., & Shimada, S. (2020). A deep learning approach for determining effects of *Tuta absoluta* in tomato plants. *arXiv preprint arXiv:2004.04023*.
- Sánchez, J. (2008). Zoophytophagy in the plantbug *Nesidiocoris tenuis*. *Agricultural and Forest Entomology*, 10(2), 75-80. <https://doi.org/10.1111/j.1461-9563.2007.00357.x>
- Sasso, R., Iodice, L., Digilio, M. C., Carretta, A., Ariati, L., & Guerrieri, E. (2007). Host-locating response by the aphid parasitoid *Aphidius ervi* to tomato plant volatiles. *Journal of Plant Interactions*, 2(3), 175-183. <https://doi.org/10.1080/17429140701591951>
- Sasso, R., Iodice, L., Woodcock, C. M., Pickett, J. A., & Guerrieri, E. (2009). Electrophysiological and behavioural responses of *Aphidius ervi* (Hymenoptera: Braconidae) to tomato plant volatiles. *Chemoecology*, 19(4), 195-201. <https://doi.org/10.1007/s00049-009-0023-9>
- Satiansiriwat, S., Intorrathed, S., & Siriwan, N. (2018). Integration of agricultural knowledge with the Thai language, mathematics, and science subjects for first-year elementary school of Thailand. *The New Educational Review*, 51(1), 41-52. <https://doi.org/10.15804/tner.2018.51.1.03>
- Selvanarayanan, V., & Narayanasamy, P. (2006). Factors of resistance in tomato accessions against the fruit worm, *Helicoverpa armigera* (Hubner). *Crop Protection*, 25(10), 1075-1079. <https://doi.org/10.1016/j.cropro.2006.02.008>
- Selvaraj, M., Vergara, A., Ruiz, H., Safari, N., Elayabalan, S., Ocimati, W., & Blomme, G. (2019). AI-powered banana diseases and pest detection. *Plant Methods*, 15(1). <https://doi.org/10.1186/s13007-019-0475-z>
- Seplyarsky, V., Weiss, M., & Haberman, A. (2010). *Tuta absoluta* Povolny (Lepidoptera: Gelechiidae), a new invasive species in Israel. *Phytoparasitica*, 38(5), 445-446. <https://doi.org/10.1007/s12600-010-0115-7>
- Shah, M., & Liu, T. (2013). Feeding experience of *Bemisia tabaci* (Hemiptera: Aleyrodidae) affects their performance on different host plants. *PLOS ONE*, 8(10), e77368. <https://doi.org/10.1371/journal.pone.0077368>
- Sharma, P., et al. (2022). Development of automated systems for agricultural pest and disease detection: A review. *Agricultural Informatics*, 4(1), 100-115.
- Sharma, S., Devlash, R., Kumar, J., Bala, B., & Jamwal, R. (2016). Evaluation of IPM modules for the management of fruit borer and fruit rot diseases in tomato, *Lycopersicon esculentum* Miller. *Journal of Applied and Natural Science*, 8(1), 240-244. <https://doi.org/10.31018/jans.v8i1.780>

- Sharma, S., Sharma, G., & Menghani, E. (2022). The role of CNN in detection and prediction of tomato leaf disease: A review. *Proceedings of the 4th International Conference on Information Management & Machine Intelligence*.
