

Domates Meyvesinde Bazı Hastalıkların YOLOv8 Derin Öğrenme Algoritması ile Tespit Edilmesi

Detection of Some Diseases in Tomato Fruit Using the YOLOv8 Deep Learning Algorithm

Mesut Yaşar^{1,*}  Nurhayat Yurtaslan¹ 

¹Varaka Kağıt Sanayi A.Ş., Balıkesir, Türkiye

* Corresponding author (Sorumlu Yazar): M. Yaşar, e-mail (e-posta): yasarmesut10@gmail.com

Makale Bilgisi

Alınış tarihi : 09.12.2024
Düzeltilme tarihi : 07.02.2025
Kabul tarihi : 09.02.2025

Anahtar Kelimeler:

Tarım Makineleri
YOLO Algoritması
Bitki Sağlığı İzleme
Derin Öğrenme

Atf için:

Yaşar, M., Yurtaslan, N. (2025). "Domates Meyvesinde Bazı Hastalıkların YOLOv8 Derin Öğrenme Algoritması ile Tespit Edilmesi", *Journal of Agricultural Machinery Science*, 21(1): 18-35.

ÖZET

Tarım sektörü, artan dünya nüfusu ve çevresel faktörler nedeniyle sürdürülebilir üretim ve verimlilik artırma konusunda önemli zorluklarla karşı karşıyadır. Artan nüfus, bitki hastalıkları ve verim kayıplarıyla mücadele etmeyi zorlaştırmaktadır. Bitki hastalıkları zamanında tespit edilmezse hızla yayılıp büyük kayıplara yol açabilmektedir. Erken tespit, müdahale ve çevresel zararları engellemeyi sağlar, tedavi maliyetlerini düşürür. Geleneksel yöntemler zaman alıcı ve verimsizken, yapay zeka ve derin öğrenme tabanlı algoritmalar daha hızlı ve doğru tespit imkanı sunar. Doğru zamanlamada yapılan müdahale, verimliliği artırır ve sürdürülebilir tarımı destekler. Bu makale, YOLOv8 algoritmasının domates meyvesi hastalıklarını tespit etme uygulamaları ve tarımda sürdürülebilirliği nasıl destekleyeceğini incelemektedir. YOLOv8, hastalıklar, zararlılar ve stres belirtilerini hızlı ve doğru bir şekilde tespit edebilen bir modeldir. Makale kapsamında iki çalışma gerçekleştirilmiş olup, ilk çalışmadaki eksikliklerin nedenleri belirlenerek, ikinci çalışmada yapılan iyileştirmelerle modelin performansı önemli ölçüde artırılmıştır. Precision değeri 0.93, Recall değeri 0.90 ve F1-Score yüksek seviyelere ulaşmıştır. Bu başarı, eğitim sürecinde epoch sayısının 50 ile sınırlandırılması, veri augmentasyonlarının optimize edilmesi ve domateslerin olgunluk seviyelerinin eğitim verisine eklenmesiyle sağlanmıştır. Sonuç olarak, yapılan iyileştirmeler sayesinde YOLOv8, tarım sektöründe hastalık tespiti ve erken müdahale için güvenilir bir araç olarak kullanılabilir hale gelmiştir. Bu iyileştirmeler, verim kaybını azaltarak tarımsal üretimde önemli katkılar sunmaktadır.

Article Info

Received date : 09.12.2024
Revised date : 07.02.2025
Accepted date : 09.02.2025

Keywords:

Agricultural Machinery
YOLO Algorithm
Plant Health Monitoring
Deep Learning

How to Cite:

Yaşar, M., Yurtaslan, N. (2025). "Domates Meyvesinde Bazı Hastalıkların YOLOv8 Derin Öğrenme Algoritması ile Tespit Edilmesi", *Journal of Agricultural Machinery Science*, 21(1): 18-35.

ABSTRACT

The agricultural sector faces significant challenges in achieving sustainable production and increasing productivity due to the growing global population and environmental factors. The increasing population, along with plant diseases and yield losses, complicates management efforts. If plant diseases are not detected in a timely manner, they can spread rapidly, leading to substantial losses. Early detection, intervention, and prevention of environmental damage are crucial, as they reduce treatment costs. Traditional methods are time-consuming and inefficient, whereas artificial intelligence and deep learning-based algorithms offer faster and more accurate detection capabilities. Interventions made at the right time improve productivity and support sustainable agriculture. This paper examines the application of the YOLOv8 algorithm in detecting tomato fruit diseases and its potential contribution to sustainability in agriculture. YOLOv8 is a model capable of detecting diseases, pests, and stress symptoms quickly and accurately. Two studies were conducted in this paper, and the causes of the shortcomings in the first study were identified, leading to significant improvements in the second study that enhanced the model's performance. The precision reached 0.93, recall was 0.90, and the F1-score achieved high levels. This success was achieved by limiting the number of epochs to 50 during training, optimizing data augmentations, and including the ripeness stages of tomatoes in the training data. In conclusion, with the improvements made, YOLOv8 has become a reliable tool for disease detection and early intervention in the agricultural sector. These enhancements significantly contribute to reducing yield losses and offer substantial benefits to agricultural production.

1. GİRİŞ

Tarım sektörü, dünya genelindeki gıda üretimi, kırsal kalkınma ve çevre yönetimi açısından kritik bir öneme sahiptir. Artan nüfus ve iklim değişikliklerinin etkisiyle tarımsal verimliliği sürdürülebilir şekilde artırmak giderek zorlaşmaktadır. Geleneksel tarım yöntemleri, yüksek iş gücü ve maliyet gereksinimlerinin yanı sıra çevresel etkilere yol açmakta olup, bu da üreticileri çeşitli zorluklarla karşı karşıya bırakmaktadır (Liu vd., 2021). Tarımı destekleyen verimli teknolojiler, kaynakları doğru bir şekilde yönetmeye yardımcı olur. Yapay zeka ve derin öğrenme tabanlı sistemler, tarım makinelerinin çevresel verileri daha doğru bir şekilde analiz etmelerini sağlayarak, su, gübre ve ilaç kullanımını optimize eder (Basso vd., 2020). Bu bağlamda, Akıllı Tarım uygulamalarının, teknoloji ile tarım alanında devrim yaratma potansiyeline sahip olduğu vurgulanmaktadır. Akıllı Tarım, özünde doğru zamanda, doğru yere, doğru miktarda tarımsal girdi uygulamasını amaçlayan bir anlayıştır. Bu yaklaşım, her ne kadar modern teknolojilerle ilişkilendirilse de, geleneksel tarım ekipmanlarıyla da uygulanabilir. Ancak, bilgisayarlar, yazılımlar, algılayıcılar, konum belirleme ve Coğrafi Bilgi Sistemleri (CBS) gibi yeni teknolojilerin entegrasyonu ile yapılan uygulamalarda bu sistemler Akıllı Tarım Teknolojileri ya da Hassas Tarım Teknolojileri olarak adlandırılmaktadır.

Tarımsal üretimde kalite ve verimliliği artırmak, maliyetleri düşürmek için yüksek doğrulukla çalışan otonom sistemlerin kullanımı gereklidir (Dulkadir ve Gültekin, 2023). Özellikle derin öğrenme tabanlı yöntemlerin kullanımı, tarım makinelerinin verimliliğini artırırken çevresel etkileri azaltmak adına güçlü bir araç sunmaktadır. Geleneksel tarım yöntemleri, çevresel etkilerinin yanı sıra yüksek iş gücü gereksinimi ve maliyetlerle de üreticileri zorlamakta olup, bu durum verimlilik açısından büyük sorunlar yaratmaktadır. Bu noktada, Akıllı Tarım uygulamaları, algılayıcılar ve yapay zeka gibi modern teknolojilerin entegrasyonu ile tarımsal verimliliği artırmayı ve çevresel etkileri azaltmayı hedeflemektedir. Akıllı Tarım uygulamaları, bitki sağlığı izleme, sulama optimizasyonu ve yabancı ot kontrolü gibi alanlarda büyük faydalar sağlamaktadır. Özellikle YOLO (You Only Look Once) algoritması, tarım makinelerinin bitkilerdeki hastalıkları tespit etmesini sağlayarak, kimyasal ilaç kullanımını minimize ederek çevre dostu bir çözüm sunmaktadır (Pretty vd., 2018). YOLO, nesneleri tanımlamak ve sınıflandırmak için tek bir işlem adımı kullanan bir algoritmadır. Görüntüler, bir ağ aracılığıyla işlenerek nesneler hızlıca tespit edilir ve her bir nesnenin etrafına sınırlayıcı kutular yerleştirilir (Redmon vd., 2016). Bu özellik, YOLO'yu gerçek zamanlı uygulamalar için son derece uygun hale getirir. Tarımda, yüksek çözünürlüklü kameralarla elde edilen görsellerin işlenmesinde YOLO'nun sunduğu hız ve doğruluk, tarım makinelerinin etkin bir şekilde çalışmasına olanak tanır.

