



## Derin Öğrenme Destekli Gerçek Zamanlı Zeytin Tespiti Uygulaması

Erhan KAHYA<sup>1\*</sup>, Yasin ASLAN<sup>2</sup>

<sup>1</sup> Tekirdağ Namık Kemal Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, Kontrol ve Otomasyon Teknolojisi Programı, 59100, Tekirdağ

<sup>2</sup> Freelance Senior Software Developer, 59100, Tekirdağ

<sup>1</sup><https://orcid.org/0000-0001-7768-9190>

<sup>2</sup><https://orcid.org/0009-0007-8042-9729>

\*Sorumlu yazar: ekahya@nku.edu.tr

### Araştırma Makalesi

#### Makale Tarihçesi:

Geliş tarihi: 17.11.2023

Kabul tarihi:04.03.2024

Online Yayınlanma: 16.09.2024

#### Anahtar Kelimeler:

Derin öğrenme

Tanımlama

Zeytin

Hassas tarım

YOLOv5

### ÖZ

Ürün verim tahmini, ürün hasadı ve pazarlama stratejilerinin oluşturulması için çok önemli bir rol oynamaktadır. Son yıllarda, birçok tarımsal üründe verimi tahmin etmek için bilgisayarla görme ve derin öğrenme teknikleri çalışmaları yapılmaktadır. Ürünlerin dal üzerinden tam olarak ayrılması ürün verim tahminini doğrudan etkilemektedir. Bu çalışmada ağaç üzerinde ürünlerin yerlerini tespit ederek ürün verim tahminini kolaylaştıracak derin öğrenme modeli gerçekleştirilmiştir. Materyal olarak zeytin seçilmiştir. Derin öğrenme tabanlı zeytin tespiti yapılmıştır. Modelin algoritması, zeytin tespiti için olive adlı nesne sınıfından oluşmaktadır. Eğitim ve test omurgası YOLOv5 (nano-small-medium ve large) modelleridir. Oluşturan modellerin tüm metrik değerleri incelenmiştir. En başarılı model YOLOv5s algoritmasıyla, 640x640 boyutundaki görsellerin 15 Batch, 115 Epoch ile eğitilmiş model olduğu görülmüştür. Model değerleri sonuçları "metrics/precision", "metrics/recall", "metrics/mAP\_0,5" ve "metrics/mAP\_0,5:0,95" olarak incelenmiştir. "YOLOv5 small" modelinin metrik verilerinin diğer modellerle kıyaslandığında daha yüksek olduğu tespit edilmiştir. Başarı oranı 115 epoch için F1 score %85,18, precision %95,63, recall %84,24, mAP %72,8'dir. Buradan "Model 2"nin robotik zeytin hasadında zeytinin toplanmasında kullanılacak en iyi tespit modeli olduğu anlaşılmıştır.

### Deep Learning Supported Real-Time Olive Detection Application

#### Research Article

#### Article History:

Received: 17.11.2023

Accepted: 04.03.2024

Published online: 16.09.2024

#### Keywords:

Deep learning

Description

Olive

Precision agriculture

YOLOv5

#### ABSTRACT

Crop yield prediction plays a very important role in crop harvesting and marketing strategies. In recent years, computer vision and deep learning techniques have been used to predict the yield of many agricultural crops. The exact separation of the crops from the branch directly affects the yield estimation. In this study, a deep learning model has been implemented to facilitate crop yield estimation by detecting the location of crops on the tree. Olives were selected as the material. Deep learning based olive detection was performed. The algorithm of the model consists of an object class named olive for olive detection. The training and test backbone are YOLOv5 (nano-small-medium and large) models. All metric values of the constituent models were analysed. It was seen that the most successful model was the model trained with the YOLOv5s algorithm with 15 Batches and 115 Epochs for 640x640 sized images. The results of the model values were analysed as "metrics/precision", "metrics/recall", "metrics/mAP\_0,5" and "metrics/mAP\_0,5:0,95". It was found that the metric data of the "YOLOv5 small" model was higher compared to other models. The success rate for 115 epochs is F1 score %85,18, precision %95,63, recall %84,24, mAP %72,8. It

is concluded that "Model 2" is the best detection model to be used for olive picking in robotic olive harvesting.

**To Cite:** Kahya E, Aslan Y. Derin Öğrenme Destekli Gerçek Zamanlı Zeytin Tespiti Uygulaması. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi 2024; 7(4): 1438-1454.