- Shiberu, T. (2017). Evaluation of some insecticides against tomato leaf miner, *Tuta absoluta* (Meyrick) (Gelechiidae: Lepidoptera) under laboratory and glasshouse conditions. *Agricultural Research & Technology Open Access Journal*, 7(3). <https://doi.org/10.19080/artoaj.2017.07.555711>
- Shiberu, T., & Getu, E. (2018). Determination of the economic threshold level of tomato leaf miner, *Tuta absoluta* Meyrick (Lepidoptera: Gelechiidae) on tomato plant under glasshouse conditions. *Journal of Horticulture and Forestry*, 10(2), 9-16. <https://doi.org/10.5897/jhf2018.0522>
- Shoaib, M., Hussain, T., Shah, B., Ullah, I., Shah, S. M., Ali, F., & Park, S. H. (2022). Deep learning-based segmentation and classification of leaf images for detection of tomato plant disease. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1031748>
- Shutske, J. M. (2023). Editorial: Harnessing the power of large language models in agricultural safety & health. *Journal of Agricultural Safety and Health*. DOI: 10.13031/jash.15841
- Sim, S., Robbins, M., Chilcott, C., Zhu, T., & Francis, D. (2009). Oligonucleotide array discovery of polymorphisms in cultivated tomato (*Solanum lycopersicum* L.) reveals patterns of SNP variation associated with breeding. *BMC Genomics*, 10(1). <https://doi.org/10.1186/1471-2164-10-466>
- Siqueira, H., Guedes, R., & Picanço, M. (2000). Cartap resistance and synergism in populations of *Tuta absoluta* (Lep., Gelechiidae). *Journal of Applied Entomology*, 124(5-6), 233-238. <https://doi.org/10.1046/j.1439-0418.2000.00470.x>
- Soliman, T., Mourits, M., & Werf, W. (2013). Economic justification for quarantine status - The case study of 'Candidatus *Liberibacter solanacearum*' in the European Union. *Plant Pathology*, 62(5), 1106-1113. <https://doi.org/10.1111/ppa.12026>
- Sood, A., Sharma, R., & Bhardwaj, A. (2021). Artificial intelligence research in agriculture: A review. *Online Information Review*, 46(6): 1054-1075. <https://doi.org/10.1108/OIR-10-2020-0448>
- Sozzi, M., Cantalamessa, S., Cogato, A., Kayad, A., & Marinello, F. (2022). Automatic bunch detection in white grape varieties using YOLOv3, YOLOv4, and YOLOv5 deep learning algorithms. *Agronomy*, 12(2): 319. <https://doi.org/10.3390/agronomy12020319>
- Srinivasan, R., Abney, M., Lai, P., Culbreath, A., Tallury, S., & Leal-Bertioli, S. (2018). Resistance to thrips in peanut and implications for management of thrips and thrips-transmitted orthotospoviruses in peanut. *Frontiers in Plant Science*, 9. <https://doi.org/10.3389/fpls.2018.01604>
- Stout, M., Workman, K., Bostock, R., & Duffey, S. (1997). Specificity of induced resistance in the tomato, *Lycopersicon esculentum*. *Oecologia*, 113(1): 74-81. <https://doi.org/10.1007/s004420050355>
- Su, Q., Mescher, M., Wang, S., Chen, G., Xie, W., Wu, Q., & Zhang, Y. (2016). Tomato yellow leaf curl virus differentially influences plant defence responses to a vector and a non-vector herbivore. *Plant, Cell & Environment*, 39(3): 597-607. <https://doi.org/10.1111/pce.12650>

- Sun, Z., Zhai, J., Pei, L., Li, W., & Zhao, K. (2023). Automatic pavement crack detection transformer based on convolutional and sequential feature fusion. *Sensors*, 23(7): 3772. <https://doi.org/10.3390/s23073772>
- Sundararaman, B., Jagdev, S., & Khatri, N. (2023). Transformative role of artificial intelligence in advancing sustainable tomato (*Solanum lycopersicum*) disease management for global food security: A comprehensive review. *Sustainability*, 15(15): 11681. <https://doi.org/10.3390/su151511681>
- Szafranek, B., Synak, E., Waligora, D., Szafranek, J., & Nawrot, J. (2008). Leaf surface compounds of the potato (*Solanum tuberosum*) and their influence on Colorado potato beetle (*Leptinotarsa decemlineata*) feeding. *Chemoecology*, 18(4): 205-216. <https://doi.org/10.1007/s00049-008-0407-2>
- Şahin, H., & Topal, B. (2016). The effect of the use of information technologies in businesses on cost and financial performance. *International Journal of Engineering Innovations and Research (IJEIR)*, 5(6): 394-402.