Sürdürülebilir tarım, doğal kaynakların korunması, olumsuz çevresel etkilerin azaltılması ve verimliliğin artırılması açısından büyük önem taşımaktadır. Teknolojik yenilikler, tarımsal uygulamaların etkinliğini artırarak, verimlilik ile çevresel koruma arasındaki dengeyi kurmaktadır. Derin öğrenme tabanlı algoritmalar, tarım makinelerinin daha verimli ve çevre dostu bir şekilde çalışmasını sağlamaktadır. Bu nedenle, güncel algoritma tabanlı teknolojilerin tarımda daha yaygın bir şekilde kullanılmasının, çevresel ve ekonomik sürdürülebilirliği sağlamada önemli bir adım olduğu söylenebilir.

Akıllı Tarım teknolojileri, verimlilik ve olumsuz çevresel etkilerin azaltılması açısından büyük bir potansiyel taşımaktadır. Derin öğrenme ve özellikle YOLO algoritmasının tarım makinelerindeki uygulamaları, tarım sektöründe önemli bir dönüşüm sağlamaktadır. Bu dijital teknolojilerin yaygınlaşması, tarımda üretim verimliliğini artırmaya yardımcı olmaktadır. Bitki sağlığı izleme, tarımda

verimliliği artırmak için temel bir gerekliliktir. Bitkilerdeki hastalıklar, zararlılar ve stres durumları genellikle görsel belirtiler göstermeden önce yayılmaktadır. Tarımda erken tespit ve müdahale, hastalıkların yayılmasını önleyebilir ve verim kayıplarını engelleyebilir (Sharma vd., 2020). Ancak, geleneksel yöntemlerle bitki sağlığını izlemek zaman alıcı ve maliyetli olabilmektedir. Ayrıca, çok geniş alanlarda bu tür işlemleri manuel olarak yapmak neredeyse imkansızdır (Zimdahl, 2018). Akıllı Tarım (Hassas Tarım) sistemleri, bu tür sorunlara çözüm sunarak, tarımda daha verimli ve sürdürülebilir bir üretim sağlanmasına yardımcı olmaktadır.

Domates, dünya çapında yaygın olarak yetiştirilen ve ekonomik değeri yüksek bir tarım ürünüdür. Ancak, domates yetiştiriciliği, bitki sağlığına yönelik birçok zorlukla karşı karşıyadır. Domates bitkileri, fungal ve bakteriyel hastalıklar, zararlılar ve çevresel değişkenliklere duyarlıdır (Liu vd., 2021). Bu nedenle, domates bitkilerinin sağlığının izlenmesi ve erken tedavi yöntemlerinin uygulanması, hem verimliliğin artırılması hem de olumsuz çevresel etkilerin en aza indirilmesi açısından oldukça önemlidir.

Geleneksel bitki sağlığı izleme yöntemleri, görsel gözlemler ve laboratuvar testleri gibi süreçlere dayanır (Pretty vd., 2018). Ancak bu yöntemler zaman alıcı, iş gücü yoğun ve genellikle doğruluğu sınırlıdır. Ayrıca, büyük alanlarda yapılan geleneksel izleme işlemleri, her bitkiyi izlemek için büyük iş gücü, ekipman, ulaşım ve zaman gerektirir. Bu süreç, uzman gözlemleri ve manuel veri toplama gibi kaynakları içerir, bu da yüksek maliyetlere yol açar.

Bu durum, özellikle büyük çapta domates üretimi yapan çiftçiler için büyük bir zorluk oluşturur. Bu nedenle, bitki sağlığı izleme sürecinin daha hızlı, doğru ve verimli hale getirilmesi için teknolojinin kullanımı büyük bir gereklilik halini almıştır (Kamilaris ve Prenafeta-Boldú, 2018).

Bitki sağlığı izleme, tarımda önemli bir alan olup, özellikle domates gibi hassas ürünlerde sağlıklı ve verimli üretimin sürdürülebilirliğini sağlamak için kritik rol oynamaktadır. Geleneksel yöntemlerin yetersiz kaldığı bu alanda, YOLO gibi derin öğrenme tabanlı algoritmalar büyük bir potansiyele sahiptir ve bu nedenle çalışmada performansı değerlendirilecektir. Bu tür teknolojiler, tarımda verimliliği artırmanın yanı sıra, olumsuz çevresel etkileri azaltır (Kamilaris ve Prenafeta-Boldú, 2018).

Derin öğrenme ve yapay zeka tabanlı algoritmalar, tarımda verimlilik ve sürdürülebilirliği artırmada önemli bir rol oynamaktadır. Bu teknolojiler, tarım makinelerinin verimli çalışmasını sağlayarak, tarla alanlarındaki hastalıklar, zararlılar ve stres belirtilerinin hızlı bir şekilde tespit edilmesine olanak tanımaktadır. Özellikle YOLO algoritması, gerçek zamanlı nesne tespiti yapabilme yeteneği sayesinde bitki sağlığı izleme ve yabancı ot kontrolü gibi kritik görevlerin etkin bir şekilde yerine getirilmesini mümkün kılmaktadır. YOLO algoritması, tarım makinelerinin geniş alanlarda hastalıkları, zararlıları ve stres belirtilerini hızlıca tespit etmelerini sağlayarak, erken müdahaleyi mümkün kılmakta ve çevresel etkilerin azaltılmasına katkı sağlamaktadır (Redmon vd., 2016). YOLO, tarım makineleri için büyük bir fırsat sunmaktadır. Örneğin, IHA'lar veya tarım robotları, tarla üzerinde gezerek bitkileri izleyebilir ve hastalıkları tespit edebilir. Ayrıca, yabancı otlar veya zararlılar gibi hedeflere yönelik özel ilaçlama yaparak çevreye zarar vermeden tarımsal üretimi destekler (Zhao vd., 2020).

YOLO algoritması, domates meyvesinde hastalıklarının erken dönemde tespit edilmesini sağlayarak, çiftçilerin hastalığın yayılmadan önce müdahale etmelerine olanak tanır. Ayrıca, bu teknoloji, yalnızca hasta veya zararlı etkiler altındaki bölgeleri tespit ederek, tedavi uygulamalarının daha hedeflenmiş ve verimli bir şekilde yapılmasını sağlar (Pretty vd., 2018). Otonom tarım makineleri, doğal kaynakların daha verimli kullanılmasını ve çevresel etkilerin azaltılmasını sağlar. Bu dönüşüm, verimliliği artırırken çevresel sürdürülebilirliği de destekler (Kamilaris ve Prenafeta-Boldú, 2018).

2. MATERYAL VE YÖNTEM

2.1. YOLO Algoritması

YOLO, bir nesne tespiti algoritmasıdır ve CNN (Konvolüsyonel Sinir Ağı) kullanarak çalışır. Bu algoritma, veriye yalnızca bir kez bakarak nesneleri tespit etme yeteneğine sahiptir (Kıvrak ve Gürbüz, 2022). Bu çalışmada, YOLOv8 modelleri kullanılarak nesne tespiti yapılmıştır. Domates meyvelerinin görüntülerinden oluşturulmuş özel bir veri setinde, bu modellerin başarıları analiz edilmiştir.

YOLO, nesneleri analiz etmek ve tahmin etmek yerine regresyon temelli bir yaklaşım kullanır. Yani, görüntüdeki belirli nesneleri tanımlamak yerine, algoritma tüm görüntüyü analiz eder ve kategorileri ile bu nesnelerin çevresini saran kutuları tahmin eder. Model çalıştırıldığında, bu algoritma, görüntülerdeki ya da videolardaki nesneleri ve bu nesnelerin koordinatlarını aynı anda tespit eder.