## 1.Giriş

Derin öğrenme, özellik gösterimi, örüntü tanıma ve büyük ve karmaşık veri kümelerinin analizi için güçlü yetenekler sunarak çeşitli uygulamalarda kullanılmaktadır. Potansiyelinden dolayı tıbbi görüntüleme büyük veri analitiğine kadar çeşitli alanlarda kendisine yer bulmuştur. Derin öğrenme yöntemleri tarımda, özellikle bitki hastalıklarının tespitinde, gübreleme ve sulamada, tarım arazilerinin haritalamasında, hasat tahmininde, tarım robotlarında kullanılmaya başlanmıştır. Tarım sektöründe, özellikle de zeytin yetiştiriciliği bağlamında derin öğrenme büyük ilgi görmektedir. Derin öğrenme tekniklerinin zeytinle ilgili süreçler bağlamında uygulanması, son zamanlarda yapılan birçok çalışmanın odak noktası olmuştur. Zhang ve ark. (2022) derin öğrenme tekniklerini tarlada meyve tespiti ve takibi için kullanmışlar ve meyve bahçelerinde hızlı meyve tespiti ve verim tahmini potansiyelini ortaya koymuşlardır. Derin öğrenme de dahil olmak üzere makine öğrenimi, mahsul sınıflandırması, hastalık tahmini ve karar verme süreçlerini kapsayan modern tarım yönetiminde çok önemli bir rol oynamaktadır (Zhang ve ark., 2021). Görsel tanımlama, 3D yeniden yapılandırma ve konumlandırma alanındaki son gelişmeler, ürün hasadı da dahil olmak üzere tarımda robotik uygulamalarını genişletmiştir (Tang ve ark., 2020). Derin öğrenme teknolojisiyle birleştirilen görüş tabanlı meyve toplama robotları, meyve hasadında umut verici sonuçlar göstermektedir. Zeytin hasadında benzer uygulamalar için potansiyele işaret etmektedir (Tang ve ark., 2020). Ayrıca, derin öğrenmenin tarımda uygulanması, zeytin hasadında derin öğrenme modellerinin başarılı bir şekilde uygulanması için gerekli olan mahsullerle ilgili büyük miktarda verinin elde edilmesini ve işlenmesini içerir (Fountsop ve ark., 2020). Ayrıca, YOLOv3 gibi algoritmaların ön ve son işlemlerle birlikte kullanılması, hasat robotlarında meyve tespiti için tasarlanmış ve derin öğrenmenin robotik hasat sistemlerine entegrasyonunu göstermiştir (Kuznetsova ve ark., 2020). Otonom hasat robotik sistemleri, kümeler içinde doğru meyve tespiti için derin öğrenme sınıflandırmasına güvenerek sera ortamlarında verimli hasat yapılmasını sağlamaktadır (Toon ve ark., 2019). Li ve ark., (2020) yılındaki çalışmalarında robotik hasat makinelerinde engel tespiti ve çarpışmadan kaçınma için derin öğrenme algoritmalarının uygulanması, zeytin hasat süreçlerinin güvenliğini ve verimliliğini artırma potansiyelini vurgulamaktadırlar. Zeytin bahçesinde otomatik hasat potansiyeli, özellikle de zeytin meyvesi kesimine yönelik ürünlerin uygulanması, zeytin hasadında yenilikçi çözümlerin geliştirilmesi için bir fırsat sunmaktadır (Quilez ve ark., 2012). Ayrıca son zamanlarda yapılan çalışmalarda, insansız hava araçlarının (İHA'lar) hasat için uygun ürünlerinin algılaması için otonom navigasyonda derin öğrenmenin uygulanmasını araştırarak akıllı tarım ve kaynak optimizasyonu potansiyelini ortaya koymuşlardır (Sellers ve ark., 2023). Otonom biçerdöverler için zayıf denetimli mahsul alanı segmentasyonuna derin öğrenme uygulanmış ve tarımsal otomasyon için pratik performansını vurgulamışlardır (Kim ve ark., 2021). Bir başka çalışmada Fujinaga ve ark. (2020)

derin öğrenme, domates büyüme durumu haritalaması için uygulanmış ve bitkilerin büyüme durumuna göre domateslerin izlenmesi ve hasat edilmesini otomatikleştirme potansiyelini ortaya koymuşlardır. Onishi ve ark. (2018) otomatik bir meyve hasat robotunun geliştirilmesi için derin öğrenme kullanılmışlar ve meyve hasat süreçlerinin otomasyonunu ilerletmedeki rolünü vurgulamışlardır. İspanya, İtalya, Yunanistan ve Türkiye 'de zeytin meyvesi, ekonominin büyük bir parçasını teşkil eden güçlü bir tarımsal öneme sahip tarımsal üründür. 2021 yılı verilerine göre İspanya önde gelen zeytin üreticisidir ve 2,4 milyon hektardan fazla özel arazide 1.125,3 ton zeytinyağı üretmektedir (Anonim 1). Zeytinyağı, şu anda diğer gıdaların üretimine girmiş olan önemli bir besin kaynağıdır. Ayrıca zeytin dikimi, birçok bölgede tarımın sosyal, ekonomik ve çevresel öneminin geleneksel bir parçasıdır (Al-Hababed ve ark., 2022). Bu çalışmada robotik zeytin hasadı için kullanılacak derin öğrenme modelinin seçimi yapılmıştır. Robotik zeytin hasat sistemleri dijital görüntülerden zeytin meyvesini tespit etme ve yerini belirleme yeteneğine sahip olması gerekmektedir. Yapılan çalışmada zeytin meyvesine ait dijital görüntülerin derin öğrenme modellerinden biri olan YOLOv5 ile eğitilerek gerçek zamanlı olarak tespiti yapılmıştır. YOLO, nesne tespitini bir regresyon problemi olarak ele almaktadır. Faster R-CNN gibi "iki aşamalı" yöntemlerden daha hızlı ancak daha az doğru olmasını sağlar (Xu ve ark., 2021). Görüntülerdeki nesnelere verimli bir şekilde tespit etmek için evrişimli katmanları ve bağlantılı katmanları birleştirir (Huynh ve ark., 2022). YOLO, tıbbi teşhis görevleri, gözetim, akıllı ulaşım sistemleri ve baskılı devre kartlarının kalite denetimi dahil olmak üzere çeşitli alanlarda uygulanmaktadır (Adibhatla ve ark., 2020; Dai ve ark., 2023; Stodt ve ark., 2023). Kısıtlı ortamlarda gerçek zamanlı nesne tespiti ve enerji tasarruflu nesne tespiti için de kullanılmaktadır. (Kim ve ark., 2021). YOLO algoritması, gerçek zamanlı yetenek ve algılama doğruluğu açısından üstün performans göstererek akıllı video analizi, trafik izleme ve gözetim sistemleri gibi uygulamalar için uygun hale gelmiştir (Xu ve ark., 2021; Lin ve ark., 2022; Yunefri ve ark., 2022). Derin öğrenme modellerinin, özellikle de Yapay Sinir Ağlarının uygulanması, hastalık yönetiminden verim tahminine ve çevresel etki değerlendirmesine kadar zeytin yetiştiriciliğinin çeşitli yönlerini geliştirmek için umut vadetmektedir. Derin öğrenme teknolojilerinin zeytin hasadına entegrasyonu, tarım sektöründe üretkenliği, verimliliği ve sürdürülebilirliği artırmak içinde önemlidir.

## **2. Materyal ve Yöntemler**

### **2.1. Materyal**

Zeytin meyvesi hasadı için belirlenen kriterler, zeytin meyvelerinin olgunluk seviyesi, yağ içeriği, fenolik bileşenlerin miktarı, meyve dökülme kuvveti, hasat zamanı, mekanik hasat yöntemlerinin etkisi ve su uygulamalarının zeytinyağı kalitesi üzerindeki etkileri gibi çeşitli faktörleri içermektedir. Öncelikli kriter, zeytin meyvelerinin olgunluk seviyesidir. Zeytin hasadı, meyvelerin toplanması ve zeytinyağı üretimi için kritik bir süreçtir. Bu süreçte kullanılan farklı hasat yöntemleri ve bu yöntemlerin zeytin ve zeytinyağı kalitesi üzerindeki etkileri üzerine birçok araştırma yapılmıştır. Mekanik hasadın zeytinlerde iç hasara neden olabileceği ve bu durumun meyvelerin hızlı yumuşamasına ve çürümmesine

yol açabileceği belirtilmiştir. Bununla birlikte, mekanik hasadın daha yüksek miktarda yağ elde etmeyi kolaylaştırdığı ve bu yağın meyve depolaması sırasında hızla bozulabileceği gözlemlenmiştir (Yousfi ve ark., 2012). Dag ve ark. (2008) yılında modernizasyonun bir parçası olarak mekanik hasadın kullanımı vurgulanmışlardır. Diğer bir araştırmada, entegre bir hasat sisteminin zeytin meyvelerinin kalitesi üzerindeki etkilerini değerlendirmiştir. Plasquy ve ark.(2021) optimum koşulların işlenmeden önce zeytin meyvelerinin kalitesi için ne kadar önemli olduğunu ortaya koymuştur.

