

**LJAR**Lapseki Meslek Yüksekokulu Uygulamalı Bilimler Dergisi
https://ljar.dergi.comu.edu.tr

YOLOv8 Tabanlı 2B Nesne Tespiti ve Işın İzleme Entegrasyonu ile Fotogrametrik Ağaç Modeli Üzerinde Şeftali Meyvelerinin Coğrafi Referanslı 3B Konumlandırılması

YOLOv8-Based 2D Detection and Ray-Casting Integration for Georeferenced 3D Localization of Peach Fruits on a Photogrammetric Tree Model

Canan ULAŞ**Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü*

MAKALE BİLGİSİ

Araştırma Makalesi

Geliş Tarihi: 22.12.2025

Kabul Tarihi: 06.04 2026

Anahtar Kelimeler:

Derin öğrenme

Nesne tespiti

Fotogrametri

ÖZ

Bu çalışmada, tarımsal alanlarda şeftali meyvelerinin otomatik tespiti ve üç boyutlu gerçek dünya konumlarının belirlenmesine yönelik derin öğrenme ve fotogrametri tabanlı bütünlük bir yöntem sunulmaktadır. İHA ve yer tabanlı kameralarla farklı bakış açıları ve aydınlatma koşullarında elde edilen görüntüler ve açık kaynaklı hazırlanan benzer veri setleri ile zenginleştirilerek oluşturulan veri seti 3463 adet etiket ile YOLOv8 formatında hazırlanmıştır. Bu veri seti ile eğitilen YOLOv8 modeli kullanılarak şeftali meyvelerinin iki boyutlu tespiti görüntüler üzerinde gerçekleştirilmiştir. Model performansı doğrulama verileri üzerinde mAP50 ve mAP50-95 değerleri sırasıyla %84,62 ve %60,33 olarak elde edilmiştir. 2B tespit sonuçları, kamera dış yönelme parametreleri kullanılarak ışın izleme yöntemiyle fotogrametrik 3B modele aktarılmıştır. Toplam 340 ışıktan 268'inin mesh yüzeyiyle kesiştiği belirlenmiş, aynı meyveye ait çoklu kesişimler DBSCAN tabanlı kümeleme yöntemiyle elimine edilmiştir. Sonuç olarak, ağaç üzerinde bulunan 14 şeftaliden 13'ü 3B model üzerinde konumlandırılmıştır; tespit edilemeyen meyvenin yoğun yaprak örtüsü nedeniyle görüntülerde görünür olmadığı gözlemlenmiştir. Meyvelerin mekânsal konumları; kullanılan 3B altlık modelin üretim aşamasında ışın demeti blok dengelemesi ve Yer Kontrol Noktaları (YKN) kullanılarak ITRF96 (TM27) direkt olarak referans koordinat sisteminde elde edilmiştir. Önerilen yöntem, literatürde çoğunlukla ayrı ayrı ele alınan 2B nesne tespiti ile 3B mekânsal konumlandırma süreçlerini tek bir otomatik iş akışında birleştirilerek, tarımsal ürünlerin uzaysal dağılımının santimetre mertebesinde belirlenmesine olanak sağlamaktadır. Bu yönüyle çalışma; ürün sayımı, verim analizi ve hassas tarım uygulamaları için yenilikçi, uygulanabilir ve yüksek doğruluklu bir çözüm sunmaktadır.

*Sorumlu Yazar:
ulas.canann@gmail.com

ARTICLE INFO

Research Article

Received 22.12.2025

Accepted: 06.04 2026

Keywords:

Deep learning

Object detection

Photogrammetry

ABSTRACT

This study presents an integrated method based on deep learning and photogrammetry for the automatic detection of peach fruits in agricultural fields and the determination of their three-dimensional real-world locations. The dataset, enriched with images obtained from UAV and ground-based cameras at different viewing angles and lighting conditions, as well as similar datasets prepared from open sources, was prepared in YOLOv8 format with 3463 labels. Using the YOLOv8 model trained with this dataset, two-dimensional detection of peach fruits was performed on the images. Model performance on test data yielded mAP50 and mAP50–95 values of 84.62% and 60.33%, respectively. The 2D detection results were transferred to a photogrammetric 3D model using ray tracing with camera orientation parameters. It was determined that 268 of the total 340 rays intersected with the mesh surface, and multiple intersections belonging to the same fruit were eliminated using the DBSCAN-based clustering method. As a result, 13 of the 14 peaches on the tree were located on the 3D model; it was observed that the undetected fruit was not visible in the images due to dense leaf cover. The spatial locations of the fruits were obtained directly in ITRF96 (TM27) reference coordinate system as a result of Bundle Block Adjustment by using Ground Control Points (GCPs). The proposed method combines the processes of 2D object detection and 3D spatial localization, which are mostly addressed separately in the literature, into a single automated workflow, enabling the determination of the spatial distribution of agricultural products at the centimeter level. In this regard, the study offers an innovative, applicable, and highly accurate solution for crop counting, yield analysis, and precision farming applications.

GİRİŞ

Tarımsal üretimde dijitalleşme süreci, özellikle meyve tespiti, ürün sayımı ve verim analizi gibi görevlerde görüntü tabanlı yöntemlerin kullanımını giderek yaygınlaştırmaktadır. Artan nüfus baskısı ve iş gücü maliyetleri, tarımsal üretim süreçlerinde daha hızlı, daha nesnel ve tekrarlanabilir ölçüm yöntemlerine olan ihtiyacı artırmaktadır. Bu bağlamda, insansız hava araçları (İHA) ve yer tabanlı görüntüleme sistemleri ile elde edilen verilerin, derin öğrenme tabanlı nesne tespiti modelleriyle analiz edilmesi, tarımsal gözlem ve değerlendirme çalışmalarında önemli bir araştırma alanı hâline gelmiştir.

Şeftali gibi görece küçük boyutlu, yaprak örtüsü içerisinde kısmen gizlenebilen meyveler, YOLO gibi görüntü tabanlı tespit sistemleri açısından zorlu hedefler oluşturmaktadır. YOLO (You Only Look Once), tek bir evrişimli sinir ağı (CNN) kullanarak görüntünün tamamını tek bir geçişte analiz eden ve nesnelerin konumları ile sınıf olasılıklarını eş zamanlı olarak hesaplayan, yüksek hızlı gerçek zamanlı bir nesne tespiti algoritmasıdır (Redmon vd., 2016). Özellikle doğal tarım sahalarında değişken aydınlatma koşulları, karmaşık arka plan yapısı ve görüş açılarına bağlı örtüşmeler, tespit doğruluğunu doğrudan etkilemektedir. Bu nedenle, şeftali tespiti gibi uygulamalarda yalnızca yüksek doğruluklu iki boyutlu (2B) algılama yeterli olmamakta; elde edilen tespitlerin mekânsal bağlam içerisinde anlamlandırılabilmesi de önem kazanmaktadır.

