



## Detection of Damage Caused by Some Vineyard Pests with the YOLOv8x Model Using Deep Learning and Object Detection Methods

Tahsin Uygun<sup>1,a,\*</sup>, Mehmet Metin Özgüven<sup>2,b</sup>, Dürdane Yanar<sup>3,c</sup>

<sup>1</sup>Tokat Gaziosmanpaşa Üniversitesi, Biyosistem Mühendisliği Bölümü, Türkiye

<sup>2</sup>Ankara Üniversitesi, Tarım Makineleri ve Teknolojileri Mühendisliği Bölümü, Türkiye

<sup>3</sup>Tokat Gaziosmanpaşa Üniversitesi, Bitki Koruma Bölümü, Türkiye

\*Corresponding author

ARTICLE INFO	ABSTRACT
<p><i>Research Article</i></p> <p>Received : 31.10.2023 Accepted : 08.12.2023</p> <p><b>Keywords:</b> Deep Learning Object Detection YOLOv8x Vineyard Pests Vineyard</p>	<p>It is very important to control, monitor and maintain the vineyards correctly and on time. Excessive use of pesticides in combating vineyard pests endangers human health and causes environmental pollution. In addition, excessive use of pesticides causes an increase in operating expenses when considered from an economic perspective. Therefore, timely diagnosis of pests and their damage in the vineyard is very important. One of the methods that helps ensure timely detection is deep learning. This study was carried out to detect the damage caused by some vineyard pests (Grapevine moth, thrips, vineyard leaf scab and two-spotted spider mite) on leaves and fruit parts with the YOLOv8x model, which is a deep learning algorithm. A dataset consisting of 7 different classes and 3500 images was generated. The generated dataset; Trained with YOLOv8(n/s/m/l/x) models. As a result of the training, YOLOv8x model performance values are as follows; It gave results as mAP<sub>0.5</sub>, mAP<sub>0.5-0.95</sub>, Precision, Recall, 0.926, 0.648, 0.892 and 0.903. The same dataset was trained with YOLOv7, DETR and RTMDet models and performance comparisons were made with the YOLOv8x model. As a result of the comparison, the YOLOv8x model was the one that best detected the damage caused by the mentioned pests in the vineyards.</p>

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 12(3): 386-396, 2024

## Derin Öğrenme ve Nesne Algılama Yöntemleri Kullanılarak Bazı Bağ Zararlılarının Oluşturduğu Hasarın YOLOv8x Modeli ile Tespiti

MAKALE BİLGİSİ	ÖZ
<p><i>Araştırma Makalesi</i></p> <p>Geliş : 31.10.2023 Kabul : 08.12.2023</p> <p><b>Anahtar Kelimeler:</b> Derin Öğrenme Nesne Algılama YOLOv8x Bağ Zararlıları Bağ</p>	<p>Bağların kontrolünün, takibinin ve bakımının zamanında doğru bir şekilde yapılması çok önemlidir. Bağ zararlılarıyla mücadelede aşırı pestisit kullanımı, insan sağlığını tehlikeye atmakta ve çevre kirliliğine yol açmaktadır. Ayrıca aşırı pestisit kullanımı ekonomik açıdan düşünüldüğünde işletme giderlerinin artmasına sebep olmaktadır. Bu nedenle bağdaki zararlıların ve hasarlarının zamanında tespiti çok önemlidir. Zamanında tespiti sağlamaya yardımcı olan yöntemlerden biri derin öğrenmedir. Bu çalışmada, bir derin öğrenme nesne algılama algoritması olan YOLOv8x modeli ile bazı bağ zararlılarının (Salkım güvesi, Trips, Bağ yaprak uyuzu ve İki noktalı kırmızı örümcek) yaprak ve meyve kısmında oluşturduğu hasarın tespitine yönelik çalışma gerçekleştirilmiştir. 7 farklı sınıftan ve 3500 görüntüden meydana gelen veri seti oluşturulmuştur. Oluşturulan veri seti; YOLOv8(n/s/m/l/x) modelleri ile eğitilmiştir. Eğitim sonucunda, YOLOv8x modeli performans değerleri sırayla; mAP<sub>0.5</sub>, mAP<sub>0.5-0.95</sub>, Kesinlik (Precision), Duyarlılık (Recall), 0,926, 0,648, 0,892 ve 0,903 şeklinde sonuçlar vermiştir. Aynı veri seti, YOLOv7, DETR ve RTMDet modelleriyle de eğitilerek YOLOv8x modeliyle performans karşılaştırmaları yapılmıştır. Karşılaştırma sonucunda bağlarda belirtilen zararlıların oluşturduğu hasarı en iyi tespit eden YOLOv8x modeli olmuştur.</p>

<sup>a</sup> [sahin\\_uygun@hotmail.de](mailto:sahin_uygun@hotmail.de)

<sup>b</sup> <https://orcid.org/0000-0002-9625-9513>

<sup>c</sup> [mmozguven@ankara.edu.tr](mailto:mmozguven@ankara.edu.tr)

<https://orcid.org/0000-0002-6421-4804>

<sup>c</sup> [durdane.yanar@gop.edu.tr](mailto:durdane.yanar@gop.edu.tr)

<https://orcid.org/0000-0003-2517-1538>



## Giriş

Tarım, biyolojik, fiziksel ve kimyasal süreçlerin entegre olduğu karmaşık bir faaliyettir. Ayrıca, tarımsal üretim sırasında kontrol edilemeyen faktörler, hava koşulları, iklim değişiklikleri, toprak özellikleri, hastalıklar ve zararlılar ile çevre kirliliği gibi bir dizi etken tarafından olumsuz etkilenebilmektedir (Ozguven, 2023). İklim değişikliği, bitki hastalıkları ve zararlı türlerinin sayısında artışa neden olmakta ve bu artış, tarım ürünlerinin verimliliğini ciddi şekilde tehdit etmektedir. Bitki hastalık ve zararlıları ile başa çıkılması, tarım ürünlerinin sağlıklı bir şekilde yetiştirilmesi ve ürün veriminin korunması açısından kritik bir öneme sahiptir (Kang ve ark., 2023).