## 2.2.Yöntem

Çalışma kapsamında nesne tespiti ve analizi hedeflenen zeytin meyvesinin veri setini hazırlarken, Tekirdağ Naip köyünde üretici zeytin tarlasından alınan 30 görüntü ile çeşitli internet kaynaklarından alınmış 110 görüntü kullanıldı. Görüntüler içindeki her bir zeytin görüntüsünü içeren kısımların sınırlayıcı kutu alanı ile işaretlenmesi yapıldı. Şekil 1.a-b 'de üretici tarlasından alınan görüntülerinden, Şekil 2.a-b 'de veri seti için internet ortamından alınan görüntü örneklerinden örnek görüntüler verilmiştir.



(a)



(b)

Şekil 1.a-b. Üretici tarlasından alınan görüntü örnek resimleri



(a)



(b)

Şekil 2.a-b. İnternet ortamından alınmış eğitimde kullanılmış görüntü örnekleri(Anonim 2.a-b)

### 2.2.1.Etiketleme

Bir nesne tespiti modelinin, bir veri seti üzerinde eğitim gerçekleştirebilmesi için, tespit edilmesi hedeflenen nesnelere eğitileceği veri setinde etiketlenmesi gerekmektedir. Bu sebeple Tekirdağ Naip köyünde üretici zeytin tarlasından ve çeşitli internet kaynaklarından alınmış toplam 140 görselin her birinde zeytin görüntüsünü içeren kısımların sınırlayıcı kutu alanı ile işaretlendi. Ait oldukları nesne sınıfı adı "olive" olarak tanımlandı. Görsel etiketleme programı olarak Roboflow kullanıldı. Şekil 3'te etiket ekranı gösterilmiştir.



Şekil 3. Label Ekranı (Anonim 3)

### 2.2.2.Eğitim Model Seçimi ve Başlatılması

Yapmış olduğumuz çalışmada, CNN (Convolutional Neural Networks) yöntemiyle geliştirilmiş YOLO (You Only Look Once) derin öğrenme modellemesi olan YOLOv5 modellemesi kullanılmıştır. YOLO algoritması, bilgisayarla görme alanında büyük ilgi gören nesne tespitine yönelik bir derin öğrenme yaklaşımıdır. YOLO'nun temel amacı, bir görüntü üzerindeki nesnelere tespit etmek ve bu nesnelere sınıflandırmaktır. YOLO'nun ana avantajı, diğer geleneksel nesne tanıma yöntemlerine göre daha hızlı çalışmasıdır. Geleneksel yöntemler genellikle bir görüntüyü birkaç farklı bölgeye böler ve her bir bölgeyi ayrı ayrı analiz eder. Ancak YOLO, görüntüyü tek bir seferde analiz ederek nesne tespiti ve sınıflandırma işlemlerini gerçekleştirir. YOLO, genellikle derin öğrenme kütüphaneleri ve çerçeveleri (örneğin, TensorFlow veya PyTorch) üzerinde uygulanan bir algoritma olarak kullanılır. Bu sayede, nesne tespiti, sınıflandırma modellerini eğitmek ve kullanmak daha kolay olmaktadır. YOLO algoritması, hız ve doğruluk arasında bir denge sunarak gerçek zamanlı nesne tespiti için güçlü bir araç olarak ortaya çıkmaktadır. Uygulamaları çeşitli alanlara yayılmıştır ve uyarlanabilirliği, performansı, bilgisayarla görme alanında yaygın olarak kullanılmasına katkıda bulunmaktadır. Bu nedenle eğitim ve test seti olarak YOLOv5n/s/m ve l (nano-small-medium ve large) tercih edilmiştir.

Eğitim YOLOv5'in resmi sitesi GitHub veri deposundan indirilen kodlarla birlikte Python editöründe yazılmış program kodları ile yapılmıştır. Eğitim için aşağıda yazılı olan kodlar içerisindeki parametreler ve düzenlemeler tercih edilmiştir.

```
python train.py --img 640 --batch 15 --epochs 115 --data dataset.yaml --weights yolov5n.pt
```

```
python train.py --img 640 --batch 15 --epochs 115 --data dataset.yaml --weights yolov5s.pt
```

```
python train.py --img 640 --batch 15 --epochs 115 --data dataset.yaml --weights yolov5m.pt
```

```
python train.py --img 640 --batch 15 --epochs 115 --data dataset.yaml --weights yolov5l.pt
```

Program, öncelikle YOLOv5 dosyalarını kontrol etmekte, herhangi bir güncelleme durumunu olup olmadığını kontrol etmektedir. Sonraki adımı istenen döngü sayısı (epoch) kadar eğitim işlemi tekrarlamaktadır. Eğitim sonucundaki değerlendirme göstergeleri şunlardır;

Gerçek Pozitif (TP), doğru şekilde pozitif olarak sınıflandırılan pozitif görüntülerin sayısını tanımlar.

Gerçek Negatif (TN), modelin negatif bir örneği gerçekten negatif olarak doğru şekilde tanımladığı belirli bir örnek sayısını gösterir.

Yanlış Pozitif (FP), negatif bir örneğin algoritma tarafından kaç örnekte yanlışlıkla pozitif bir örnek olarak tanımlandığını detaylandırır.

Yanlış Negatif (FN), algoritmanın pozitif bir numuneyi yanlışlıkla negatif olarak kategorize ettiği örnek sayısını gösterir.