Literatürde derin öğrenme tabanlı nesne tespiti yöntemlerinin tarımsal uygulamalarda yaygın olarak kullanıldığı görülmektedir. YOLO ailesine ait farklı sürümler (YOLOv4, YOLOv5, YOLOv7) ile çilek (Nergiz 2023), kamkat (Gündüz 2023) ve benzeri meyvelerin 2B görüntüler üzerinde başarıyla tespit edildiği çalışmalar mevcuttur. Bu çalışmalar, derin öğrenme mimarilerinin tarımsal sahnelerde yüksek tespit başarımı sağlayabildiğini göstermektedir. Bununla birlikte, mevcut çalışmaların büyük çoğunluğu, tespit sonuçlarını yalnızca görüntü düzleminde değerlendirmekte ve meyvelerin üç boyutlu (3B) mekânsal konumlarıyla ilişkilendirilmesine sınırlı ölçüde odaklanmaktadır. Başka bir ifadeyle, literatürde 2B nesne tespiti ile 3B mekânsal konumlandırmanın bütüncül bir sistem içerisinde otomatik olarak ilişkilendirildiği uygulamaların sayısı sınırlıdır. Bu çalışma, söz konusu literatür boşluğunu hedefleyerek, tarımsal alanlardaki şeftali meyvelerinin ağaç üzerindeki konumlarının hem 2B hem de 3B ortamda yüksek metrik doğrulukla belirlenmesini amaçlayan özgün bir yaklaşım sunmaktadır. Çalışma kapsamında araziden toplanan özgün görüntülerin açık kaynaklı benzer veri setleriyle hibrit hale getirilmesiyle oluşturulan zenginleştirilmiş veri seti, derin öğrenme algoritmasının ağaç üzerindeki meyve tespiti performansını maksimize etmiştir. Elde edilen 2B verilerin 3B uzaya aktarılmasında fotogrametri biliminden faydalanılmıştır. Fotogrametri, fiziksel nesnelerin ve çevrenin konum, boyut ve şekil gibi geometrik özelliklerini, fotoğraflar üzerinden yapılan hassas ölçümlerle 3B olarak elde etme teknolojisidir (Wolf ve Dewitt, 2000). Bu çalışmada fotogrametri, arazinin santimetre hassasiyetinde 3B modelinin üretilmesi amacıyla kullanılmıştır. Fotogrametrik ışın demeti blok dengelemesi (bundle block adjustment) yöntemiyle üretilip, Yer Kontrol Noktaları (YKN) yardımıyla doğrudan ITRF96 gerçek dünya koordinat sisteminde elde edilen 3B ağaç modeli üzerinde; 2B görüntülerden elde edilen tespit pikselleri Işın İzleme (Ray Casting) algoritması kullanılarak üç boyutlu uzaya izdüşürülmüştür. Çalışmanın en özgün yanı; derin öğrenme çıktılarının yalnızca görsel bir katman olarak kalmayıp, santimetre hassasiyetinde mutlak yöneltmesi yapılmış bu fotogrametrik altlık sayesinde harici bir koordinat dönüşümüne ihtiyaç duymaksızın doğrudan gerçek dünya koordinatlarında elde edilmesidir. Bu bağlamda çalışma, şeftali meyvelerinin tespitini salt görsel bir veri olmaktan çıkararak; elde edilen sonuçları hassas tarım, verim analizi ve rekolte tahmini uygulamalarında doğrudan kullanılacak nitelikte metrik, coğrafi referanslı ve güvenilir bir mühendislik verisine dönüştürmektedir.

1. LİTERATÜR TARAMASI

Görüntü işleme ve nesne tespiti alanlarında derin öğrenme temelli yaklaşımlar, son yıllarda hem akademik çalışmalarda hem de gerçek zamanlı uygulamalarda yoğun şekilde kullanılmaya başlanmıştır. Bu yaklaşımlar özellikle tarım, güvenlik, savunma, ulaşım ve çevre izleme gibi çok çeşitli alanlarda etkin çözümler sunmaktadır.

Mobil sistemlerle entegre nesne tespitine yönelik çalışmalardan biri (Mohammad 2020) tarafından gerçekleştirilmiştir. Bu çalışmada YOLOv3 algoritması stereo kameralar ile birleştirilerek robotik sistemlere entegre edilmiş, derinlik bilgisinden faydalanılarak hem sabit hem de hareketli nesnelerin tespiti sağlanmıştır. Çalışmanın güçlü yönü, nesne tespitinin derinlik bilgisiyle desteklenerek mobil platformlarda uygulanabilirliğinin gösterilmesidir. Bununla birlikte, yöntem daha çok kontrollü deneysel koşullarda değerlendirilmiş olup, doğal tarım ortamlarındaki karmaşık sahne yapıları bu çalışmanın kapsamı dışında kalmıştır.

Botanik alanda gerçekleştirilen çalışmalardan (Şensu, 2024), hazır bir çiçek veri seti kullanarak bitki sınıflandırması gerçekleştirmiştir. Çalışmada makine öğrenimi algoritmaları belirli bitki türlerinde yüksek doğruluk değerlerine ulaşmıştır. Ancak bu çalışma, nesne tespitinden ziyade sınıflandırmaya odaklanmakta olup, nesnelerin görüntü içerisindeki konumsal dağılımını veya mekânsal ilişkilerini ele almamaktadır. Bu yönüyle tarımsal hasat planlaması ya da saha bazlı uygulamalar için sınırlı bir kapsam sunmaktadır.