- Şahin, H., & Topal, B. (2018). Impact of information technology on business performance: Integrated structural equation modeling and artificial neural network approach. *Scientia Iranica*, 25(3): 1272-1280.
- Şahin, H., Güntürkün, R., & Osman, H. I. Z. (2020). Design and application of PLC controlled robotic arm choosing objects according to their color. *Electronic Letters on Science and Engineering*, 16(2): 52-62.
- Şahin, Y. S., Gençer, N., & Susurluk, A. (2020). Control potentials of some entomopathogenic nematodes against Asian chestnut gall wasp, *Dryocosmus kuriphilus* Yasumatsu, 1951 (Hymenoptera: Cynipidae). *Turkish Journal of Entomology*, 44(4): 529-537.
- Şen, E., & Gençer, N. S. (2023). Toxic effects of essential oils against *Bemisia tabaci* (Gennadius, 1889) (Hemiptera: Aleyrodidae) and its certain important natural enemies. *Pakistan Journal of Agricultural Sciences*, 60(1).
- Talekar, N., Opeña, R., & Hanson, P. (2006). Helicoverpa armigera management: A review of AVRDC's research on host plant resistance in tomato. *Crop Protection*, 25(5): 461-467. <https://doi.org/10.1016/j.cropro.2005.07.011>
- Tan, M., Pang, R., & Le, Q. V. (2019). EfficientDet: Scalable and efficient object detection. In *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 1-10). DOI: 10.1109/CVPR42600.2020.01079.
- Tan, X., Wang, S., Ridsdill-Smith, T., & Liu, T. (2014). Direct and indirect impacts of infestation of tomato plant by *Myzus persicae* (Hemiptera: Aphididae) on *Bemisia tabaci* (Hemiptera: Aleyrodidae). *PLOS ONE*, 9(4): e94310. <https://doi.org/10.1371/journal.pone.0094310>
- Tannous, M., Stefanini, C., & Romano, D. (2023). A deep-learning-based detection approach for the identification of insect species of economic importance. *Insects*, 14(2): 148. <https://doi.org/10.3390/insects14020148>
- Tansey, J., Dosdall, L., & Keddie, B. (2009). Phyllotreta cruciferae and Phyllotreta striolata responses to insecticidal seed treatments with different modes of action. *Journal of Applied Entomology*, 133(3): 201-209. <https://doi.org/10.1111/j.1439-0418.2008.01321.x>
- Tian, M., Xu, L., Jiang, J., Zhang, S., Liu, T., & Xu, Y. (2020). Host plant species of *Bemisia tabaci* affect orientational behavior of the ladybeetle *Serangium japonicum* and their implication for the biological control strategy of whiteflies. *Insects*, 11(7): 434. <https://doi.org/10.3390/insects11070434>

- Tian, Y., Yang, G., Wang, Z., Li, E., & Liang, Z. (2019). Detection of apple lesions in orchards based on deep learning methods of CycleGAN and YOLOv3-Dense. *Journal of Sensors*, 2019, 1-13. <https://doi.org/10.1155/2019/7630926>
- Tilkov, S., & Vinoski, S. (2010). Node.js: Using JavaScript to build high-performance network programs. *IEEE Internet Computing*, 14(6): 80-83.