YOLO algoritması, görüntüyü öncelikle küçük parçalara böler. Bu parçalarda yer alan nesneleri tespit etmek için çevrelere kutular çizer ve her bir parçada bulunan nesnenin olasılığını hesaplar. Ayrıca, her nesne için bir güven skoru belirler. Bu skor, nesnenin doğru tahmin edilme olasılığını yüzde olarak ifade eder ve tahminin doğruluğu hakkında bilgi verir (Kıvrak ve Gürbüz, 2022). Bu sürecin uygulanabilmesi için bazı ön adımların gerçekleştirilmesi gerekmektedir. İlk olarak, her bir alan için özel bir tahmin vektörü oluşturulur ve bu vektörler güven skoru içerir. Güven skoru sıfır olduğunda, o bölgede nesne bulunmadığı kabul edilir; bir olduğu takdirde ise nesne mevcut demektir. Aynı nesne, birden fazla kutu içerisinde yer alabilir. Bu tür sorunları ortadan kaldırmak amacıyla Non-Maximum Suppression (NMS) adı verilen bir yöntem kullanılır. Bu yöntem, en yüksek güven skoruna sahip olan kutuyu seçip diğerlerini iptal eder. Tüm bu işlemler tamamlandıktan sonra, doğruluk değeri hesaplanır ve nihai sonuç elde edilir.

2.2. YOLO'nun Tarımda Hastalık Tespitinde Etkin Kullanımı

YOLO algoritması, gerçek zamanlı nesne tespiti için kullanılan derin öğrenme tabanlı bir tekniktir. YOLO, yüksek çözünürlüklü kameralarla çekilen görselleri analiz ederek, bitkilerdeki hastalıkların, zararlılarının ve stres belirtilerinin yerini hızlı bir şekilde tespit edebilir (Redmon vd., 2016). Bitkilerdeki hastalıklar genellikle görsel işaretlerle kendini gösterdiği için, bu tür görselleri YOLO ile analiz etmek, daha doğru ve hızlı sonuçlar sağlar. Hastalık tespiti konusunda YOLO'nun sağladığı avantajlardan biri, modelin sürekli öğrenme yeteneği sayesinde çeşitli bitki türleri ve hastalıklarla ilgili geniş bir veri kümesi üzerinde eğitilebilmesidir. Bu sayede, farklı coğrafi bölgelerde ve iklim koşullarında tarım yapılan alanlarda da yüksek doğrulukla hastalık tespiti yapılabilmektedir. YOLO'nun eğitiminde kullanılan büyük veri setleri, modelin farklı hastalıkları tanıma ve doğru bir şekilde sınıflandırma yeteneğini artırmaktadır.

Ayrıca, YOLO ile hastalık tespiti, manuel gözlemlerle karşılaştırıldığında önemli bir zaman tasarrufu sağlar. Bu algoritma, gerçek zamanlı görüntü analizi yapabilme yeteneği ile tespit edilen hastalıkların hızlı bir şekilde haritalanmasını sağlar ve çiftçilerin daha hızlı bir şekilde müdahale etmelerini mümkün kılar. Bu, özellikle büyük tarım arazilerinde zaman açısından kritik bir avantaj sağlar.

YOLO algoritması, bitki hastalıklarının tespiti dışında, tarım sektöründe hastalık haritalarının oluşturulması ve reçete esaslı uygulama teknolojilerinde önemli bir rol oynayabilir. Örneğin, tespit edilen hastalık verilerinin coğrafi bilgi sistemleri (GIS) ile entegre edilmesi, tarla bazlı hastalık yoğunluk haritalarının oluşturulmasını mümkün kılar. Bu haritalar, sadece hastalıkların yerini tespit etmekle kalmaz, aynı zamanda hastalığın yayılım dinamiklerini analiz etmeye de olanak sağlar. Ayrıca, algoritmanın konumlama sistemleriyle entegre edilmesi, ilaçlama makineleri gibi tarım ekipmanlarının

hastalık odaklı bölgelere özel müdahale yapmasını sağlar. Bu tür reçete esaslı uygulamalar, gereksiz ilaç kullanımını azaltarak çevresel etkileri en aza indirirken, kaynak tasarrufu ve maliyet düşüşü gibi önemli avantajlar sunar. Böylelikle, YOLO algoritmasının potansiyeli yalnızca hastalık tespitiyle sınırlı kalmaz; tarımda sürdürülebilir bir üretim modeline katkıda bulunacak kapsamlı bir teknoloji olarak değerlendirilebilir.

YOLO algoritması, bitki hastalıklarını tespit etmede yüksek doğruluk oranları, hız ve verimlilik sunan bir araç olarak tarım sektöründe büyük bir potansiyele sahiptir. Tarım makinelerinin bu algoritma ile entegrasyonu, hastalıkların daha hızlı tespiti ve etkili müdahaleyi mümkün kılarken, çevresel etkilerin azaltılmasına ve maliyetlerin düşürülmesine katkı sağlar.

3. METODOLOJİ

3.1. Veri Seti

Bu çalışmada, birbirinden farklı ve 3 farklı hastalık tipi (*Clavibacter michiganensis*, *Pseudomonas syringae* pv. tomato, *Phytophthora infestans*) için YOLO veri tabanında bulunan açık kaynaklı veri setlerinden ve internet üzerinde bulunan açık kaynaklı görsellerle elde edilen yeni bir veri seti bu çalışma için oluşturulmuştur. Seçilen ve bu çalışma için oluşturulan 650 domates görseli kullanılmıştır. Veri seti, 200 *Clavibacter michiganensis*, 200 *Pseudomonas syringae* pv. tomato, 250 *Phytophthora infestans* adet hastalıklı domates görsellerinden oluşturulmuştur. Bu veri setinden 350 adet test görseli seçilmiş olup, bu görsel sayısı 100 *Clavibacter michiganensis*, 100 *Pseudomonas syringae* pv. tomato, 150 *Phytophthora infestans* adet olacak şekilde seçilmiştir.

Bir ana kitleyi doğru şekilde temsil eden örneklem sayısını belirlemek için, örneklem büyüklüğü hesaplaması yapmak gereklidir. Bu, genellikle **örnekleme hatası**, **güven aralığı** ve **kitledeki varyans** gibi faktörlere bağlıdır.

Ana kitleyi temsil eden örneklem sayısını hesaplamak için kullanılan formül aşağıdaki gibidir:

$$n = \frac{N * Z^2 * p * (1 - p)}{E^2 * (N - 1) + Z^2 * p * (1 - p)}$$

- **n** = Örneklem büyüklüğü
- **N** = Ana kitle büyüklüğü (650)
- **Z** = Z-değeri (güven aralığına bağlı, örneğin %95 güven aralığı için Z=1.96)
- **p** = Kitledeki tahmin edilen oran (örneğin, 0.5 en temkinli tahmindir, çünkü bu oran en büyük örneklem büyüklüğünü gerektirir)
- **E** = Örnekleme hatası (genellikle 0.05, yani %5 kabul edilir)(Baş, 2013).

Adım Adım Hesaplama

Varsayalım:


- **N** = 650 (ana kitle büyüklüğü)
- **Z** = 1.96 (güven aralığı %95 için)
- **p** = 0.5 (en büyük örneklem büyüklüğü için)
- **E** = 0.05 (örnekleme hatası)

Formülü yerine koyarsak:

$$n = \frac{650 * (1,96)^2 * 0,5 * (1 - 0,5)}{(0,05)^2 * (650 - 1) + (1,96)^2 * 0,5 * (1 - 0,05)}$$

n=243 olarak bulunmuştur.

Yani, bu hesaplama göre **yaklaşık 243 örneklem** almamız, 650'lik ana kitleyi doğru şekilde temsil edecektir. Ancak hedef kitledeki sayısı fazlalığı sebebiyle örneklemin bütünü temsil etme kabiliyetinin artırılması amaçlanarak “Gayeli Örneklem Yöntemi” uygulanarak 243 olan görsel sayısı 350'ye çıkarılarak çalışma gerçekleştirilmiş ve 100 *Clavibacter michiganensis*, 100 *Pseudomonas syringae* pv. tomato, 150 *Phytophthora infestans* adet olacak şekilde seçilmiştir. Veri seti, görsellerin farklı renk, boyut ve olgunluk seviyelerindeki domateslerden oluşacak şekilde çeşitlendirilmiş olup, hastalıkların belirtileri farklı olgunluk seviyelerindeki domateslerde değişiklik gösterebilir. Ayrıca, görsellerin farklı ışık koşulları ve çözünürlüklerde olması, modelin hastalıkları doğru şekilde tespit etme yeteneği üzerinde etkili olabilir. Bu çeşitlilik, modelin doğruluğunu artırmak için önemli bir fırsat sunarken, aynı zamanda modelin zorluklarla karşılaşmasına da neden olabilmektedir. Veri seti, Roboflow sitesi üzerinden anotasyonlanma işlemi yapılmış olup, çeşitli veri arttırma teknikleri uygulanarak 700 görsel çıkarılmıştır. Veri seti içerisinde anotasyon yapılmış birkaç görsel Şekil 1’de gösterilmiştir.