**Doğruluk (Accuracy):** İncelenen sınıflandırma problemi dengeli sınıf dağılımına sahipse kullanılan metriktir. Sınıf dağılımının dengesiz olması durumunda, sınıf sayısı düşük olan sınıfı yakalama problemi yaşanabilmektedir.

$$\text{Accuracy} = \frac{\text{TN} + \text{TP}}{(\text{TP} + \text{FP} + \text{TN} + \text{FN})} \quad (1)$$

**Hata Oranı (Error Rate):** Probleme yanlış yapılan sınıflandırmaların/tahminlerin sıklığının oranını verir.

$$\text{Error Rate} = \frac{\text{FN} + \text{FP}}{(\text{TP} + \text{FP} + \text{TN} + \text{FN})} \text{ or } (1 - \text{Accuracy}) \quad (2)$$

**Hassasiyet (Precision):** Pozitif sınıf (1) tahminlerinin başarı oranıdır. Tahmin edilen pozitif sınıfların (1 olarak tahmin edilen sınıfların) gerçekte ne kadarının pozitif olduğunu gösteren metrik değeridir.

$$\text{Precision} = \frac{\text{TP}}{(\text{FP} + \text{TP})} \quad (3)$$

**Duyarlılık (Recall):** Pozitif sınıfın (1) doğru tahmin edilme oranıdır. Tahmin edilen pozitif sınıfların ne kadarının doğru tahmin edildiğini gösteren metrik değeridir.

$$\text{Recall} = \frac{\text{TP}}{(\text{TP} + \text{FN})} \quad (4)$$

**F1-Score:** Precision ve recall değerlerinin harmonik ortalamasıdır.

$$\text{F1 Score} = \frac{2 * \text{Precision}}{(\text{Precision} + \text{Recall})} \quad (5)$$

**Ortalama Kesinlik Ölçütü (Mean Average Precision):** Bu metrik, algılanan sınırlayıcı kutuların hassas ve geri çağırma değeridir. mAP değer skalası 0 ile 1 arasındadır. Elde edilen değerler ne kadar yüksek olursa kesinlik ölçütü o kadar iyi olacaktır. mAP, her sınıf için ayrı ayrı ortalama kesinlik (AP)




ve ardından sınıf üzerindeki ortalama hesaplanarak bulunur. Hesaplanan mAP değeri 0.5'in üzerindeyse doğru pozitif olarak kabul edilir.

$$mAP = \frac{1}{C} + \sum_{k=1}^T P(k)\Delta R(k) \quad (6)$$

### 3.Araştırma Bulguları


YOLOv5 algoritmalarının sonuçlarının hata matrisi metriklerine göre sonucu F1 Score, Precision ,Recall ve Precision-Recall değer grafikleri incelenmiştir. Değer grafikleri aşağıdaki Şekil 4 F1Score, Şekil 5 precision, Şekil 6 recall, Şekil 7 precision-recall ve Şekil 8'de Loss function grafikleri verilmiştir.



Şekil 4. F1 score değerleri


Şekil 4'deki grafik, YOLOv5 modelinin F1 skorunun güven değerine göre nasıl değiştiğini göstermektedir. YOLOv5n, YOLOv5s, YOLOv5m ve YOLOv5l modellerin F1 score değerleri sırasıyla 0,92, 0,90, 0,95 ve 0,89 olduğu tespit edilmiştir. YOLOv5s modelinin F1 skorunun maksimum değeri 0,90 olarak görünmektedir. Bu değer, modelin hassasiyet ve geri çağırma değerlerini en iyi dengelediği güven değerini (yaklaşık 0,503) göstermektedir. Bu, modelin pozitif olarak tahmin edilen örneklerin çoğunun gerçekten pozitif olduğunu (yüksek hassasiyet) ve aynı zamanda tüm gerçek pozitif örneklerin çoğunu doğru bir şekilde tahmin ettiğini (yüksek geri çağırma) göstermektedir.

F1 skorunun 0,5'in üzerinde olması genellikle iyi bir performans göstergesi olarak kabul edilir. Bu durumda, modelin F1 skoru 0,5'in çok üzerinde olduğu için, modelin performansının oldukça iyi olduğu söylenilebilir.



Şekil 5. Hassasiyet sonuç grafiği

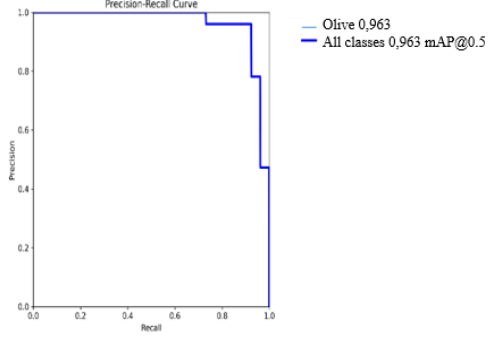
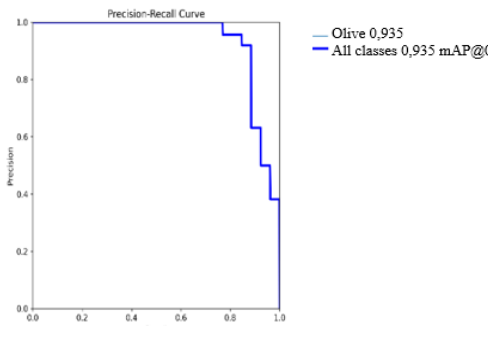
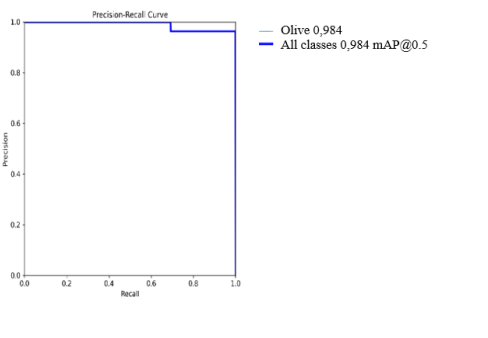
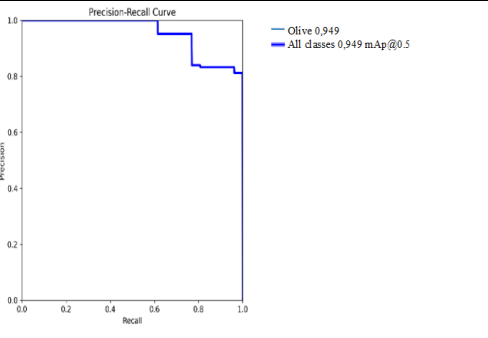
Şekil 5'deki grafikte gözlemlenen hassasiyet (precision) grafiği, modelin tahminlerinin doğruluğunu değerlendiren önemli bir ölçü olan hassasiyet skorunu göstermektedir. YOLOv5n, YOLOv5s, YOLOv5m ve YOLOv5l modellerin hassasiyet değerleri sırasıyla 0,91, 0,95, 0,92 ve 0,81 olduğu tespit edilmiştir. YOLOv5s modelinin grafik üzerindeki hassasiyet skoru, 1 civarında bir maksimum değere ulaşmaktadır. Bu durum, modelin nesne tespitlerinde yüksek kesinlikle çalıştığını ifade etmektedir.