Ülkemiz, bağcılık için elverişli iklim kuşağına sahip olmasıyla kültür asma (Vitis vinifera L.) ve bağcılık geleneğinin ana vatanı olmasıyla öne çıkar. Bu durum, asmanın genetik zenginliği ve eski zamanlardan beri "Asma" olarak bilinen (Vitis sp.) bitkinin yetiştirilmesine olanak tanırken, asma yetiştiriciliği, toprak ve iklimdeki az seçiciliği ve üzüm ile yaprak gibi ürünlerin ekonomik değerlendirilebilirliği sayesinde birçok aile için geçim kaynağı oluşturmaktadır. Ancak, bağlarda ortaya çıkan çeşitli hastalıklar, kalite ve verim düşüklüğüne neden olarak ekonomik sorunlara yol açmaktadır (Karabat, 2014; Altaş ve ark., 2021). Türkiye, dünyanın önde gelen üzüm üreticisi ülkelerinden biridir, ancak bağcılık verimini olumsuz etkileyen en büyük sorunlardan biri bağ hastalıkları ve zararlılarıdır (Altaş ve ark., 2023).

Hastalıkların teşhisi ve hastalık şiddetinin izlenmesi açısından, teknolojik yöntemlerin kullanılması büyük avantajlar sunmakta ve bu yeni yaklaşımlar hızlı, pratik olmakla birlikte ve insan hatalarını da minimize edebilmektedir (Ozguven ve Yanar, 2022). Bu nedenle, bitki hastalıklarının otomatik olarak teşhis edilmesini sağlamak için görüntü işleme ve derin öğrenme gibi teknikler aktif olarak araştırılmaktadır (Ozguven ve Altas, 2022). Bitki hastalık ve zararlılarının tespitinin doğru ve etkili bir şekilde gerçekleştirilmesi için geliştirilen görüntü analiz araçları, uzmanların çıplak gözle yaptığı incelemeler sırasında meydana gelebilecek iş gücü ve zaman kaybını azaltmaya da yardımcı olmaktadır (Uygun ve ark., 2019).

Son yıllarda, yapay zeka, görüntü işleme ve grafik işleme birimlerindeki (GPU) ilerlemeler, bitki koruma ve büyüme alanındaki hassas uygulamaların kapsamını ve etkinliğini artırmaktadır. Özellikle bitki hastalıklarının tespiti ve sınıflandırılmasında, çeşitli yapay zeka yöntemleri kullanılmaktadır. Günümüzde, hızlı, otomatik ve kesin bir sistem geliştirmek amacıyla derin öğrenme son zamanlarda büyük ilgi görmekte ve görüntü sınıflandırma için standart bir teknik haline gelmektedir (Barbedo, 2019; Geetharamani ve Arun, 2019). Yapay zeka tarımsal araştırmalarda önemli bir rol oynayarak bitkisel üretim planlamaları, bitki sınıflandırması, verim tahmini, hastalık ve zararlı tespiti, tarım robotlarının rotalarının belirlenmesi, sera koşullarının yönetimi, işletme kararları, sulama yönetimi, ürün rotasyonu, gübre ve ekipman seçimi, hayvan hastalıklarının teşhisi, yem rasyonlarının hazırlanması ve hayvan davranışlarının analizi gibi birçok alanda araştırmacıların ilgisini çekmektedir ve bu konularda birçok çalışma bulunmaktadır (Terzi ve ark., 2019). Bitki hastalık ve zararlılarının derin öğrenme yöntemiyle belirlenmesi için çeşitli teknikler ve

algoritmalar geliştirilmiş olmasına rağmen, bu alanda hala geliştirme fırsatları mevcuttur (Ozguven ve Adem, 2019).

Farklı nesne algılama algoritmaları kullanılarak gerçekleştirilen bazı bitki hastalık ve zararlı hasarı tespit çalışmaları; 6000 görüntüde (Kaggle veri seti) YOLOv3 model ile mAP<sub>0,5</sub> 0,9 (Mahesh ve Mathew, 2023), 6241 görüntüde (GPD veri seti) GMLDD model ile mAP<sub>0,5</sub> 0,7 (Rashid ve ark., 2023), 820 görüntüde YOLOv5-CA based GDM model ile mAP<sub>0,5</sub> 0,89 (Zhang ve ark., 2022), 2000 görüntüde (Kaggle Plant Pathology Apple veri seti) YOLOv4 model ile mAP<sub>0,5</sub> 0,91 (Roy ve Bhaduri., 2021) ve 3000 (Plant village) görüntüde DBA\_SSD model ile mAP<sub>0,5</sub> %0,92 (Wang ve ark., 2021) olduğu raporlanmıştır.

Bu çalışmada, farklı lokasyonlarda bulunan bağ arazilerinden Salkım güvesi, Trips, Bağ yaprak uyuzu ve İki noktalı kırmızı örümcek gibi önemli bağ zararlılarının yaprak ve meyve kısımlarında neden olduğu hasarların görüntüleri edinilmiştir. Edinilen görüntülerden 7 farklı sınıf oluşturulmuştur. Zararlı hasarlarının tespit edilmesi amacıyla YOLOv8x nesne algılama modeli kullanılmıştır. Oluşturulan veri seti ile farklı boyutları sahip (n,s,m,l) YOLOv8 modelleri eğitilmiş ve en büyük modeli olan YOLOv8x modeli ile performansları karşılaştırılmıştır. Ayrıca çalışmada, farklı nesne algılama modelleriyle performans karşılaştırmaları yapılmıştır. Önerilen yaklaşım, benzer yöntemlerle karşılaştırıldığında önemli ölçüde daha iyi sonuçlar elde etmiştir. Bu araştırmanın ana katkıları, dört farklı bağ zararlısının meydana getirdiği hasarı belirlemek amacıyla büyük bir veri setinin oluşturulması ve kullanılan model ile parametrelerdir.