Şekil 1. Veri setinden anotasyonlama yapılmış görsellerden örnekler

Bu çeşitlendirilmiş veri seti, farklı domates türlerinin, olgunluk seviyelerinin ve görsel koşullarının modelin öğrenme süreci üzerinde etkili olmasına sebep olabilmektedir. Özellikle, farklı olgunluk seviyeleri ve renklerdeki domatesler, hastalıkların belirtilerinin farklı şekillerde ortaya çıkmasına yol açmaktadır. Bu da modelin doğruluğunu artırmak için veri setinin daha da genişletilmesi gerektiğine işaret edebilir.

Veri seti, modelin genel performansının doğru bir şekilde değerlendirebilmesi için eğitim (train), geçerlilik (validation) ve test setleri olmak üzere üç ana bölüme ayrılmıştır. Bu bölme işlemi, modelin her aşamada farklı amaçlar için değerlendirilmesine olanak tanımaktadır. Eğitim seti, toplam verilerin %88'ini (616 görsel) oluşturarak modelin temel öğrenme sürecini desteklemiştir. Geçerlilik seti, verilerin %8'ini (56 görsel) kapsayacak şekilde ayrılmış ve modelin hiperparametre ayarlarının optimize edilmesi için kullanılmıştır. Test seti ise %4'lük (28 görsel) bir oranda belirlenmiş ve nihai modelin genel performansını tarafsız bir şekilde değerlendirmek amacıyla kullanılmıştır. Bu oranlar, veri setinin yeterli büyüklükteki bir kısmının öğrenme sürecine ayrılmasını sağlarken, modelin

genelleme yeteneğini ve gerçek dünya uygulamalarına uygunluğunu ölçmek için dikkatlice seçilmiştir. Genellikle modelin genel doğruluğunu değerlendirmek ve öğrenme sürecinde doğru dengeleme sağlamak için yaygın olarak kullanılan değerlerdir (Bishop, 2006). Eğitim setinin daha büyük, test ve geçerlilik setlerinin daha küçük olması tercih edilir. Bu oranlar da eğitim sırasında modelin iyi performans gösterip göstermediğini izlemek ve en son değerlendirme için yeterli veriye sahip olmak için optimize edilmiştir.

Görsel boyutları Yolo algoritmasında kullanılması için 640x640 piksel olarak sabitlenmiş ve piksel değeri 0 ile 1 arasında normalize edilmiştir.

3.1.1. Metodoloji için ön işlem adımları

Modelin eğitimine başlamadan önce, görüntüler üzerinde çeşitli ön işleme adımları uygulanmıştır. Bu adımlar, modelin öğrenme sürecini optimize etmek ve doğruluk oranını arttırmak amacıyla gerçekleştirilmiştir.

Modelin görselleri üzerinde yapılan ön işleme adımları, modelin daha verimli ve doğru bir şekilde öğrenebilmesi için kritik öneme sahiptir. İlk olarak, görsellerdeki oryantasyon hataları otomatik yönlendirme (Auto-Orientation) yöntemiyle düzeltilmiştir. Görsellerin doğru bir şekilde analiz edilebilmesi için her bir görselin doğru oryantasyona getirilmesi sağlanmıştır. Bu işlem, görsellerin model tarafından tutarlı bir şekilde işlenebilmesi için veri bütünlüğünü artırır. Görseldeki herhangi bir oryantasyon hatası, modelin yanlış öğrenmesine veya düşük doğrulukla tahminlerde bulunmasına neden olabilir. Bu nedenle görselin doğru pozisyonda olması büyük önem taşımaktadır.

Bir diğer önemli adım, görsellerin boyutunun YOLO modelinin giriş boyutlarına uygun şekilde yeniden boyutlandırılmasıdır. Seçilen görseller, 640x640 piksele yeniden boyutlandırılmıştır. Bu işlem, görsellerin YOLO algoritması tarafından daha verimli bir şekilde işlenmesini sağlar. Çünkü modelin giriş boyutlarına uygun olmayan görseller, işlem sürelerini uzatabilir ve modelin doğruluğunu olumsuz yönde etkileyebilir. Boyutlandırma işlemi, modelin daha hızlı ve doğru sonuçlar elde etmesini sağlayarak verimliliği artırır.

Görsellerin kontrastı, modelin görseldeki önemli özellikleri daha iyi tanıyabilmesi amacıyla otomatik olarak ayarlanmıştır. Adaptive Equalization yöntemi kullanılarak yapılan kontrast ayarı, görsellerdeki belirgin detayları vurgular. Bu sayede, modelin ayırt edici özellikleri öğrenme kapasitesi artar. Görsellerdeki düşük kontrastlı alanlar, genellikle modelin doğru sınıflandırma yapmasını zorlaştırabilir. Bu sebeple, kontrastın optimize edilmesi, modelin görseldeki farklı özellikleri daha net bir şekilde öğrenebilmesini sağlar.

Son olarak, görseller gri tonlamaya dönüştürülmüştür (Grayscale). Renk bilgisine olan bağımlılık, modelin analiz sürecini gereksiz yere karmaşıktırabilir. Renkli görüntülerdeki gereksiz bilgilerin modelin doğruluğunu etkilemesini engellemek amacıyla gri tonlama uygulanmıştır. Bu adım, modelin yalnızca yapısal özelliklere odaklanmasını sağlar ve böylece sınıflandırma doğruluğunu artırır. Yapısal özellikler, özellikle nesnelerin şekilleri, kenarları ve dokuları gibi detaylar, modelin doğru sınıflandırma yapabilmesi için kritik rol oynar. Gri tonlama, bu özellikleri daha net bir şekilde öğrenmesine olanak tanır.

3.1.2. Veri augmentasyonu (veri çoğaltma)

Modelin genelleme yeteneğini artırmak ve farklı koşullarda daha iyi performans göstermesini sağlamak amacıyla eğitim verileri üzerinde veri augmentasyonu (veri çoğaltma) işlemi uygulanmıştır. Veri augmentasyonu, eğitim verilerinin çeşitlendirilmesi yoluyla modelin gerçek dünyadaki

değişkenlere karşı daha dayanıklı hale gelmesini sağlayan kritik bir tekniktir. Bu yöntem, modelin eğitim sırasında öğrendiği özelliklerin daha geniş bir yelpazede uygulanabilir olmasını sağlar ve aşırı öğrenme (overfitting) gibi sorunların önüne geçer. Bu bağlamda, eğitim verileri üzerinde çeşitli augmentasyon teknikleri kullanılarak, modelin daha sağlam bir öğrenme süreci geçirmesi hedeflenmiştir.

Görsellerin yatay olarak çevrilmesi (Flip) işlemi gerçekleştirilmiştir. Bu işlem, görsellerdeki nesnelerin yönünü bilinçli olarak değiştirilerek modelin farklı yönlerdeki objeleri tanıma yeteneğini artırmayı hedefler. Flip işlemi, modelin bir nesneyi sadece belirli bir yönden değil, farklı yönlerden de tanıyabilmesini sağlar. Örneğin, bir nesne hem sağa hem de sola dönük olarak görselleştirilmişse, model her iki durumda da nesneyi doğru bir şekilde tanıyabilir.

Flip işlemi, Auto-Orientation yönteminden farklı olarak, veri çeşitliliğini artırmayı amaçlayan bir veri augmentasyon tekniğidir. Auto-Orientation, görsellerdeki oryantasyon hatalarını düzelterek görsellerin doğru bir şekilde hizalanmasını sağlarken; flip işlemi, modelin farklı yönlerden gelen verileri tanıyabilmesi için görsellerin yönünü değiştirme işlemi yapar. Bu iki yöntem birbirini tamamlar: Auto-Orientation veri tutarlılığı sağlarken, flip işlemi veri setinin çeşitliliğini artırır ve modelin genelleme yeteneğini güçlendirir.