Şekil.6. Duyarlık sonuç grafiği

Şekil 6'te geri çağırma (recall), bir modelin gerçek pozitifleri (doğru tahminler) tespit etme yeteneğini ölçen metrik değerleri gösterilmektedir. YOLOv5n, YOLOv5s, YOLOv5m ve YOLOv5l modellerin geri çağırma değerleri sırasıyla 0,92, 0,97, 0,91 ve 0,81 olduğu tespit edilmiştir. YOLOv5s'in 0,97 civarında maksimum bir değere ulaştığı görülmüştür. Bu, modelin belirli nesnelere doğru bir şekilde tespit etme konusunda yüksek düzeyde bir başarı elde ettiğini göstermektedir. Geri çağırma skorunun 1'e ne kadar yakın olduğu, modelin kaçınılmış olası pozitifler konusundaki başarısını yansıtır. Grafikteki değerlerin 1 civarında olması, modelin gerçek pozitifleri büyük ölçüde tespit ettiği, ancak hala iyileştirilebilecek alanlar bulunduğu anlamına gelmektedir.




|   |  |
|---|--|
| <p>Size: 640x640, Batch: 15, Epoch: 115,<br/>Algorithm: YOLOv5n</p> |    |
| <p>Size: 640x640, Batch: 15, Epoch: 115,<br/>Algorithm: YOLOv5s</p> |    |
| <p>Size: 640x640, Batch: 15, Epoch: 115,<br/>Algorithm: YOLOv5m</p> |   |
| <p>Size: 640x640, Batch: 15, Epoch: 115,<br/>Algorithm: YOLOv5l</p> |  |

Şekil.7. Precision-Recall sonuç grafiği

Şekil 7 'teki değerler geri çağırma ve hassasiyet grafikleri, bir nesnenin doğru bir şekilde tespit edilip edilemediğini değerlendirmek için önemlidir. YOLOv5n, YOLOv5s, YOLOv5m ve YOLOv5l modellerin geri çağırma ve hassasiyet değerleri sırasıyla 0,963, 0,935, 0,984 ve 0.949 olduğu tespit edilmiştir. YOLOv5s 'in grafikte hassasiyet ve geri çağırma skorlarının 0,935 civarında maksimum değere ulaşması, modelinizin belirli nesnelere doğru bir şekilde tespit etme yeteneğinde orta düzeyde bir başarı gösterdiği anlaşılmaktadır. Hassasiyet, modelinizin ne kadar doğru tahmin yaptığını ölçer ve

yüksek hassasiyet, modelinizin tahminlerinin çoğunlukla doğru olduğunu gösterir. Geri çağırma ise modelinizin gerçek pozitifleri ne kadar etkili bir şekilde tespit ettiğini belirler. Bu iki metrik arasındaki denge, modelin genel performansını anlamak için önemlidir.



Şekil 8. Kayıp Fonksiyonları sonuç grafiği

Şekil 8 'deki grafikler incelendiğinde YOLOv5s 'in hatalarının zaman içinde genel olarak azaldığını görülmektedir. Bu durum, modelin eğitim süreci boyunca genellikle daha iyi hale geldiği ve tahminlerinin gerçek değerlere daha yakın olduğu anlamına gelmektedir.

YOLOv5s 'in ilk ve son 10 epoch değerleri incelendiğinde aşağıda verilmiş olan değerleri bulunmuştur.

**İlk 10 Epoch:****Kutu Kaybı (Box\_Loss):** 0,093945**Nesne Kaybı (Obj\_Loss):** 0,064094**Sınıf Kaybı (Cls\_Loss):** 0**Hassasiyet (Precision):** 0,54697**Duyarlılık (Recall):** 0,30769**mAP@0,5 (0,5'e göre Ortalama Hassasiyet):** 0,40124**mAP@0,5:0,95 (0,5 ila 0,95 arasında Ortalama Hassasiyet):** 0,11277**Son 10 Epoch:****Kutu Kaybı (Box\_Loss):** 0,029486**Nesne Kaybı (Obj\_Loss):** 0,022507**Sınıf Kaybı (Cls\_Loss):** 0**Hassasiyet (Precision):** 0,95633**Duyarlılık (Recall):** 0,84237**mAP@0,5 (0,5'e göre Ortalama Hassasiyet):** 0,93831**mAP@0,5:0,95 (0,5 ila 0,95 arasında Ortalama Hassasiyet):** 0,72799

Bu değerlere göre;

**1. Öğrenme Oranı:** İlk 10 epoch boyunca öğrenme oranları düşüş göstermektedir. Bu durum, modelin eğitim sürecinin başında daha geniş bir alanı keşfetmeye odaklandığını gösterir. Son 10 epoch içinde öğrenme oranları daha sabit bir seviyeye gelmiş, bu da modelin daha ince ayarlar ve özelleştirmeler üzerinde çalıştığını göstermektedir.


**2. Kayıp Fonksiyonlar:** Kutu, nesne ve sınıf kaybı değerleri ilk 10 epoch boyunca düşmeye devam ettiği anlaşılmaktadır. Bu, modelin temel konseptleri ve genel veri yapısını daha iyi anlamaya başladığını göstermektedir. Son 10 epoch içinde bu kayıp fonksiyonları daha da düştüğü görülmektedir, bu durum modelin daha spesifik ve karmaşık özellikleri öğrenmeye başladığı anlamına gelmektedir.

**3. Hassasiyet ve Duyarlılık:** Hassasiyet ve duyarlılık metrikleri ilk 10 epoch boyunca genellikle artış eğilimindedir. Bu, modelin eğitimin başlangıç değerlerinin başlangıçta iyi performans göstermediğini ancak zamanla eğitimin iyi performans gösterdiği anlaşılmaktadır. Son 10 epoch içinde bu metriklerde daha belirgin bir iyileşme tespit edilmiş, modelin eğitim verilerini daha etkili bir şekilde öğrendiğini ve bu verilere daha iyi uyum sağlandığı görülmüştür.