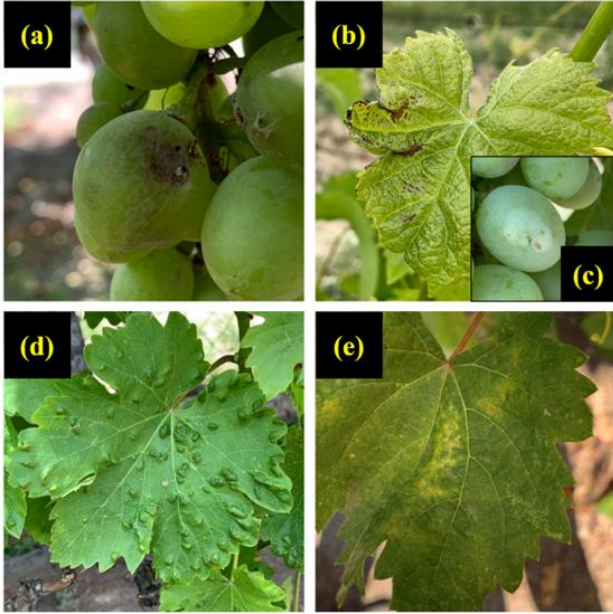
## Materyal ve Yöntem

### Çalışmadaki Bağ Zararlıları

Bağ alanlarında bir dizi zararlı türün varlığı söz konusudur. Bu araştırma, özellikle salkım güvesi, trips, bağ yaprak uyuzu ve iki noktalı kırmızı örümcek gibi en önemli bağ zararlılarının neden olduğu hasarı belirlemeye yönelik olarak gerçekleştirilmiştir. Bu zararlılar bağda; yaprak, meyve, sürgün, tomurcuk ve çiçek gibi aksamalarda hasar oluşturmaktadır. Çalışmada, Salkım güvesi meyve, trips yaprak ve meyve, bağ yaprak uyuzu yaprak, iki noktalı kırmızı örümcek yaprak kısmında oluşturduğu hasarlar incelenmiştir.

Salkım Güvesi (*Lobesia botrana* (Den. et Schiff.)) (Lepidoptera: Tortricidae), bağların başlıca zararlılarından biridir ve ürün kalitesi ve miktarı üzerinde doğrudan etkisi vardır (Şekil 1(a)). Türkiye'de Salkım Güvesi, tüm bağ alanlarında bulunan yaygın bir zararlıdır. Bağ tripsleri (*Anaphothrips vitis* Priener, *Drepanothrips reuteri* Uzel (Thys.: Thripidae)) ise bağlarda sıkça görülen vejetasyon dönemi boyunca ciddi zararlara neden olan önemli zararlılardır. Tripsler ilkbaharda gözler açıldığında ortaya çıkmakta ve yapraklardan özsuyu emerek kurumalarına yol açmaktadırlar, bu da ürün kaybına neden olmaktadır. Tripsler, bağın farklı bölgelerinde rastlanmakta ve Şekil 1(b) ve Şekil 1(c)'de görülen yaprak ve meyve hasarına sebep olmaktadır. Diğer bir zararlı olan Bağ yaprak uyuzu (*Colomerus (=Eriophyes) vitis* Pgst. (Acarina: Eriophyidae)), genellikle asma yapraklarında bulunmaktadır, bazen çiçek tomurcukları ve çiçeklerden de

beslenmektedir. Yapraklarda meydana gelen beslenme, ilkbaharda başlamakta ve geç sonbahara kadar devam etmektedir. Zarar gören yapraklar fotosentezi düzgün bir şekilde gerçekleştirememektedir, bu da Bağ yaprak uyuzu yoğunluğuna bağlı olarak ürün miktarını etkilemektedir (Şekil 1(d)). Çalışmadaki diğer zararlı olan İki noktali kırmızı örümcek (*Tetranychus urticae* Koch. (Acarina: Tetranychidae)), asma yapraklarının renginde değişikliklere yol açarak hasar oluşturmaktadır. Yüksek popülasyonlar yaprakların erken sararmasına ve kurumasına neden olabilmektedir, bu da salkımların güneşe maruz kalmasına ve olumsuz etkilenmesine yol açmaktadır. Ayrıca, asma bitkisi yıldan yıla zayıflamaktadır, bu da ürün kalitesi ve miktarını etkilemektedir (Şekil 1(e)) (Kaplan ve ark., 2008).



Şekil 1. Çalışmada incelenen (a) Salkım Güvesi, (b) Trips yaprak, (c) Trips meyve, (d) Bağ yaprak uyuzu ve (e) İki noktali kırmızı örümcek zararlılarının oluşturduğu hasar örnekleri.

Figure 1. Damages caused by vineyard pests examined in the study; (a) Grapevine Moth damage, (b) Thrips leaf damage, (c) Thrips fruit damage, (d) Vineyard leaf scab damage and (e) Two-Spotted Spider Mite damage.

#### YOLOv8x Model

YOLOv8 (Jocher ve ark., 2023) modeli, çeşitli nesne tespiti görevlerinde kullanılan bir modeldir. YOLOv8, anchor-free bir model kullanarak nesnellik, sınıflandırma ve regresyon görevlerini bağımsız bir şekilde işlemektedir (Terven ve Cordova-Esparza, 2023). Beş farklı modele ayrılan YOLOv8 serisi, ölçekleme parametreleri Çizelge 1’de belirtilmiş olan YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x versiyonlarına sahiptir.

YOLOv8x ağı, Şekil 2’de gösterilen mimariye sahiptir ve bu mimari omurga (Şekil 2a), boyun (Şekil 2b) ve kafa (Şekil 2c) bölümlerini içermektedir. YOLOv8x, giriş görüntüsünden özellik haritaları oluşturmak için CSPDarknet53 (Redmon ve Farhadi, 2018) isimli bir omurga ağı kullanmaktadır. Omurga ve boyun bölümlerinde bulunan C2f (cross-stage partial bottleneck with two convolutions) modülü (Şekil 2d), iki farklı gradyan akışını bir araya getirerek daha güçlü bir gradyan