Flip işleminin uygulanması, modelin yalnızca belirli bir pozisyondaki nesneleri öğrenmek yerine, farklı yönlerden gelen veriler üzerinde esnekliğini artırmıştır. Bu tür veri augmentasyonları, gerçek dünyadaki çeşitli durumları simüle ederek modelin genel doğruluğunu artırmaya yönelik bir katkı sağlamaktadır.

Renk tonları ve doygunluk (Hue & Saturation) değiştirme, bir diğer önemli augmentasyon tekniğidir. Bu adımda, görsellerin renk tonları ve doygunluğu rastgele değiştirilmiştir. Bu işlem, modelin renk varyasyonlarına karşı duyarlılığını artırır. Renk tonları ve doygunluğun değiştirilmesi, modelin çeşitli ışık koşulları, farklı renk varyasyonları veya görsel ortam koşullarındaki değişikliklere karşı daha dayanıklı olmasını sağlar. Örneğin, bir resmin ışıklandırma koşullarına göre farklı renk tonlarına bürünmesi modelin doğru sınıflandırma yapma yeteneğini engelleyebilir. Bu tür veri augmentasyonları sayesinde model, renk varyasyonlarına rağmen nesneleri daha doğru şekilde tanımayı öğrenir. Bu da gerçek dünya uygulamalarında daha sağlam bir performans gösterilmesine olanak tanır.

Gürültü ekleme (Noise) görsellere rastgele %0.1 oranında piksel gürültüsü eklenmiştir. Bu işlem, modelin gürültülü verilere karşı dayanıklılığını artırır. Gerçek dünya verilerinde çoğu zaman görsellerdeki kalite bozulmuş olabilir, örneğin düşük çözünürlük, bulanıklık ya da bozulmuş pikseller gibi durumlarla karşılaşılabilir. Gürültü ekleme, bu tür koşulları simüle ederek modelin bozulmuş ya da eksik verilere karşı daha güçlü bir performans sergilemesini sağlar. Model, gürültülü verilerle karşılaştığında, bu tür bozulmalara rağmen doğru sınıflandırmalar yapabilme yeteneğini geliştirir. Ayrıca, gürültü ekleme, modelin daha sağlam ve genellenebilir hale gelmesini sağlayarak, eğitim sırasında aşırı öğrenmeye karşı koruyucu bir önlem oluşturur.

Bu veri augmentasyon tekniklerinin uygulanmasının amacı, modelin eğitim sırasında daha geniş bir veri çeşitliliği üzerinde öğrenmesini sağlamaktır. Model, sadece sınırlı sayıda veriyle değil, aynı zamanda veri augmentasyonu ile zenginleştirilmiş çeşitlendirilmiş verilerle de öğrenir. Böylece, modelin hem eğitim sürecinde hem de test aşamasında daha doğru sonuçlar üretmesi sağlanır. Ayrıca, bu teknikler sayesinde modelin farklı koşullar altında daha iyi performans gösterebilmesi, gerçek dünya uygulamalarında karşılaşabileceği çeşitli durumlara uyum sağlamasını kolaylaştırır. Örneğin, farklı ışık koşulları, kamera açıları, renk değişiklikleri ya da veri bozulmalarına karşı modelin dayanıklılığı artar, böylece modelin genelleme yeteneği güçlendirilir. Sonuç olarak, bu augmentasyon teknikleri, modelin

doğruluğunu artırmakla kalmaz, aynı zamanda daha esnek, dayanıklı ve güvenilir bir yapıya kavuşmasını sağlar.

3.1.3. Etiketleme ve model seçimi

Roboflow üzerinden hastalık çeşitlerine uygun etiketleme yapılmıştır. Bu işlem, modelin doğru tahminler yapılabilmesi için kritik ve çok özellikli bir adım olup, verilerin kalite ve doğruluk açısından uygun hale getirilmesi sağlanmıştır. Etiketleme sürecindeki bu özenli çalışma, modelin hastalık belirtilerini etkili bir şekilde modelin öğrenmesine ve yüksek oranda doğrulukla hastalık belirtilerini tespit etmesinde olumlu yönde katkılar sağlamıştır.

3.2. Yöntem

Eğitim işlemi Google Colab ortamında gerçekleştirilmiştir. Google Colab, tarayıcı üzerinden erişilebilen bulut tabanlı bir Jupyter not defteri hizmetidir. Intel CPU'larla donatılmış olup yaklaşık 12 GB RAM kapasitesine sahiptir. Ayrıca derin öğrenme gibi hesaplama yoğun işlemler için NVIDIA Tesla T4, A100, L4 ve TPU v2-8 gibi GPU ve TPU'lardan birini seçme imkanı sunmaktadır. Bu çalışmada NVIDIA Tesla T4 GPU kullanılmıştır (Altun ve Altun, 2024).

YOLOv8, yüksek doğruluk oranı ve hızlı işlem kapasitesi ile birden fazla sınıfı aynı anda hızlı bir şekilde tespit edebilme yeteneğine sahiptir. Bu özellik, özellikle tarım alanında domates hastalıklarının hızlı bir şekilde belirlenmesi açısından önemli bir avantaj sunmaktadır. YOLOv8'in bu özellikleri, modelin gerçek zamanlı nesne tespiti ve sınıflandırma konusunda etkili ve güçlü bir çözüm sunduğunu ortaya koymaktadır.

İki farklı model eğitimi yapılmıştır. Bu çalışmalar YOLOv8 nesne tespiti modelinin önceden eğitilmiş yapısının kullanılmasıyla gerçekleştirilmiştir. Bu süreçler, domates hastalıklarının doğru şekilde tespit edilmesini sağlamak için modellerin doğruluğunu ve güvenilirliğini artırmaya yönelik titizlikle yapılandırılmıştır. Eğitim sürecinde izlenen adımlar, modellerin verimli bir şekilde öğrenebilmesi için ayrıntılı bir şekilde planlanmış ve her aşama dikkatle yürütülmüştür.

İlk modelin eğitiminin ilk adımında, modelin eğitimi Roboflow platformu üzerinden sağlanan etiketli veri seti ile başlatılmıştır. Bu veri setindeki her bir görsel, hastalıkların doğru şekilde etiketlendiği ve modelin etkili bir şekilde öğrenebilmesi için uygun şekilde işlenmiş ve etiketlenmiştir. Görsellerin doğru etiketlenmesi, modelin doğruluğu için kritik bir faktördür, çünkü yanlış etiketlenmiş veriler modelin yanlış öğrenmesine yol açabilir. Eğitim sürecinde, modelin performansını doğrudan etkileyebilecek olan batch size (parti büyüklüğü), epoch sayısı (eğitim döngüsü) ve learning rate (öğrenme oranı) gibi hiperparametreler optimize edilmiştir. Bu ayarlamalar, modelin verimli çalışması ve doğru tahminler yapabilmesi için titizlikle yapılmış ve her parametre için farklı kombinasyonlar denenerek en uygun yapı bulunmuştur.


Modelin konfigürasyonu, YOLOv8'in mevcut ağırlıkları üzerinden özelleştirilmiştir. YOLOv8, hızlı ve doğru nesne tespiti yapabilme kapasitesine sahip bir modeldir ve bu özellikleri domates hastalıklarının tespitinde de büyük avantaj sağlamaktadır. YOLOv8'in yapısı, her bir nesnenin (bu durumda hastalıkların) doğru bir şekilde sınıflandırılması ve her bir hastalığa ait güven skorunun hesaplanabilmesi için yeniden yapılandırılmıştır. Bu yeniden yapılandırma, yalnızca hastalıkları doğru bir şekilde tespit etmekle kalmayıp, aynı zamanda her hastalık türünün model tarafından ne kadar güvenilir bir şekilde tahmin edildiğini gösteren güven skorlarını da hesaplamasına olanak tanımaktadır. Modelin yapılandırılması sırasında, her hastalık türüne özel çıktı katmanları oluşturulmuş ve modelin bu hastalık türlerini tespit etme kapasitesinin artırılması sağlanmıştır. Bu, modelin yalnızca hastalıkları

tespit etme işlemini değil, aynı zamanda her bir hastalığa ait güven düzeyini doğru bir şekilde belirleme işlevini de yerine getirmesini sağlamaktadır.

Eğitim süreci boyunca, modelin doğruluğu sürekli olarak izlenmiş ve her epoch başında kayıp (loss) ve doğruluk (accuracy) gibi metrikler takip edilmiştir. Her eğitim döngüsünün sonunda, modelin tahmin performansı değerlendirildikten sonra, sonuçlar analiz edilmiştir. Modelin doğruluğunda sürekli bir iyileşme gözlemlenmiş ve her epoch'ta modelin tahminleri daha hassas hale gelmiştir. Bu, modelin öğrenme sürecinde ilerlediğini ve zamanla daha doğru tahminler yapabildiğini gösteren bir işarettir.