**4. Toplu Performans Analizi:** İlk 10 epoch'ta modelin genel performansı belirli zorluklarla başlamış olabileceği ancak son 10 epoch içinde önemli ölçüde artmış olduğu tespit edilmiştir. Öğrenme oranlarının düşmesi ve kayıp fonksiyonlarının düşüşü, modelin daha spesifik öğrenmeye ve verilere daha iyi uyum sağlamaya başladığını göstermektedir.

### 3.1.Eğitim Sonucu

Eğitim sonuç görüntüleri Şekil 9 ve 10 ‘da verilmiştir.



Şekil 9. Modellerin eğitimlerinin sonucunda ortaya çıkan internet üzerinden alınan görüntünün(Anonim 3) “Validation Batch” tahmin işaretlemeleri



Şekil 10. Modellerin eğitimlerinin sonucunda ortaya çıkan gerçek zamanlı “Validation Batch” tahmin işaretlemeleri

### 3.2.Model Algoritmalarının Karşılaştırılması

Model 2'nin metrik verileri ve diğer modellerin bu verilere farkı Tablo 1'de gösterilmiştir.

Modellerin başarılarını ölçmek için modellerin nesne tespitlerindeki doğru tahmin başarıları ve ortalamaları önemli rol oynasa da, tek başına yeterli değildir. Modellerin, hem eğitim hem de doğrulama veri kümelerindeki kayıp değerleri de model başarısının incelenmesinde rol oynayan önemli parametrelerdir. Eğitim ve doğrulama verilerindeki sınıflandırma kayıplarını ifade eden train/cls\_loss ve val/cls\_loss parametreleri çok sayıda nesne sınıfının tespitini gerektiren modellerde önemli bir rol oynar.

Tablo 1. Model 2'nin metrik değerlerinin diğer modellerle karşılaştırılması

| Model          | Metrics/mAP_0,5 | Fark (Model 2) | Metrics/mAP_0,5:0,95 | Fark (Model 3) |
|----------------|-----------------|----------------|----------------------|----------------|
| <b>Model 2</b> | <b>0,93831</b>  |                | <b>0,72799</b>       |                |
| Model 1        | 0,9611          | -0,02279       | 0,74545              | -0,01746       |
| Model 3        | 0,98389         | -0,044558      | 0,85117              | -0,12318       |
| Model 4        | 0,95373         | -0,01542       | 0,80113              | -0,07314       |
| Model          | Train/box_loss  | Fark (Model 2) | Train/obj_loss       | Fark (Model 2) |
| <b>Model 2</b> | <b>0,029486</b> |                | <b>0,022507</b>      |                |
| Model 1        | 0,034516        | -0,00503       | 0,025471             | -0,002964      |
| Model 3        | 0,023694        | 0,005792       | 0,019389             | 0,003118       |
| Model 4        | 0,021723        | 0,007763       | 0,017837             | 0,00467        |
| Model          | val/box_loss    | Fark (Model 2) | val/obj_loss         | Fark (Model 2) |
| <b>Model 2</b> | <b>0,023557</b> |                | <b>0,013704</b>      |                |
| Model 1        | 0,028312        | -0,004755      | 0,013987             | -0,000283      |
| Model 3        | 0,018598        | 0,004959       | 0,010963             | 0,002741       |
| Model 4        | 0,018997        | 0,00456        | 0,012009             | 0,001695       |

Modellerin kayıp değerlerini gösteren tablodaki dört parametre sütunu (train/box\_loss, train/obj\_loss, val/box\_loss, val/obj\_loss) değerleri incelendiğinde, eğitim setinde en az kayıp değerlerine sahip modelin, “Model 4” olduğu görülmektedir. Fakat doğrulama verilerindeki kutu tahmini ve nesne tespiti kayıplarında en az kayıp değerlerine sahip modelin, “Model 2” olduğu görülmektedir.

Son olarak, modellerin optimizasyon parametreleri (x/lr0-1-2) incelenmiştir. Bu değerler Tablo 2’de gösterilmiştir. Tüm modellerin bu parametrelerdeki değerleri eşittir.

Tablo 2. Optimazasyon parametreleri

| Model          | x/lr0-1-2         | Fark(Model 2) |
|----------------|-------------------|---------------|
| Model 1        | 0,00027217        | 0             |
| <b>Model 2</b> | <b>0,00027217</b> |               |
| Model 3        | 0,00027217        | 0             |
| Model 4        | 0,00027217        | 0             |

#### 4. Tartışma

Tarım sektörü, teknolojik gelişmelerle birlikte sürekli olarak evrim geçirmekte ve çeşitli yenilikçi yöntemlere açık hale gelmektedir. Derin öğrenme, yapay zeka alanında önemli bir konsepttir ve tarım sektöründe üretimde ve hasat da kullanılabilir. Bu nedenle derin öğrenme, zeytin üretimi ve hasadında giderek daha fazla uygulanmaktadır. Konvolüsyonel sinir ağları (CNN) ve kapsül ağları gibi bilgisayarla görme teknikleri, zeytin ağaçlarında hastalık sınıflandırmasının yanı sıra zeytinlerin otomatik sayımı, bireysel boyutu ve kütle tahmini için kullanılmaktadır (Alkhasawneh, 2021; Alshammari ve ark., 2022). Alshammari ve ark. (2022) yılındaki çalışmalarında zeytin yaprağı hastalıklarının teşhisi için optimal bir derin öğrenme modeli sunarak, derin öğrenmenin zeytin yetiştiriciliğinde hastalık teşhisine katkıda bulunma potansiyelini göstermişlerdir. Al-Hababeh ve ark. (2022) zeytin meyvelerini hasat etmek için