- Toffa, J., Dannon, E., Loko, Y., Bokossa, H., Adikpeto, J., Adandonon, A., & Tamò, M. (2023). Efficacy of beneficial fungi isolates in *Solanum lycopersicum* L. protection against lepidopteran insects through a leaf inoculation technique. *Advances in Microbiology*, 13(02), 89-105. <https://doi.org/10.4236/aim.2023.132006>
- Toffa, J., Loko, Y., Kpindou, O., Zanzana, K., Adikpeto, J., Gbenontin, Y., & Adandonon, A. (2021). Endophytic colonization of tomato plants by *Beauveria bassiana* Vuillemin (Ascomycota: Hypocreales) and leaf damage in *Helicoverpa armigera* (Hübner) (Lepidoptera: Noctuidae) larvae. *Egyptian Journal of Biological Pest Control*, 31(1). <https://doi.org/10.1186/s41938-021-00431-4>
- Tokumaru, S., Ando, Y., Kurita, H., Hayashida, Y., Ishiyama, M., & Abe, Y. (2007). Seasonal prevalence and species composition of *Liriomyza sativae* Blanchard, *L. trifolii* (Burgess), and *L. bryoniae* (Kaltenbach) (Diptera: Agromyzidae) in Kyoto prefecture. *Applied Entomology and Zoology*, 42(2): 317-327. <https://doi.org/10.1303/aez.2007.317>
- Toshova, T., Csonka, E., Subchev, M., & Tóth, M. (2009). The seasonal activity of flea beetles in Bulgaria. *Journal of Pest Science*, 82(3): 295-303. <https://doi.org/10.1007/s10340-009-0254-0>
- Tyler-Julian, K., Funderburk, J., Srivastava, M., Olson, S., & Adkins, S. (2018). Evaluation of a push-pull system for the management of *Frankliniella* species (Thysanoptera: Thripidae) in tomato. *Insects*, 9(4): 187. <https://doi.org/10.3390/insects9040187>
- Urbaneja, A., González-Cabrera, J., Arnó, J., & Gabarra, R. (2012). Prospects for the biological control of *Tuta absoluta*.
- Urmashiev, B., Buribayev, Z., Amirgaliyeva, Z. E., Ataniyazova, A., Zhassuzak, M., & Turegali, A. (2021). Development of a weed detection system using machine learning and neural network algorithms. *Eastern-European Journal of Enterprise Technologies*.
- Van Lenteren, J. C. (2000). Success in biological control of arthropods by augmentation of natural enemies. In *Biological Control: Measures of Success* (pp. 77-103). Dordrecht: Springer Netherlands.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.
- Wagan, T., He, Y., Long, M., Chakira, H., Zhao, J., & Hua, H. (2017). Effectiveness of aromatic plant species for repelling and preventing oviposition of *Bemisia tabaci* (Gennadius) (Hemiptera: Aleyrodidae). *Journal of Applied Entomology*, 142(3): 287-295. <https://doi.org/10.1111/jen.12471>
- Wakil, W., Ghazanfar, M., Kwon, Y., Qayyum, M., & Nasir, F. (2010). Distribution of *Helicoverpa armigera* Hübner (Lepidoptera: Noctuidae) in tomato fields and its relationship to weather factors. *Entomological Research*, 40(6): 290-297. <https://doi.org/10.1111/j.1748-5967.2010.00301.x>

- Wan, J., Yi, J., Tao, Z., Ren, Z., Otieno, E., Tian, B., Huang, W. (2022). Species-specific plant-mediated effects between herbivores converge at high damage intensity. *Ecology*, 103(5). <https://doi.org/10.1002/ecy.3647>
- Wang, J., Peiffer, M., Hoover, K., Rosa, C., Zeng, R., & Felton, G. (2017). *Helicoverpa zea* gut-associated bacteria indirectly induce defenses in tomato by triggering a salivary elicitor(s). *New Phytologist*, 214(3): 1294-1306. <https://doi.org/10.1111/nph.14429>
- Wang, Q., Zhang, S.-Y., Dong, S., Zhang, G.-C., Yang, J., Li, R., & Wang, H.-Q. (2020). Pest24: A large-scale very small object dataset of agricultural pests for multi-target detection. *Comput. Electron. Agric.*, 175, 105585. DOI: 10.1016/j.compag.2020.105585
- Wang, R., Li, R., Chen, T., Zhang, J., Xie, C., Qiu, K., Chen, P., Du, J., Chen, H., Shao, F., Hu, H., & Liu, H. (2022). An automatic system for pest recognition and forecasting. *Pest Management Science*, 78(2):711-721. <https://doi.org/10.1002/ps.6684>
- Wang, R., Liu, L., Xie, C., Yang, P., Li, R., & Zhou, M. (2021). Agripest: A large-scale domain-specific benchmark dataset for practical agricultural pest detection in the wild. *Sensors*, 21(5):1601. <https://doi.org/10.3390/s21051601>
- Wang, X., & Liu, J. (2021). Tomato anomalies detection in greenhouse scenarios based on YOLO-Dense. *Frontiers in Plant Science*, 12. <https://doi.org/10.3389/fpls.2021.634103>.