oluşturmakta ve bilgi akışını kolaylaştırmaktadır. (Bai ve ark., 2023). Omurga kısmında bulunan SPPF (Spatial Pyramid Pooling Fusion) modülü (Şekil 2e), belirli bir şekilde hem seri hem de paralel uzamsal piramit havuzlamayı kullanarak, özellik haritalarının kapsama alanını genişletirken çoklu ölçekli bilgiyi bütünleştirmektedir. Boyun, çeşitli özellikleri bir araya getiren bir bölümdür. YOLOv8x modeli, boyun kısmında PAN-FPN (Li ve ark., 2023) yapısı kullanılarak tasarlanmıştır. PAN yapısı sayesinde YOLOv5 ve YOLOv7 modelleriyle karşılaştırıldığında orijinal performansı korurken, daha hafif bir model elde etmek için yukarı örnekleme sonrasında evrişim işlemi ortadan kaldırmaktadır (Wang ve ark., 2023). Kafa kısmı ise her bir başlık için farklı görevler atanmış kafa tespit bölümünden oluşmaktadır. Bu yapı nesne sınıflandırması ve tahmini sınırlayıcı kutu regresyonu için iki ayrı dalı içermekte ve bu iki görev için özgün kayıp fonksiyonları kullanılmaktadır. Sınıflandırma görevi için İkili Çapraz Entropi Kaybı (Binary Cross-Entropy Loss) (BCE Loss) tercih edilirken, tahmin edilen kutu sınırlayıcı regresyon görevi için (Distribution focal loss) (DFL) (Li ve ark., 2020) ve CIoU (Zheng ve ark., 2020) kullanılmaktadır. Bu tasarım, tespit doğruluğunu artırmayı ve modelin hızlı yakınsamasını hedeflemektedir. Ayrıca, modelin doğruluk performansını artırmak için, örnekler dinamik olarak bir görev atayıcıya (Task-Aligned Assigner) (Feng ve ark., 2021) iletilmektedir. Bu yöntem, modelin tespit performansının daha da artmasına yardımcı olmaktadır (Wang ve ark., 2023).

#### Veri Edinimi

Bu çalışmada kullanılan veri seti farklı tarihlerde, Tokat ve Manisa şehirlerinde bulunan bağ alanlarından Apple iPhone XS akıllı telefon kullanılarak elde edilen 3500 görüntüden oluşturulmuştur. Görüntüler .jpeg formatında 2x optik zoom ile 1173x1173 1:1 formatında edinilmiştir.

#### Veri; Ön İşleme, Etiketleme ve Artırma

Görüntülerin ön işlenmesi, etiketlenmesi ve veri artırma için Roboflow platformu kullanılmıştır. Veri seti etiket isimleri “Sağlıklı yaprak”, “Sağlıklı salkım”, “Bağ yaprak uyuzu”, “Kırmızı örümcek”, “Salkım güvesi”, “Trips yaprak” ve “Trips meyve” olmak üzere 7 sınıf oluşturulmuştur. Çizelge 2’de verildiği gibi veri seti 7:2:1 oranında ayrılmıştır. 1173x1173 piksel boyutundaki görüntüler Roboflow platform üzerinde 640x640 piksel boyutuna dönüştürülmüştür.


Görüntüler sınırlayıcı kutu olarak etiketlenmiştir. Etiketlemenin ardından veri artırma işlemi uygulanmıştır. Şekil 3’te eğitim için ayrılan 2450 görüntü, döndürme veri artırma yöntemleriyle sayısı 7350 (3x) adete çıkarılmıştır.

Çalışmada etiketleme sağlığının daha iyi tespit edilebilmesi için ısı haritası çıkarılmıştır. Isı haritası, bir matrisin her bir elemanın görsel renklerle temsil edildiği veri tablosunun grafiksel bir gösterimidir. Şekil 4’de, sınıflara göre etiketlenmiş bir ısı haritası örneği bulunmaktadır. Etiketli tamamlanan veri seti, çalışmada kullanılan modelin eğitimi için Roboflow platformu üzerinden YOLOv5 PyTorch formatında dışa aktararak bir API oluşturulmuştur.

Çizelge 1. YOLOV8 modelleri için ölçekleme parametreleri (Wang ve ark., 2023).

Table 1. Scaling parameters for YOLOV8 models (Wang ve ark., 2023).

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



Şekil 2. YOLOv8x mimarisi; a) Omurga, b) Boyun, c) Kafa, d) C2f modülü ve e) SPPF modülü  
 Figure 2. YOLOv8x architecture; a) Backbone, b) Neck, c) Head, d) C2f module and e) SPPF module

Çizelge 2. Veri seti yapısı.



Table 2. Dataset structure

Sınıf	Eğitim	Doğrulama	Test
Sağlıklı yaprak	350	100	50
Sağlıklı salkım	350	100	50
Bağ yaprak uyuzu	350	100	50
Kırmızı örümcek	350	100	50
Trips meyve	350	100	50
Trips yaprak	350	100	50
Salkım güvesi	350	100	50
Toplam	2450	700	350

Çizelge 3. YOLOv8x modelin eğitimi için parametre ayarları

Table 3. Parameter settings for training YOLOv8x model

Parametre	Değer
Giriş boyutu	640x640
Epochs	100
Batch-size	8
Momentum	0,937
Öğrenme oranı (lr)	0.01
Optimizer	SGD
Aktivasyon fonksiyonu	SiLU
Weight_decay	0,0005
Warmup_epochs	3
Warmup_momentum	0,8
Warmup_bias_lr	0,1
Kayıp (Loss)	VFL_loss, CIOU_loss + DFL

Şekil 3. Veri artırma  
Figure 3. Data augmentatioŞekil 4. Sınıf bazlı etiket ısı haritası.  
Figure 4. Class-based annotation heatmap.

### Model Eğitimi

YOLOv8x modelin eğitimi için Google Colab notebook kullanılmıştır. Model yazılımı bu notebook üzerinde çalıştırılmıştır. Çalışmada Colab notebook çalıştırmak için Apple Macbook Air 2017 marka model ve MacOS Monterey işletim sistemine sahip bilgisayar kullanılmıştır. Colab notebook üzerinde modelin eğitimi için gerekli GPU Nvidia Tesla A100 (Virtual GPU, 40G) kullanılmıştır. Eğitim için kullanılan YOLOv8x modelin parametre ayarları Çizelge 3'te verilmiştir.