İlk yapılan çalışmada epoch değeri veri setindeki elemanların falza olması, hastalık çeşitlerinin az olması sebebi ile 100 olarak seçilmiştir. Modelin doğruluk oranının artması, kullanılan eğitim verisinin çeşitliliği, hiperparametre ayarlarının doğru yapılması ve modelin öğrenme sürecindeki etkinliğinin bir sonucudur. Ayrıca, modelin aşırı öğrenme (overfitting) yapmaması için geçerlilik (validation) seti düzenli olarak kullanılmıştır. Geçerlilik seti, eğitim setinden farklı görseller içerdiğinden, modelin eğitim verisiyle fazla özdeşleşmesini engelleyerek genelleme yeteneğini artırmaya yardımcı olmuştur. Bu testler, modelin eğitim verisinden bağımsız olarak ne kadar iyi performans gösterdiğini değerlendirmek için önemli bir araçtır. Aynı zamanda, hiperparametrelerin (örneğin, öğrenme oranı ve batch size) geçerlilik seti üzerinde optimize edilmesi, modelin daha hassas ve doğru sonuçlar üretmesini sağlamıştır.

Eğitim ve geçerlilik süreçlerinin ardından, modelin gerçek dünya koşullarındaki performansını test etmek amacıyla test seti üzerinde denemeler yapılmıştır. Test seti, modelin daha önce görmediği, yeni görselleri içermektedir ve bu görseller, modelin genel performansını değerlendirmek için kritik bir öneme sahiptir. Model, test setindeki görseller üzerinde yapılan tahminlerde yüksek doğruluk oranları elde etmiştir. Bu durum, modelin genelleme yeteneğini ve daha önce görmediği verilerle başa çıkabilme kapasitesini göstermektedir. Bu çıktılar şekil 2’de gösterilmiştir.



Şekil 2. Birinci çalışma sonucu elde edilen çıktı görüntüleri

Modelin test sonuçları, performans açısından bazı geliştirmelere ihtiyaç duyduğunu göstermektedir. Elde edilen çalışmanın test sonuçları Şekil 3'te verilmiştir.



Şekil 3. İkinci modelin test sonuçları

Test sonuçları, modelin tespit ettiği hastalıkları doğru bir şekilde sınıflandırmada bazı zorluklarla karşılaştığını göstermektedir. Precision (Kesinlik) değeri 0.33, modelin tespit ettiği pozitif sınıflandırmaların sadece %33'ünün doğru olduğunu gösteriyor. Bu durum, modelin bazı yanlış pozitif tespitler yaptığı anlamına gelmektedir. Bu tarz hatalar, özellikle modelin sınıflandırma sürecinde daha dikkatli ve özenli iyileştirmeler yapılması gerektiğini göstermektedir. Ancak, bu durumu yalnızca modelin başarısızlığı olarak görmek yerine, kullanılan verilerin çeşitliliği ve kalitesi ile ilişkilendirmek daha doğru olacaktır.

Özellikle domates çeşitliliği ve görsel faktörlerin, modelin doğruluğu üzerinde önemli bir etkisi vardır. Farklı domates çeşitleri, hastalıkların görsel belirtilerini farklı şekilde gösterebilir. Her domates türü, belirli hastalıklara karşı farklı reaksiyonlar verebilir ve bu da modelin hastalıkları tespit etme yeteneğini etkileyebilir. Bu nedenle, modelin doğruluğunu artırmak için farklı domates çeşitlerinin eğitim setine dahil edilmesi, modelin daha genel bir tespit yeteneği kazanmasına olanak tanıyacaktır. Ayrıca, görsel faktörler de büyük bir rol oynamaktadır. Düşük çözünürlüklü ya da farklı ışık koşullarında çekilmiş görseller, modelin doğru sonuçlar vermesini zorlaştırabilir. Bu nedenle, eğitim verisinin yüksek kaliteli, tutarlı ışık koşullarında ve iyi çözünürlükte görsellerle zenginleştirilmesi gerekmektedir.

Diğer bir önemli etken, domatesin olgunlaşma seviyesi ve hastalıkların bu farklı olgunluk seviyelerinde nasıl görüldüğüdür. Olgunlaşmış ve çok olgun domateslerin hastalık belirtileri farklı şekilde gözlemlenebilir. Erken evre hastalıklar, olgunlaşmış domateslerde daha belirgin olabilirken, çok olgun domateslerde belirtiler daha az fark edilebilir veya farklı şekillerde gözlemlenebilir. Bu nedenle, her olgunluk seviyesindeki domatesin eğitim setinde temsil edilmesi önemlidir. Modelin her seviyedeki hastalık belirtilerini doğru şekilde öğrenebilmesi için, bu farklı olgunluk seviyelerini temsil eden görsellerin eğitim veri setine dahil edilmesi faydalı olacaktır.


Bu faktörler göz önünde bulundurulduğunda, modelin doğruluğunu artırmak için yapılması gereken en önemli iyileştirme, veri setinin çeşitlendirilmesi ve zenginleştirilmesidir. Daha fazla domates çeşidi, yüksek kaliteli görseller ve farklı olgunluk seviyelerini temsil eden verilerle modelin eğitilmesi, precision ve recall değerlerini artırabilir. Bu, modelin daha geniş bir hastalık spektrumunu doğru bir şekilde tespit etmesine yardımcı olacaktır. Bu tür verilerle eğitilen bir model, gerçek dünya koşullarında daha etkili ve doğru sonuçlar verecektir.

İlk modelin eğitim çıktılarında hedeflenen değerlerin elde edilememesi, aşırı öğrenme (overfitting) ve veri augmentasyonlarının etkilerinin gözden geçirilmesi gerektiğini ortaya koymuştur. İlk çalışmada, Şekil 2’de de görüldüğü gibi hastalıklı alanların tümünün ayrı ayrı işaretlenmesi, modelin genel özellikler yerine spesifik detaylara aşırı odaklanmasına neden olmuş ve bu durum aşırı öğrenmeye yol açmıştır. Bu hatayı minimize etmek için ikinci çalışmada epochs değeri 50 ile sınırlandırılarak modelin gereğinden fazla öğrenmesi engellenmiştir.

Veri augmentasyonu sürecinde uygulanan renk tonları (Hue) ve doygunluk (Saturation) değişimi, modelin genelleme yeteneğini artırmayı hedeflese de bazı durumlarda doğruluk skorlarının düşmesine neden olmuştur. Örneğin, Hue bileşeninin rastgele değiştirilmesi, hastalık semptomlarının doğal renk karakteristiğini etkileyerek modelin yanlış öğrenmesine yol açmıştır. Bu durum, özellikle bitki hastalıklarının renk tabanlı tanımlandığı veri kümelerinde hassas bir problem yaratabilir. Bunun yerine, aydınlatma koşullarını simüle etmek amacıyla V bileşeni üzerinde rastgele değişim yapılması, modelin performansını artıran daha mantıklı bir yaklaşım olarak öne çıkmıştır.

İkinci çalışmada yapılan bu düzenlemeler sonucunda, modelin genelleme kabiliyeti artmış ve aşırı öğrenme minimize edilmiştir. Ayrıca, renk tonları ve aydınlatma augmentasyonlarının optimize edilmesiyle doğruluk oranı önemli ölçüde iyileşerek 0.8 değerine ulaşmıştır. Bu sonuç, modelin veri augmentasyonu sırasında semptom karakteristiğini koruyan bir yaklaşım benimsediğinde daha başarılı performans sergilediğini göstermektedir.


Şekil 4’te de görülebileceği gibi ikinci modelin çıktılarında domatesin hastalık tespitinde domatesi bir bütün olarak kabul edip, hastalık tespitini daha doğru şekilde yapmıştır.