özel olarak tasarlanmış akıllı bir robotik kol tanıtılarak, zeytin hasadında robotik ve potansiyel olarak derin öğrenmenin potansiyel uygulamasını göstermiştir. Kanagaraju ve ark. (2022) zeytinyağının olgunlaşma süresini tahmin etmek için görüntü işleme ve sinir ağı modellerini kullanmışlar ve hasat zamanlamasını optimize etmede derin öğrenmenin potansiyeli göstermişlerdir. Andrushia ve ark. (2022) 'de zeytin de dahil olmak üzere meyvelerde hastalık tespiti ve analizi için derin öğrenme yöntemlerini kullanmışlardır. Bu tekniklerin tarımsal ortamlarda geniş uygulanabilirliği vurgulamışlardır. Bu çalışmalar, zeytin üretimi ve hasadı da dahil olmak üzere tarımsal uygulamalarda devrim yaratmada derin öğrenmenin önemli etkisini toplu olarak vurgulamaktadır. Bir başka çalışmada Susanti ve ark. (2023), derin öğrenme modellerinin, özellikle de Yapay Sinir Ağlarının, tarımsal bitki ürünlerindeki yaprak hastalıklarını ve zararlılarını tespit etmek ve sınıflandırmak için doğru olduğunu vurgulamışlardır. Vega-Márquez ve ark. (2020), zeytinyağı sınıflandırmasının performansını artırmak için derin öğrenme tekniklerinin kullanımını tartışarak zeytin ürünleri bağlamında derin öğrenmenin potansiyelini göstermişlerdir. Benzer şekilde, Mamdouh ve ark. (2021) yılındaki çalışmalarında zeytin meyve sineği tespiti ve sayımı için özel olarak tasarlanmış bir derin öğrenme çerçevesi sunarak zeytin bahçelerinde haşere yönetiminde derin öğrenme ile yapılabileceğini vurgulamışlardır. Zeytin hasadında derin öğrenmenin kullanılması, verimliliği ve üretkenliği artırarak sektörde devrim yaratma potansiyeline sahiptir. Bu alandaki ilerlemeyi hızlandırmak için derin öğrenme algoritmaları ve mimarileri geliştirilmektedir (LeCun ve ark., 2015). YOLO, Inception,R-CNN gibi derin öğrenme algortimaları bu amaçla kullanılmaktadır. Şekil, renk gibi ortak özelliklerde standart getirilmeye çalışılmaktadır. Bununla birlikte, robotik hasat sistemlerinin yaygın olarak benimsenmesi için gerekli verimlilik düzeyine ulaşmada zorluklar devam etmektedir (Zhou ve ark., 2022). Önceki çalışmalar incelendiğinde zeytin meyvesinde sadece hastalık tespiti ve ürün tahmin sistemlerinde derin öğrenme modelleri kullanıldığı görülmektedir. Bunun sebebi olarak Abozeid ve ark. (2022), zeytin çiftlikleri için standart bir veri setinin olmamasının bu alanda derin öğrenme tekniklerinin uygulanmasını engellediğini belirtmişlerdir. Yaptığımız çalışmada, eğitilen modelin tarlada ve internet üzerinden elde edilen görüntülerle gerçek zamanlı olarak test edilmesi sonucunda, hasat robotları için derin öğrenme yardımıyla tespit sistemlerine duyulan ihtiyaca uyumlu olduğu görülmüştür.

## 5.Sonuçlar

Çalışma robotik zeytin hasadında kullanılmak üzere zeytinin dal üzerinde en iyi tespit modelini belirlemek için yapılmıştır. Bir diğer amaçta robotik zeytin hasadı yönteminin güvenilirliğini ve hızını arttırmaktır. Çalışmada, 140 adet ağaç üzerinde zeytin meyvesi görüntüsünden oluşan bir veri kümesi hazırlanmıştır. Her bir görüntüde birden fazla zeytin bulunmaktadır. Hazırlanan veri seti ile eğitilen ağ tarlada gerçek zamanlı olarak ve ayrıca internet üzerinden alınmış görüntüler, tarlada çekilmiş görüntülerle test edilmiştir. Yolov5 modelinin tüm alt modelleri için hazırlanmış olan eğitim setinin doğruluğu, test seti ile kontrol edilmiştir. Elde edilen tüm metrik değerleri incelenmiştir. YOLOv5 'in alt modeller sonuçları birbirleriyle karşılaştırılmıştır. En başarılı model algoritması, 640x640

boyutundaki görselle eğitilen YOLOv5s olduğu tespit edilmiştir. Model değerleri sonuçları “metrics/precision”, “metrics/recall”, “metrics/mAP\_0,5” ve “metrics/mAP\_0,5:0,95” olarak incelenmiştir. “YOLOv5 small” modelinin metrik verilerinin diğer modellerle kıyaslandığında daha yüksek olduğu tespit edilmiştir. Başarı oranı 115 epoch için F1 score %85,18, precision %95,63, recall %84,24, mAP %72,8’dir. Buradan YOLOv5 small’un robotik zeytin hasadında zeytinin dal üzerinde tespitinde kullanılacak en iyi tespit modeli olduğu anlaşılmıştır. Ayrıca çalışma ürün tespiti için derin evrişimli sinir ağlarının kullanılmasını ve derin öğrenmenin ürün tespit sistemlerindeki önemini desteklenmektedir.

### **Çıkar Çatışması Beyanı**

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

### **Araştırmacıların Katkı Oranı Beyan Özeti**

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan ederler.

### **Kaynakça**

- Abozeid A, Rayan A., Elhadad, A., Taloba AI., El-Aziz RMA. A large-scale dataset and deep learning model for detecting and counting olive trees in satellite imagery. *Computational Intelligence and Neuroscience* 2022; 1-8.
- Adibhatla VA., Chih H., Hsu C., Cheng JY., Abbod MF., Shieh J. Defect detection in printed circuit boards using you-only-look-once convolutional neural networks. *Electronics* 2020; 9(9): 1547.
- Al-Hababeh OM., Ayoub S., Yaman MA., Matahen M., Sarayra M. A smart robotic arm for harvesting olive fruits. *MATEC Web of Conferences* 2022; 370.
- Alkhasawneh MS. Olive oil ripping time prediction model based on image processing and neural network. *International Journal of Advanced Computer Science and Applications* 2021;12(1).
- Alshammari H., Gasmi K., Krichen M., Ammar LB., Abdelhadi MO., Boukrara A., Mahmood MA. Optimal deep learning model for olive disease diagnosis based on an adaptive genetic algorithm. *Wireless Communications and Mobile Computing* 2022; 1-13.
- Alshammari H., Gasmi K., Ltaifa IB., Krichen M., Ammar LB.,Mahmood MA. Olive disease classification based on vision transformer and cnn models. *Computational Intelligence and Neuroscience* 2022; 1-10.
- Andrushia AD., Neebha TM., Patricia AT., Umadevi S., Anand N., Varshney A. Image-based disease classification in grape leaves using convolutional capsule network. *Soft Computing* 2022; 27(3): 1457-1470.
- Anonim1. <https://arastirma.tarimorman.gov.tr/tepge> (Erişim tarihi:10/11/2023)
- Anonim 2-a. <https://www.tarimdanhaber.com/zeytin-yetistiriciligi> (Erişim tarihi:20/07/2023)