### Model Değerlendirme Göstergeleri

Bu çalışmanın denemelerinde, modelin sınırlayıcı kutu doğruluğunun değerlendirilmesi için  $mAP_{0,5}$  ve  $mAP_{0,5-0,95}$  ölçütleri kullanılmıştır. Bu ölçütler, sınırlayıcı kutu doğruluğunu hesaplamak için Denklem (1) ve Denklem (2) kullanılmıştır.

$$mAP_{0,5} = \frac{1}{n_c} \int_0^1 P(R) dR \quad (1)$$

$$mAP_{0,5-0,95} = avg(mAP_i), i = 0,5:0,05:0,95 \quad (2)$$

Denklem 1 de yer alan, “ $n_c$ ” sınıf sayısını belirtmekte ve “ $P$ ” Kesinlik (Precision) ve “ $R$ ” Duyarlılık (Recall), sınıf sayısı temsil edilirken kullanılmaktadır.  $P$ , Denklem (3) ile hesaplanırken,  $R$  ise Denklem (4) ile hesaplanmaktadır.

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

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

TP (Doğru Pozitif) kavramı burada doğru şekilde saptanan sonuçları ifade etmekte ve  $IoU > 0,5$  olan tahmin kutularının sayısını temsil etmektedir. FP (Yanlış Pozitif) kavramı yanlış şekilde saptanan sonuçları ifade etmekte ve  $IoU$  değeri 0,5 olan tahmin kutularını temsil etmektedir. FN (Arkaplan) ise tahmini olmayan etiketlerin sayısını temsil etmektedir.

## Deneysel Sonuçlar ve Tartışma

Veri setinin oluşturulmasından model sonuçlarının da dahil edildiği aşamaların anlatıldığı Şekil 5'teki genel akış şemasına göre ilk aşama farklı lokasyonlarda verilerin edinimi ile başlamaktadır. Ardından verilere; ön işleme, etiketleme ve veri artırma işlemleri yapılmıştır. Hazır hale getirilen veri seti ile belirlenen parametrelerde modeller eğitilmiştir. Son aşama olarak eğitimi tamamlanan modellerin performans karşılaştırması yapılmıştır.

### Model Sonuçları

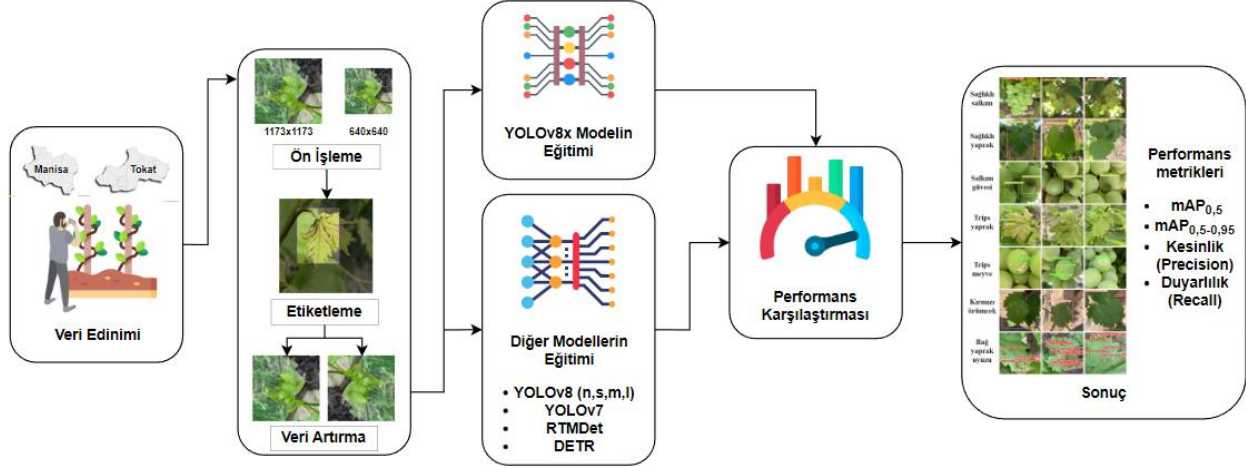
Çalışmada farklı büyüklüklerdeki YOLOv8 modelleri ile Çizelge 3'teki parametreler kullanılarak eğitimler gerçekleştirilmiştir. Çizelge 4'de gösterildiği gibi her modelin performansı değerlendirildiğinde, YOLOv8x modelinin  $mAP_{0,5}$ ,  $mAP_{0,5-0,95}$ , Kesinlik (P) ve Duyarlılık (R) değerlerinin diğer modellerden yüksek çıktığı görülmektedir.

YOLOv8x modelinin sınırlayıcı kutu performansı sınıf bazında değerlendirilmiştir. Çizelge 5 incelendiğinde,

“Sağlıklı salkım” sınıfına ait  $mAP_{0,5}$ ,  $mAP_{0,5-0,95}$ , Kesinlik (P) ve Duyarlılık (R) değerlerinin diğer sınıflardan daha yüksek olduğu görülmektedir. Bu sınıf değerini “Sağlıklı yaprak” ve “Salkım güvesi” sınıfları takip etmektedir. En düşük sınıf performansı ise “Trips yaprak” sınıfı göstermiştir.

Eğitim sonucunda YOLOv8x modelinin her bir sınıfı tespit etme performansını çeşitli kategoriler açısından daha iyi anlaşılması için, Şekil 6'te gösterilen karışıklık matrisi oluşturulmuştur. Belirtilen sınıfların tespiti için eğitilen YOLOv8x modeli, “Sağlıklı salkım”, “Sağlıklı yaprak” ve “Salkım güvesi” sınıflarını en iyi tanımada en iyi performansı göstermiştir ve onu “Kırmızı örümcek” sınıfı takip etmektedir.

Benzer şekilde, bu çalışma, model eğitim sürecinin güvenilirliğini belirlenmesi için Şekil 7'de gösterildiği gibi, modelin eğitim ve doğrulama aşamalarındaki sınırlayıcı kutu (train/box\_loss, val/box\_loss) ve sınıf (train/cls\_loss, val/cls\_loss) kayıp grafikleri verilmiştir. Aynı şekilde model eğitim ve doğrulama sürecinde performans metrikleri  $mAP_{0,5}$ ,  $mAP_{0,5-0,95}$ , Kesinlik (P) ve Duyarlılık (R) grafikleri de verilmiştir. Kayıp grafikleri, incelendiğinde, eğitim ve doğrulama değerlerinin birbirine yakın olması modelin eğitiminin güvenilirliğini göstermektedir. Benzer biçimde 4 algılama ölçütü ( $mAP_{0,5}$ ,  $mAP_{0,5-0,95}$ , Kesinlik (Precision), Duyarlılık (Recall)) çizgilerinin ve eğrilerin birbirine yakın sonuçlar göstermesi sistemin başarılı olduğunu göstermektedir.