- Wang, X., Li, J., & Zhu, X. (2021). Early real-time detection algorithm of tomato diseases and pests in the natural environment. *Plant Methods*, 17(1). <https://doi.org/10.1186/s13007-021-00745-2>
- Wen, H., Huang, C., & Guo, S. (2021). The application of convolutional neural networks (CNNs) to recognize defects in 3D-printed parts. *Materials*, 14(10): 2575. <https://doi.org/10.3390/ma14102575>
- Wu, X., Zhan, C., Lai, Y., Cheng, M., & Yang, J. (2019). IP102: A large-scale benchmark dataset for insect pest recognition. <https://doi.org/10.1109/CVPR.2019.00899>
- Xiang, Q., Huang, X., Huang, Z., Chen, X., Cheng, J., & Tang, X. (2023). YOLO-pest: An insect pest object detection algorithm via CAC3 module. *Sensors*, 23(6): 3221. <https://doi.org/10.3390/s23063221>
- Xie, Y., Aggarwal, K., & Ahmad, A. (2023). Efficient continual pre-training for building domain-specific large language models. *ArXiv*, abs/2311.08545. DOI: 10.48550/arXiv.2311.08545. Link
- Yadav, S., Pal, R., Yadav, A., Yadav, A., & Singh, G. (2022). Seasonal incidence of tomato fruit borer, *Helicoverpa armigera* (Hubner) and its correlation with abiotic factors: An experimental investigation. *International Journal of Plant & Soil Science*, 1577-1582. <https://doi.org/10.9734/ijpss/2022/v34i2231535>
- Yang, G., Wang, J., Nie, Z., Yang, H., & Yu, S. (2023). A lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention. *Agronomy*. <https://doi.org/10.3390/agronomy13071824>
- Yang, H., Gao, L., Tang, N., & Yang, P. (2019). Experimental analysis and evaluation of wide residual networks based agricultural disease identification in smart agriculture system. *Eurasip Journal on Wireless Communications and Networking*, 2019(1). <https://doi.org/10.1186/s13638-019-1613-z>
- Yang, H., Gao, L., Tang, N., & Yang, P. (2019). Experimental analysis and evaluation of wide residual networks based agricultural disease identification in smart agriculture

- system. *Eurasip Journal on Wireless Communications and Networking*, 2019(1). <https://doi.org/10.1186/s13638-019-1613-z>
- Yang, M. (2022). Application of assembly construction in intelligent construction under the background of artificial intelligence. <https://doi.org/10.2991/ahis.k.220601.044>
- Yang, R., & Yu, Y. (2021). Artificial convolutional neural network in object detection and semantic segmentation for medical imaging analysis. *Frontiers in Oncology*, 11. <https://doi.org/10.3389/fonc.2021.638182>
- Yılmaz, M., Şahin, H., & Yıldız, A. (2021). Sectoral application analysis of studies made with deep learning models. *Electronic Letters on Science and Engineering*, 17(2): 126-140.