- Anonim 2-b. <https://yemek.com/zeytin-agaclari-hakkinda-bilmeniz-gerekenler> (Erişim tarihi : 20/07/2023)
- Anonim 3. <https://pixabay.com/photos/olives-olive-tree-sheets-branches-3900423> (Erişim tarihi: 10/08/2023)
- Dag A., Ben-Gal A., Yermiyahu U., Basheer L., Yogev N., Kerem Z. The effect of irrigation level and harvest mechanization on virgin olive oil quality in a traditional rain-fed 'sourı' olive orchard converted to irrigation. *Journal of the Science of Food and Agriculture* 2008; 88(9): 1524-1528.
- Dai Y., Liu W., Xie W., Liu R., Zheng Z., Long K., Ling G. Making you only look once faster: toward real-time intelligent transportation detection. *IEEE Intelligent Transportation Systems Magazine* 2023; 15(3): 8-25.
- Fountsop AN., Fendji JLEK., Atemkeng M. Deep learning models compression for agricultural plants. *Applied Sciences* 2020; 10(19): 6866.
- Fujinaga T., Yasukawa S., Ishii K. Tomato growth state map for the automation of monitoring and harvesting. *Journal of Robotics and Mechatronics* 2020; 32(6): 1279-1291.
- Huynh K., Ly-Tu N., Le-Tien T. An efficient model for copy-move image forgery detection. *International Journal of Web Information Systems* 2020; 18(2/3): 181-195.
- Kanagaraju P., Aushiq NM., Vanan RT. Disease detection and analysis in fruits using image processing. *International Journal of Health Sciences* 2022; 1198-1211.
- Kim W., Lee D., Kim T., Kim H., Sim T., Kim YJ. Weakly supervised crop area segmentation for an autonomous combine harvester. *Sensors* 2021; 21(14): 4801.
- Kuznetsova A., Maleva T., Soloviev V. Using yolov3 algorithm with pre- and post-processing for apple detection in fruit-harvesting robot. *Agronomy* 2020; 10(7): 1016.
- LeCun Y., Bengio Y., Hinton GE. Deep learning. *Nature* 2015; 521(7553): 436-444.
- Li Y., Iida M., Suyama T., Suguri M., Masuda R. Implementation of deep-learning algorithm for obstacle detection and collision avoidance for robotic harvester. *Computers and Electronics in Agriculture* 2020; 174, 105499.
- Lin C., Jhang J. Intelligent traffic-monitoring system based on yolo and convolutional fuzzy neural networks. *IEEE Access* 2022;10: 14120-14133.
- Mamdouh N., Khattab A. Yolo-based deep learning framework for olive fruit fly detection and counting. *IEEE Access* 2021; 9: 84252-84262.
- Onishi Y., Yoshida T., Kurita H., Fukao T., Arihara H., Iwai A. An automated fruit harvesting robot by using deep learning. *The Proceedings of JSME Annual Conference on Robotics and Mechatronics (Robomec)*, 2018(0); 1A1-B03.
- Plasquy E., Blanco-Roldán GL., Fernández MDCF., García JM. Effects of an integrated harvest system on the quality of olive fruit for small producers. *Grasas Y Aceites* 2021; 72(4): e436.

- Quilez OA., Castillo NS., Maiz FR., Rodríguez JC., Mohedano DP., Lovera M., Corzo FC. Automated harvesting in the olive grove - application of products for olive fruits abscission. *Acta Horticulturae* 2012; (949): 427-430.
- Sellers T., Lei T., Carruth DW., Luo C. Deep learning-based heterogeneous system for autonomous navigation. *Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping VIII* 2023.
- Stodt J., Madan M., Reich C., Filipović L., Ilijaš T. A study on the reliability of visual xai methods for x-ray images. *Studies in Health Technology and Informatics* 2023; 32-35.
- Susanti R., Nofendra R., Zaini Z., Suhaimi MSAb., Rusydi, MI. The use of artificial neural networks in agricultural plants. *Andalas Journal of Electrical and Electronic Engineering Technology* 2023; 2(2): 62-68.
- Tang Y., Chen M., Chen Z., Luo L., Li J., Lian G., Zou X. Recognition and localization methods for vision-based fruit picking robots: a review. *Frontiers in Plant Science* 2020; 11.
- Toon OP., Zakaria MA., Nasir AFA., Majeed APPA., Tan CY., Yew, LNC. Autonomous tomato harvesting robotic system in greenhouses: deep learning classification. *Mekatronika* 2019; 1(1): 80-86.
- Vega-Márquez B., Nepomuceno-Chamorro IA., Jurado-Campos N., Rubio-Escudero C. Deep learning techniques to improve the performance of olive oil classification. *Frontiers in Chemistry* 2020; 7.
- Xu Z., Li J., Zhang M. A surveillance video real-time analysis system based on edge-cloud and fl-yolo cooperation in coal mine. *IEEE Access* 2021; 9: 68482-68497.
- Yousfi K., Weiland C., García JM. Effect of harvesting system and fruit cold storage on virgin olive oil chemical composition and quality of superintensive cultivated ‘arbequina’ olives. *Journal of Agricultural and Food Chemistry* 2012; 60(18): 4743-4750.
- Yunefri Y., Agushybana F., Fadrial YE., Anggraini K., Ramadhani M., Hardianto R. Implementation of object detection with you only look once algorithm in limited face-to-face times in pandemic. *Journal of Applied Engineering and Technological Science (JAETS)* 2022; 4(1): 400-404.
- Zhang J., Liu J., Chen Y., Feng X., Sun Z. Knowledge mapping of machine learning approaches applied in agricultural management- A scientometric review with citespace. *Sustainability* 2021; 13(14): 7662.
- Zhang W., Wang J., Liu Y., Chen K., Li H., Duan Y., Guo W. Deep-learning-based in-field citrus fruit detection and tracking. *Horticulture Research* 2022; 9.
- Zhou H., Xiao J., Kang H., Wang X., Au W., Chen C. Learning-based slip detection for robotic fruit grasping and manipulation under leaf interference. *Sensors* 2022; 22(15): 5483.