Şekil 5. Çalışmanın genel akış şeması  
Figure 5. General flowchart of the study

Çizelge 4. YOLOv8(n/s/m/l/x) modellerinin performans karşılaştırmaları


Table 4. Performance comparisons of YOLOv8(n/s/m/l/x) models

Model	Parametre	Katman	Eğitim süresi	GFLOPs	Tesla A100 maks. GPU kullanımı (G)	$mAP_{0,5}$	$mAP_{0,5-0,95}$	P	R
YOLOv8n	3M	168	17d	8,1	6,3	0,909	0,629	0,881	0,863
YOLOv8s	11M	168	18d	28,5	7,7	0,907	0,625	0,878	0,858
YOLOv8m	25M	218	22d	78,7	10,5	0,922	0,645	0,864	0,895
YOLOv8l	43M	268	28d	164,8	14,5	0,916	0,635	0,883	0,890
YOLOv8x	68M	268	34d	257,4	17,7	0,926	0,648	0,892	0,903

Çizelge 5. YOLOv8x modelinin sınıf bazında performans sonuçları.


Table 5. Class-based performance results of the YOLOv8x model.

Sınıf	Görüntü sayısı	Örnekler (Instances)	P	R	mAP <sub>0,5</sub>	mAP <sub>0,5-0,95</sub>
Genel	620	229	0,892	0,903	0,926	0,648
Sağlıklı yaprak	620	14	0,894	1	0,995	0,898
Sağlıklı salkım	620	14	0,961	1	0,995	0,919
Bağ yaprak uyuzu	620	96	0,867	0,812	0,902	0,400
Kırmızı örümcek	620	25	0,890	0,88	0,875	0,799
Trips meyve	620	24	0,878	0,903	0,920	0,517
Trips yaprak	620	30	0,844	0,724	0,814	0,408
Salkım güvesi	620	26	0,910	1	0,982	0,597




Şekil 6. Karışıklık matrisi.

Figure 6. Confusion matrix



Şekil 7. YOLOv8x modelinin eğitim ve doğrulama veri setlerindeki performans metrik ve kayıp grafikleri.

Figure 7. Performance metric and loss graphs on the training and validation datasets of the YOLOv8x model.



Şekil 8. Modelin çıktı örnekleri (Test veri seti).  
Figure 8. Output samples of the model (Test dataset).



Çizelge 6. YOLOv8x modelinin farklı nesne tespiti modelleri ile performans karşılaştırması.

Table 6. Performance comparison of YOLOv8x model and different object detection models.

Model	Parametre	Eğitim süresi	mAP <sub>0,5</sub>	P	R
DETR	41M	2s	0,704	0,726	0,687
RTMDet	8M	52d	0,881	0,823	0,854
YOLOv7	37M	44d	0,894	0,839	0,888
YOLOv8x	68M	34d	0,926	0,892	0,903

Çizelge 7. Benzer modellerin kullanıldığı literatür çalışmaları ve karşılaştırmalar.

Table 7. Literature studies and comparisons using similar models.

Literatür	Çalışma	Veri seti	Model	mAP <sub>0,5</sub>	P	R
Zhang ve ark., 2022	Bağda Küllleme Hastalığı Tespiti	Oluşturulan veri seti	YOLOv5-CA based GDM	0,895	0,855	0,837
Zhang ve ark., 2023	Tarımsal Zararlıları ve Hastalıkları Tespit Etme	IP102	DCF-YOLOv8	0,608	0,530	0,604
Orchi ve ark., 2023	Bitki Yaprak Hastalıklarının Gerçek Zamanlı Tespiti	PlantDoc	YOLOv8	0,633	0,628	0,630
Cai ve Jiang, 2023	Bitki Hastalıkları Tespiti	PlantDoc	Yolov5+Res2block +SimAM +EIoU	0,550	0,549	0,579
Leng ve ark., 2023	Karmaşık Tarla Ortamlarında Mısır Yaprak Yanıklığının Etkin Tespiti	NLB	CEMLB-YOLO	0,875	0,934	0,793
Vaidya ve ark., 2023	Bitki Hastalıkları Tespiti	PlantDoc	YOLOv7	0,710	0,728	0,685
Bu çalışma	Bazı Bağ Zararlıları Hasarının Tespiti	Oluşturulan veri seti	YOLOv8x	0,926	0,892	0,903

Model eğitiminin ardından oluşturulan veri setinin test bölümü içerisinde örnek çıktılar alınmıştır. Çıktılar; her bir sınıfın tespit sonucunun örnekleri olacak şekilde Şekil 8'de verilmiştir. YOLOv8x modeli; sağlıklı yaprak, sağlıklı salkım ile bağ yaprak uyuzu, kırmızı örümcek, meyvede trips, yaprakta trips ve salkım güvesi hasarlarını doğru bir şekilde bölümlere ayırmış ve tespit etmiştir. Genel olarak model, karmaşık arka plan, farklı aydınlanma koşulları ve görüntü alınmadaki açı değişiklikleri gibi faktörlerden etkilenmeyerek hassas bir performans sergilemiştir.

#### **Farklı Nesne Algılama Modelleriyle Karşılaştırması**

Oluşturulan veri seti, 640 giriş boyutu, 100 epoch sayısı, 8 batch boyutu ve Tesla A100 GPU kullanılarak farklı modeller eğitilmiştir. Sonuçlar Çizelge 6'da verilmiştir ve YOLOv8x modeli, en iyi performansı sergileyerek diğer modelleri geride bırakmıştır. En düşük performans ise DETR Transformer modeli ile elde edilmiştir. Ayrıca bu sonuçlar ile önerilen YOLOv8x modeli ve modelde kullanılan parametreler, tarımsal alanda hastalık, zararlı ve zararlı hasarının tespiti için karşılaştırılan modellere göre daha uygun olduğu ve daha iyi tespit edeceğini göstermiştir.