- Yong, A., Sun, C., & Jun, T. (2020). Research on recognition model of crop diseases and insect pests based on deep learning in harsh environments. *IEEE Access*, 8, 171686-171693. <https://doi.org/10.1109/ACCESS.2020.3025325>
- Yuan, Z., Li, S., Peng, R., Leybourne, D., Yang, P., & Li, Y. (2023). PestDSS: An integrated decision support system for sustainable pest management in agriculture. *2023 IEEE 32nd International Symposium on Industrial Electronics (ISIE)*, 1-6. DOI: 10.1109/ISIE51358.2023.10228070
- Yuan, Z., Li, S., Yang, P., & Li, Y. (2022). Lightweight object detection model with data augmentation for tiny pest detection. *2022 IEEE 20th International Conference on Industrial Informatics (INDIN)*, 233-238. DOI: 10.1109/INDIN51773.2022.9976137
- Yue, X., Qi, K., Na, X., Zhang, Y., Liu, Y., & Liu, C. (2023). Improved YOLOv8-Seg network for instance segmentation of healthy and diseased tomato plants in the growth stage. *Agriculture*.
- Yule, S., Htain, N., Oo, A., Sotelo-Cardona, P., & Srinivasan, R. (2021). Occurrence of the south american tomato leaf miner, *Tuta absoluta* (Meyrick) in southern Shan, Myanmar. *Insects*, 12(11): 962. <https://doi.org/10.3390/insects12110962>
- Zehnder, G., & Trumble, J. (1984). Host selection of *Liriomyza* species (Diptera: Agromyzidae) and associated parasites in adjacent plantings of tomato and celery. *Environmental Entomology*, 13(2): 492-496. <https://doi.org/10.1093/ee/13.2.492>
- Zhang, G., Xian, X., Zhang, Y., Liu, W., Liu, H., Feng, X., Dai, A. (2021). Outbreak of the south american tomato leafminer, *Tuta absoluta*, in the chinese mainland: geographic and potential host range expansion. *Pest Management Science*, 77(12): 5475-5488. <https://doi.org/10.1002/ps.6588>
- Zhang, J., Yin, H., Zhou, L., Gu, C., Qiu, W., Lv, X., Sun, H., Yu, H., & Zhang, Z. (2023b). Variable rate air-assisted spray based on real-time disease spot identification. *Pest Management Science*, 79(1): 402-414. <https://doi.org/10.1002/ps.7209>
- Zhang, L., Ding, G., Li, C., & Li, D. (2023a). DCF-Yolov8: an improved algorithm for aggregating low-level features to detect agricultural pests and diseases. *Agronomy*, 13(8), 2012. <https://doi.org/10.3390/agronomy13082012>
- Zhang, N., Wang, M., & Wang, N. (2002). Precision agriculture—a worldwide overview. *Computers and Electronics in Agriculture*, 36(2-3): 113-132.
- Zhang, S., Huang, W., Wang, Z., & Wang, H. (2022). U-segnet with parallel pooling attention for crop pest detection. <https://doi.org/10.21203/rs.3.rs-2258534/v1>
- Zhang, S., Zhang, C., Park, D., & Yoon, S. (2023). Editorial: Machine learning and artificial intelligence for smart agriculture, volume II. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1166209>

- Zhang, W., Huang, H., Sun, Y., & Wu, X. (2022). Agripest-YOLO: A rapid light-trap agricultural pest detection method based on deep learning. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1079384>
- Zhang, W., Xia, X., Zhou, G., Du, J., Chen, T., Zhang, Z., & Ma, X. (2022). Research on the identification and detection of field pests in the complex background based on the rotation detection algorithm. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1011499>
- Zhavoronkov, A. (2022). Rapamycin in the context of Pascal's wager: Generative pre-trained transformer perspective. *Oncoscience*, 9, 82-84. <https://doi.org/10.18632/oncoscience.571>
- Zhu, F., Poelman, E., & Dicke, M. (2014). Insect herbivore-associated organisms affect plant responses to herbivory. *New Phytologist*, 204(2): 315-321. <https://doi.org/10.1111/nph.12886>
- Zu, L., Zhao, Y.-P., Liu, J., Su, F., Zhang, Y., & Liu, P. (2021). Detection and segmentation of mature green tomatoes based on Mask R-CNN with automatic image acquisition approach. *Sensors (Basel, Switzerland)*, 21(23): 7842. <https://doi.org/10.3390/s21237842>