Şekil 4. İkinci çalışma sonucu elde edilen çıktı görüntüleri

Yapılan çalışmanın çıktı grafikleri de Şekil 5’te görüleceği gibi daha başarılı bir sonuç çıkarmıştır. İkinci çalışma, yapılan optimizasyonlar ve doğru augmentasyon tekniklerinin uygulanması sayesinde modelin performansını önemli ölçüde artırmıştır. Precision değeri **0.93**, Recall değeri **0.90** ve F1-Score

dengeli bir şekilde yüksek seviyelere ulaşmıştır. Ayrıca, mAP50 değeri **0.93** ve mAP50-95 değeri **0.78** olarak hesaplanmıştır. Bu sonuçlar, modelin hem doğru tespit oranını artırdığını hem de farklı IoU eşiklerinde güçlü bir performans sergilediğini göstermektedir. Çalışma, özellikle aşırı öğrenme sorununu minimize ederek ve eğitim süreçlerini optimize ederek modelin genel başarısını büyük ölçüde iyileştirmiştir.



Şekil 5. İkinci modelin test sonuçları

İkinci çalışma, aşırı öğrenmeyi minimize etmek için epoch sayısının sınırlandırılması ve veri augmentasyonu stratejilerinin optimize edilmesiyle başarılı olmuştur. Özellikle, Hue değişimlerinin sınırlandırılması ve aydınlatma koşullarını simüle eden V bileşeni değişimlerinin uygulanmasıyla modelin genelleme kabiliyeti artırılmış ve doğruluk oranı 0.8'e ulaşmıştır. Bu sonuçlar, semptom karakteristiğini koruyan yaklaşımların model performansını önemli ölçüde iyileştirdiğini göstermektedir.

4. SONUÇ

Tarımda verimliliği artırmak, çevresel etkileri minimize etmek ve sürdürülebilir üretim yöntemlerini benimsemek, günümüz tarımının en önemli hedefleri arasında yer almaktadır. Geleneksel tarım yöntemleri, yüksek iş gücü ve maliyet gereksinimlerinin yanı sıra çevreye zarar verebilecek uygulamalara sahip olup, su tüketimi, aşırı kimyasal gübre kullanımı ve toprak erozyonu gibi olumsuz çevresel etkiler yaratabilir. Bu sorunların çözülmesi, tarımda daha verimli ve çevre dostu çözümler arayışını zorunlu kılmaktadır. Bu noktada, akıllı tarım teknolojileri büyük bir potansiyel sunmaktadır. Bu teknolojiler, üretim süreçlerini daha verimli hale getirmekte ve çevresel etkileri azaltarak sürdürülebilir tarım uygulamalarına katkı sağlamaktadır.

Bu alandaki en önemli yeniliklerden biri, YOLO tabanlı derin öğrenme yöntemlerinin tarım sektörüne entegrasyonudur. YOLO algoritması, yüksek hızda ve yüksek doğrulukla gerçek zamanlı nesne tespiti yapabilme kapasitesine sahip olup, tarım makinelerinin bitki sağlığı izleme, hastalık tespiti, zararlı kontrolü ve yabancı otlarla mücadele gibi kritik görevleri etkin bir şekilde yerine getirmesini sağlar. Bu özellik, geleneksel tarım yöntemlerinin sınırlamalarını ortadan kaldırarak, çok daha hızlı, verimli ve çevre dostu üretim süreçlerinin önünü açmaktadır. YOLO, yalnızca hastalık ve zararlıları

tespit etmekle kalmaz, aynı zamanda bu sorunların hedeflenmiş bir şekilde çözülmesine olanak tanır; böylece gereksiz kimyasal kullanımını engeller, bu da maliyetlerin düşmesini ve çevresel etkilerin azaltılmasını sağlar.

İlk çalışmada elde edilen sonuçlar, modelin hem Precision (doğruluk) hem de Recall (duyarlılık) açısından sınırlı bir performans sergilediğini ortaya koymaktadır. Precision değeri 0.33 olarak hesaplanmış ve bu, modelin yaptığı tahminlerin önemli bir kısmının yanlış olduğunu göstermektedir. Recall değeri ise 0.50 olarak belirlenmiş ve bu, modelin doğru tespit edebildiği hastalık alanlarının yalnızca yarısına ulaşabildiğini ifade etmektedir. Bu düşük Precision ve Recall değerlerinin bir sonucu olarak, F1-Score da 0.40 ile oldukça düşük bir seviyede kalmıştır. Ayrıca, mAP50 ve mAP50-95 değerlerinin düşük olması, modelin farklı IoU eşiklerinde başarısız olduğunu göstermektedir.

İyileştirilmiş modelde ise, yapılan optimizasyonlar ve doğru augmentasyon stratejilerinin uygulanması sayesinde Precision değeri 0.93'e, Recall değeri 0.90'a yükselmiştir. Bu artışlar, modelin hem yanlış pozitif oranını büyük ölçüde azalttığını hem de daha fazla doğru tespit yaptığını göstermektedir. Bu gelişmeler, F1-Score'u daha dengeli ve güçlü bir performans sergileyerek üst düzey bir seviyeye taşımıştır. Ek olarak, mAP50 değeri 0.93 ve mAP50-95 değeri 0.78 olarak hesaplanmış, bu da modelin farklı IoU eşiklerinde de yüksek performans sergileyebildiğini kanıtlamaktadır. Sonuç olarak, iyileştirilmiş model, doğru yapılandırılmış veri işleme ve eğitim yöntemleri sayesinde gerçek dünya senaryolarında daha güvenilir ve etkili bir çözüm sunmaktadır.

Sonuç olarak, YOLO tabanlı teknolojilerin tarım makinelerine entegrasyonu, tarım sektöründe önemli bir ilerleme kaydedilmesine olanak sağlayacaktır. Bu teknolojiler, yalnızca verimliliği artırmakla kalmayıp, aynı zamanda çevresel etkileri azaltmaya ve sürdürülebilir tarım uygulamalarını teşvik etmeye de büyük katkı sağlayacaktır. Tarımda çevre dostu çözümler sunmak ve üretim süreçlerini daha verimli hale getirmek için bu teknolojilerin yaygın bir şekilde benimsenmesi, sürdürülebilir bir tarım geleceği için önemli bir adımdır.

KAYNAKÇA

- Altun, M. G., & Altun, A. H. (2024). Beton yüzey çatlaklarının YOLOv8 derin öğrenme algoritması ile tespit edilmesi. *Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi*, 39(3), 667-678.
- Basso, B., Cammarano, D., & Li, X. (2020). Application of remote sensing in precision agriculture: A review. *Field Crops Research*, 246, 107697. <https://doi.org/10.1016/j.fcr.2019.107697>
- Baş, T. (2013). *Anket Nasıl Hazırlanır?*. Seçkin Yayıncılık, (7. Baskı), s. 40-44, Ankara.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer, New York, NY, USA.
- Dulkadir, S., & Gültekin, G. K. (2023). Tarımsal otomasyon sistemleri için muz olgunluk seviyelerinin derin öğrenme yöntemleri ile sınıflandırılması. *EMO Bilimsel Dergi*, 13(3).
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). A review of the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture*, 143, 210-226. <https://doi.org/10.1016/j.compag.2017.10.018>
- Kıvrak, O., & Gürbüz, M. Z. (2022). Performance comparison of YOLOv3, YOLOv4, and YOLOv5 algorithms: A case study for poultry recognition. *Avrupa Bilim ve Teknoloji Dergisi*, (38), 392-397. <https://doi.org/10.31590/ejosat.1111288>
- Liu, S., Wang, H., & Li, Y. (2021). A survey on machine learning in precision agriculture. *Computers and Electronics in Agriculture*, 180, 105877. <https://doi.org/10.1016/j.compag.2020.105877>

- Pretty, J., Bharucha, Z. P., & Gorelick, S. M. (2018). Sustainable intensification in agriculture: A review. *International Journal of Agricultural Sustainability*, 16(1), 1-24. <https://doi.org/10.1080/14735903.2017.1414100>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- Sharma, R., Lakhani, R., & Shukla, A. (2020). Plant disease detection using image processing and deep learning. *Journal of King Saud University- Computer and Information Sciences*. <https://doi.org/10.1016/j.jksuci.2020.06.020>
- Zhao, X., Tan, W., & Zhang, X. (2020). A novel method for weed detection in crops based on YOLO deep learning model. *Computers and Electronics in Agriculture*, 175, 105551. <https://doi.org/10.1016/j.compag.2020.105551>
- Zimdahl, R. L. (2018). *Weeds and weed management: A critical review*. Springer. <https://doi.org/10.1007/978-3-319-73293-9>

EXTENDED ABSTRACT

Introduction and Research Questions & Purpose

Agriculture plays a vital role in global food production, rural development, and environmental sustainability. However, population growth and climate change have made sustainable agricultural productivity increasingly challenging. Traditional farming methods are often costly, labor-intensive, and environmentally risky (Liu et al., 2021). In response, smart farming technologies, such as deep learning-based YOLO (You Only Look Once) algorithms, offer efficient and eco-friendly solutions. These technologies enhance agricultural productivity by enabling precise disease detection, reducing chemical usage, and supporting sustainable practices (Dulkadir & Gültekin, 2023; Pretty et al., 2018).