Önerilen YOLOv8x modelinin, bazı bağ zararlılarının oluşturduğu hasarın tespitindeki etkinliği literatürde kullanılan diğer derin öğrenme modellerinin sonuçlarıyla karşılaştırılmıştır (Çizelge 7). Önerilen yöntem, literatürdeki benzer bazı yöntemlere kıyasla daha üstün sonuçlar sergilemiştir. 2022 ve 2023 yıllarına ait

literatürdeki bazı çalışmalar incelendiğinde, bitki hastalıkları, zararlıları ve hasarlarının teşhisinde YOLO tabanlı derin öğrenme modellerinin tercih edildiği görülmektedir. Bu çalışmada, YOLOv8x derin öğrenme modelinin oluşturulan veri setine uygulanması sonucunda hasar tespiti mAP<sub>0,5</sub> metriği altında şu değerler elde edilmiştir: "Sağlıklı yaprak" 0,995, "Sağlıklı salkım" 0,995, "Bağ yaprak uyuzu" 0,902, "Kırmızı örümcek" 0,875, "Trips meyve" 0,920, "Trips yaprak" 0,814 ve "Salkım güvesi" 0,982. Hasar tespitinde sınıf genelinde mAP<sub>0,5</sub>, 0,926 elde edilmiştir. Bu sonuçlar, tarımsal problemler için uygun derin öğrenme modelinin belirlenmesinin önemine dikkat çekmektedir. Ayrıca, literatürdeki bazı çalışmalarda derin öğrenme modellerinin hazır veri setleri ile eğitildiği gözlemlenmiştir. Fakat bu çalışmada, gerçek arazi koşullarında toplanan verilerle veri seti oluşturulması, çalışmayı özgün kılmıştır.

#### **Sonuç**

Bu çalışma, bağlardaki salkım güvesi, bağ yaprak uyuzu, trips ve iki noktalı kırmızı örümcek zararlılarının, bağdaki yapraklar ve meyveler üzerinde neden olduğu zararın doğal ortamlarda daha etkili bir şekilde tespit edilmesi amacıyla yürütülen bir araştırmanın sonuçlarını sunmaktadır. Çalışmada bağ zararlıların yapraklar ve meyveler üzerindeki hasarını tespit etmek için bu alanda en iyi performans sergileyen modellerden olan YOLOv8x modeli önerilmektedir. Çalışmada sunulan temel bulgular aşağıda özetlenmiştir:

- Tokat ve Manisa şehirlerindeki bağ alanlarından alınan görüntülerle bir veri seti oluşturulmuştur. Bu veri seti, sınırlayıcı kutu olarak etiketlenmiş ve ardından önleme ile veri artırma teknikleri uygulanmıştır.
- Veri seti üzerinde belirlenen parametrelerle yapılan denemeler sonucunda, YOLOv8 modelinin farklı büyüklüklerdeki versiyonları eğitilmiştir. Bu çeşitli model varyasyonları içinde, en üstün performansı sergileyen model YOLOv8x olarak belirlenmiştir.
- Çalışmada ayrıca, YOLOv7, RTMDet ve DETR gibi farklı nesne algılama modelleriyle de eğitimler gerçekleştirilmiş ve bu modellerin performansları YOLOv8x modeli ile karşılaştırılmıştır. Karşılaştırma sonuçlarına göre, en üstün performansı YOLOv8x modeli sergilemiştir.

Deney sonuçları, çalışmanın veri setinin, model parametrelerinin ve YOLOv8x modelinin bağ zararlılarının yaprak ve meyve kısımlarında neden olduğu hasarı tespit etme konusunda büyük uygulama potansiyeline sahip olduğunu göstermektedir. Gelecekte, bu algoritmaların daha da geliştirilmesiyle daha hassas tespit sistemleri oluşturulabilir ve bu sistemler tarım robotlarıyla entegre edilebilir.

## Kaynaklar

Altaş, Z., Özgüven, M. M., & Dilmaç, M. (2021). Görüntü işleme teknikleri ile bağ yaprak uyuzu hasarının belirlenmesi. *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, Volume 10:3:77-87

Altaş, Z., Özgüven, M. M., & Adem, K. (2023). Automatic detection and classification of some vineyard diseases with Faster R-CNN model. *Turkish Journal of Agriculture - Food Science and Technology*, 11(1), 97-103. <https://doi.org/10.24925/turjaf.v11i1.97-103.5665>

Bai, R., Shen, F., Wang, M., Lu, J., & Zhang, Z. (2023). Improving detection capabilities of YOLOv8-n for small objects in remote sensing imagery: Towards Better Precision with Simplified Model Complexity. (2023) DOI: <https://doi.org/10.21203/rs.3.rs-3085871/v1>

Barbedo, J. G. A. (2019). Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, 180:96-107

Cai, H., & Jiang, J. (2023). An improved plant disease detection method based on YOLOv5. 2023 15th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC) | 979-8-3503-2617-8/23/\$31.00 ©2023 IEEE | DOI: 10.1109/IHMSC58761.2023.00062

Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., & Zagoruyko, S. (2020). End-to-end object detection with transformers. *Computer Vision and Pattern Recognition (cs.CV) 2020*. <https://doi.org/10.48550/arXiv.2005.12872>

Feng, C., Zhong, Y., Gao, Y., Scott, M. R., & Huang, W. (2021). TOOD: Task-Aligned one-stage object detection. In *Proceedings of the 2021 IEEE International Conference on Computer Vision (ICCV)*, Montreal, QC, Canada, 10-17 October 2021; pp. 3490-3499

Geetharamani, G., & Arun, P. J. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers and Electrical Engineering*, 76:323-338

Jocher, G., Chaurasia, A., & Qiu, J. (2023). "YOLO by Ultralytics." <https://github.com/ultralytics/ultralytics>. (Erişim tarihi: 25.10.2023)

Kang, J., Zhao, L., Wang, K., & Zhang, K. (2023). Research on an improved YOLOv8 image segmentation model for crop pest. *Advances in Computer, Signals and Systems Clausius Scientific Press, Canada*. DOI: 10.23977/acss.2023.070301. ISSN 2371-8838 Vol. 7 Num. 3

Kaplan, C., Zeki, C., Çakırbay, F., Çetin, G., Öztürk, N., Altındışli, Ö., & Kahveci, Y. (2008). *Meyve ve bağ zararlıları. Zirai Mücadele Teknik Talimatları Cilt IV. Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü Bitki Sağlığı Araştırmaları Daire Başkanlığı*

Karabat, S. (2014). Türkiye ve dünya bağcılığı. *Apelasyon*, ISSN:2149-4908. <http://apelasyon.com/Yazi/33-dunya-ve-turkiye-bagciligi> (Erişim Tarihi: 08.12.2023)

Leng, S., Musha, Y., Yang, Y., & Feng, G. (2023). CEMLB-YOLO: Efficient detection model of maize leaf blight in complex field environments. *Appl. Sci.* 2023, 13, 9285. <https://doi.org/10.3390/app13169285>

Li, X., Wang, W., Wu, L., Chen, S., Hu, X., Li, J., Tang, J., & Yang, J. (2020). Generalized Focal Loss: Learning qualified and distributed bounding boxes for dense object detection. *arXiv 2020*, arXiv:2006.04388

Li, S., Liu, S., Cai, Z., Liu, Y., Chen, G., & Guoqing, G. (2023). TC-YOLOv5: rapid detection of floating debris on raspberry Pi 4B. *Journal of Real-Time Image Processing* (2023) 20:17. <https://doi.org/10.1007/s11554-023-01265-z>

Lyu, C., Zhang, W., Huang, H., Zhou, Y., Wang, Y., Liu, Y., Zhang, S., & Che, K. (2022). RTMDet: An empirical study of designing real-time object detectors. *Computer Vision and Pattern Recognition*. <https://doi.org/10.48550/arXiv.2212.07784>

Mahesh, T. Y., & Mathew, M. P. (2023). Detection of bacterial spot disease in bell pepper plant using YOLOv3, IETE *Journal of Research*, DOI: 10.1080/03772063.2023.2176367

Orchi, H., Sadik, M., Khaldoun, M., & Sabir, E. (2023). Real-time detection of crop leaf diseases using enhanced YOLOv8 algorithm. *International Wireless Communications and Mobile Computing (IWCMC) 2023* | 979-8-3503-3339-8/23/\$31.00 ©2023 IEEE | DOI: 10.1109/IWCMC58020.2023.10182573

Ozguven, M., & Adem, K. (2019). Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A: Statistical Mechanics and its Applications*, 535(2019), 122537. doi: 10.1016/j.physa.2019.122537

Ozguven, M. M., & Altas, Z. (2022). A new approach to detect mildew disease on cucumber (*Pseudoperonospora cubensis*) leaves with image processing. *J Plant Pathol*. <https://doi.org/10.1007/s42161-022-01178-z>

Ozguven, M. M., & Yanar, Y. (2022). The technology uses in the determination of sugar beet diseases. In: Misra, V., Srivastava, S., Mall, A.K. (eds) *Sugar Beet Cultivation, Management and Processing*. Springer, Singapore. [https://doi.org/10.1007/978-981-19-2730-0\\_30](https://doi.org/10.1007/978-981-19-2730-0_30)

Ozguven, M. M. (2023). The digital age in agriculture. *CRC Press Taylor & Francis Group LLC*. ISBN 978-103-23-8577-8

Rashid, J., Khan, I., Ali, G., Rehman, S. U., Alturise, F., & Alkhalifah, T. (2023). Real-time multiple guava leaf disease detection from a single leaf using hybrid deep learning technique. *Computers, Materials & Continua*, 74(1), 1235-1257. <https://doi.org/10.32604/cm.c.2023.032005>

Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. *arXiv 2018*, arXiv:1804.02767

Roy, A. M., & Bhaduri, J. (2021). A deep learning-enabled multi-class plant disease detection model based on computer vision. *AI 2021*, 2, 413-428. <https://doi.org/10.3390/ai2030026>

Terven, J. R., & Cordova-Esparza, D. M. (2023). A comprehensive review of yolo: from yolov1 and beyond. *arXiv:2304.00501v4 [cs.CV]*

- Terzi, İ., Özgüven, M. M., Altaş, Z., & Uygun, T. (2019). Tarımda yapay zeka kullanımı. International Erciyes Agriculture, Animal Food Sciences Conference 24-27 April 2019- Erciyes University- Kayseri/Turkey.
- Uygun, T., Ozguven, M. M., & Yanar, D. (2020). A new approach to monitor and assess the damage caused by two-spotted spider mite. *Experimental and Applied Acarology*, 82(3), 335-346. <https://doi.org/10.1007/s10493-020-00561-8>
- Vaidya, S., Kavthekar, S., & Joshi, A. (2023). Leveraging YOLOv7 for plant disease detection. 2023 4th International Conference on Innovative Trends in Information Technology (ICITIT) | 978-1-6654-9414-4/23/\$31.00 ©2023 IEEE | DOI: 10.1109/ICITIT57246.2023.10068590
- Wang, J., Yu, L., Yang, J., & Dong, H. (2021). DBA\_SSD: A novel end-to-end object detection algorithm applied to plant disease detection. *Information* 2021, 12, 474. <https://doi.org/10.3390/info12110474>
- Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. Institute of Information Science, Academia Sinica, Taiwan. <https://doi.org/10.48550/arXiv.2207.02696>
- Wang, G., Chen, Y., An, P., Hong, H., Hu, J., & Huang, T. (2023). UAV- YOLOv8: A small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios. *Sensors* 2023, 23, 7190. <https://doi.org/10.3390/s23167190>
- Zhang, Z., Qiao, Y., Guo, Y., & He, D. (2022). Deep learning based automatic grape downy mildew detection. *Front. Plant Sci.* 13:872107. doi: 10.3389/fpls.2022.872107
- Zhang, L., Ding, G., Li, C., & Li, D. (2023). DCF-Yolov8: An improved algorithm for aggregating low-level features to detect agricultural pests and diseases. *Agronomy* 2023, 13, 2012. <https://doi.org/10.3390/agronomy13082012>
- Zheng, Wang, P., Liu, W., Li, J., Ye, R., & Ren, D. (2020). Distance-IoU loss: Faster and better learning for bounding box regression. In Proceedings of the AAAI Conference on Artificial Intelligence, New York, NY, USA, 7–12 February 2020; pp. 12993–13000