Tomato cultivation, a globally significant crop, faces challenges from diseases and environmental variability. Traditional monitoring methods are labor-intensive and inefficient for large-scale farms (Sharma et al., 2020). The integration of YOLO into agricultural machinery provides a scalable, accurate, and sustainable approach to address these issues.

This study explores the application of the YOLO algorithm in addressing critical challenges in tomato farming, focusing on its potential to improve efficiency and sustainability. The integration of deep learning techniques like YOLO into agricultural practices offers innovative solutions to longstanding issues, including disease detection, resource optimization, and environmental impact reduction. One key goal is to assess the effectiveness of YOLO in detecting plant diseases at early stages. Early detection is crucial for minimizing crop losses and preventing the spread of diseases, particularly in high-value crops like tomatoes. By leveraging YOLO's advanced image analysis capabilities, the study evaluates its accuracy and reliability in identifying disease symptoms before they become widespread.

Another objective is to examine the role of YOLO in reducing the use of chemical treatments, such as pesticides and fungicides. Targeted disease detection enables precise interventions, which not only lowers chemical usage but also mitigates environmental harm. This aligns with sustainable agriculture principles, ensuring farming practices balance productivity with ecological responsibility. Finally, the research investigates the scalability of YOLO for large-scale tomato farming. Traditional monitoring methods often struggle to cover expansive fields efficiently, making them impractical for modern agricultural operations. By integrating YOLO into agricultural machinery, this study demonstrates how the algorithm can enhance disease monitoring across large areas, providing real-time insights and actionable data.

In summary, this research showcases the transformative potential of YOLO in agriculture. By improving disease detection, reducing resource wastage, and enabling scalable solutions, the algorithm contributes to a more efficient, sustainable, and technology-driven approach to farming.

Methodology

The methodology of this study involves integrating the YOLO algorithm for real-time object detection in agricultural applications. High-resolution images of crops, particularly tomatoes, are collected from agricultural fields under various environmental conditions. These images undergo preprocessing steps such as resizing, normalization, and augmentation to ensure consistency and enhance model robustness. The YOLO algorithm, specifically YOLOv8, is employed for its speed and accuracy. The model is trained using annotated images where plant diseases, pests, and weeds are labeled with bounding boxes. A transfer learning approach is utilized to fine-tune a pre-trained model with the agricultural dataset, improving performance and reducing training time.

The model's performance is evaluated through metrics such as precision, recall, F1 score, and mean Average Precision (mAP). After training, the YOLO model is deployed on agricultural robots or drones for real-time testing, where its ability to detect specific plant issues is evaluated. The system's effectiveness in enabling targeted interventions, like selective pesticide application, is assessed. This aims to improve agricultural productivity and minimize environmental impact. This methodology ensures the development of an efficient system for sustainable and precise agricultural practices.

Results and Conclusions

The test results of the second study demonstrate significant improvements in the model's ability to classify diseases accurately. The initial model's performance, with a Precision value of 0.33, was insufficient for reliable disease detection, prompting the need for a second study to address its limitations. The optimized model achieved a much higher accuracy, significantly reducing false positives. This improvement can be attributed to better training strategies and adjustments made to the dataset and augmentations.

In the second study, the inclusion of optimized augmentations and limiting the epochs to 50 helped prevent overfitting, allowing the model to generalize better across diverse disease symptoms. The dataset was refined to include more representative images of tomato diseases, avoiding overemphasis on specific disease characteristics and instead focusing on a holistic understanding of disease patterns.

Additionally, augmentations such as Hue and Saturation adjustments were carefully applied to enhance the model's ability to adapt to varying lighting conditions while preserving the natural characteristics of disease symptoms. These changes minimized distortions in the training data, allowing the model to maintain higher accuracy.

By incorporating images of tomatoes at various ripeness stages and maintaining consistent lighting and resolution, the second study successfully addressed the challenges of the initial model. This led to enhanced classification performance, with a Precision value exceeding 0.90, demonstrating the model's ability to detect diseases more accurately and reliably. These improvements highlight the importance of dataset diversity and augmentation optimization in achieving robust results.

YAZARLARIN BİYOGRAFİSİ



Mesut YAŞAR

Mesut Yaşar, makine imalatı, özellikle tarım makineleri ve iş sağlığı güvenliği alanında kapsamlı bir akademik ve mesleki geçmişe sahiptir. Yüksek lisans eğitimini Aydın Adnan Menderes Üniversitesi Fen Bilimleri Enstitüsü Tarım Makineleri Anabilim Dalı'nda tamamlamıştır. Lisans eğitimini Ege Üniversitesi Ziraat Fakültesi Tarım Makineleri Bölümü'nde tamamlamış, ayrıca Anadolu Üniversitesi İşletme Fakültesi'nde ikinci lisans programını başarıyla bitirmiştir. Hâlen Balıkesir Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği bölümünde lisans öğrenimine devam etmektedir. Farklı sektörlerde kazandığı deneyimlerle Ar-Ge mühendisliği alanında önemli katkılar sunmuştur. Hâlen Varaka Kağıt Sanayi A.Ş.'de Ziraat Mühendisi olarak görev yapmaktadır. Mesut Yaşar; Ar-Ge projeleri, iş sağlığı ve güvenliği, kalite yönetimi, çevre yönetimi ve tarımda iş güvenliği gibi birçok alanda aldığı sertifikalar ve eğitimlerle kendisini geliştirmiştir. KOSGEB, TÜBİTAK, ISO 9001, ISO 14001, ISO 22000 ve OHSAS 18001 gibi önemli sertifikalara sahiptir. Bu niteliklerini üretkenliği artırmak, çevresel etkileri azaltmak ve üretim süreçlerini optimize etmek için kullanmaktadır. Ayrıca mekanik bakım, motosiklet tamiri, kümes hayvancılığı ve tarım makinelerinde iş güvenliği gibi kişisel ilgi alanlarına sahiptir. Boş zamanlarını bu hobilerle değerlendirmenin yanı sıra, tarımda iş güvenliği ve ergonomi konularında makaleler ve yazılar yazarak bu birikimini akademik çalışmalarına da entegre etmektedir.

Adres: Varaka Kağıt Sanayi A.Ş., Balıkesir, Türkiye

İletişim
ORCID Adresi

yasarmesut10@gmail.com
<https://orcid.org/0000-0002-8573-0197>



Nurhayat YURTASLAN

Nurhayat Yurtaslan, yapay zekâ ve mobil uygulamalar üzerine çalışan bir akademisyen ve profesyonel araştırmacıdır. Hâlen Bursa Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine devam etmektedir. Lisans eğitimini Erciyes Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde tamamlamıştır. Sektörel deneyimiyle Ar-Ge mühendisliği alanına katkı sunan Yurtaslan, Varaka Kağıt A.Ş.'de Elektrik-Elektronik Mühendisi olarak görev yapmaktadır. Eğitim hayatı boyunca yürüttüğü projeler ve çalışmalar sayesinde sektörde uygulamalı deneyim kazanmıştır. Yapay zekâ, görüntü işleme, adli bilişim, yazılım geliştirme ve mobil uygulama geliştirme gibi alanlarda geniş bir eğitim ve sertifika yelpazesine sahiptir. Disiplinler arası bilgi birikimiyle Ar-Ge projelerinde yenilikçi çözümler üretmeyi hedeflemektedir. Nurhayat Yurtaslan, akademik ve profesyonel yaşamının yanı sıra kişisel gelişime de önem vermektedir. Kitap okumak, doğa yürüyüşleri yapmak ve sanatsal etkinliklere katılmak hobileri arasındadır. Ayrıca sosyal sorumluluk projelerinde yer alarak topluma katkıda bulunmayı amaçlamaktadır. Boş zamanlarında teknolojiye olan ilgisini artırmak adına yenilikçi projeler üzerinde çalışmaya ve çeşitli platformlarda bilgi paylaşımında bulunmaya devam etmektedir.

İletişim
ORCID Adresi

nurhayat.yurtaslan@varaka.com
<https://orcid.org/0009-0006-5959-6883>