Tarımsal zararlı tespiti alanında (Biçgi ve Karaca İ. 2022) tarafından gerçekleştirilen çalışmada, YOLOv4 algoritması kullanılarak patates böceği ve larvalarının bitki üzerindeki tespiti yapılmıştır. 1024×1024 çözünürlükte eğitilen model ile %87,53 mAP ve %87,53 kesinlik ve %0,81 F1 skoru değerleri elde edilmiştir. Ayrıca sarı yapışkan ve çukur tuzaklarla yapılan saha kontrolleri sonucunda, YOLOv4'ün tarımsal erken uyarı sistemleri ve popülasyon izleme amacıyla kullanılabileceği ortaya konmuştur. Bununla birlikte, çalışmada tespit edilen nesnelerin yalnızca görüntü düzlemindeki konumları ele alınmış, mekânsal veya üç boyutlu konumlandırmaya yönelik bir değerlendirme yapılmamıştır.

YOLO mimarisinin meyve tespiti ve sınıflandırmasındaki başarısını ortaya koyan çalışmalardan biri (Nergiz 2023) tarafından gerçekleştirilmiştir. YOLOv7 algoritması kullanılarak çilek meyvesinin farklı olgunluk evreleri sınıflandırılmış ve Strawberry-DS veri seti ile yapılan deneylerde “red” sınıfı için %80'in üzerinde doğruluk elde edilmiştir. Bu çalışma, sınırlı veri setleriyle dahi derin öğrenme tabanlı modellerin anlamlı sonuçlar üretebileceğini göstermesi açısından önemlidir. Benzer şekilde (Gündüz 2023), kamkat meyvesi için YOLOv7 mimarisini kullanarak %93 doğruluk ve 35 FPS değerine ulaşmıştır. Her iki çalışma da gerçek zamanlı performans açısından güçlü sonuçlar sunmakla birlikte, sabit kamera düzenekleriyle gerçekleştirilmiş ve doğal ağaç ortamlarındaki yoğun örtüşme ve arka plan karmaşıklığı sınırlı düzeyde ele alınmıştır.

İnsansız hava aracı (İHA) tabanlı çalışmalara bakıldığında, (Ataberdiev 2022) tarafından gerçekleştirilen çalışmada İHA görüntüleri kullanılarak Rassal Orman yöntemi ile farklı bitkiler yüksek doğrulukla ayrılmıştır. Çalışma, bitki ayrımı ve haritalama açısından etkili sonuçlar sunmaktadır. Ancak kullanılan yöntemin derin öğrenme tabanlı olmaması ve meyve bazlı nesne tespitine odaklanmaması, çalışmanın tarımsal ürün tespiti bağlamında sınırlı kalmasına neden olmaktadır.

Ulaşım alanında (Albayrak 2021), İHA'lardan elde edilen görüntüleri YOLO ve Mask R-CNN modelleri ile analiz ederek trafik yoğunluğu ve otopark doluluk oranlarını tespit etmiştir. Farklı irtifalardan alınan görüntülerle yapılan bu analiz, derin öğrenme tabanlı nesne tespitinin şehir içi trafik yönetiminde kullanılabilirliğini ortaya koymuştur. Benzer şekilde (Usta, 2022), YOLOv3 algoritmasını kullanarak İHA görüntülerinde insan ve araç tespiti gerçekleştirmiş; farklı çevresel koşullara karşı modelin dayanıklılığını test etmiştir. (Toroman 2018) ise Stanford Drone Dataset'inden yararlanarak oluşturduğu veri seti ile yaya ve nesne

tespitine yönelik bir sistem geliştirmiş ve derin öğrenmenin trafik kontrolü ile arama-kurtarma gibi alanlarda uygulanabilirliğini göstermiştir. Bu çalışmalar, İHA tabanlı görüntülerde nesne tespiti başarısını ortaya koymakla birlikte, tarımsal sahnelerle özgü görsel zorlukları doğrudan ele almamaktadır. Bununla birlikte, söz konusu çalışmalar ağırlıklı olarak kentsel ve düzenli sahne yapılarında elde edilen İHA görüntülerine dayanması olup, bitki örtüsü yoğunluğu, düzensiz arka plan yapısı, ışık koşullarındaki ani değişimler ve nesne örtüşmesi gibi tarımsal ortamlarda sıkça karşılaşılan görsel zorlukların değerlendirme kapsamı dışında kalmıştır.

Daha güncel çalışmalarda; (Sıkar ve Bozatalı 2025), tarafından YOLOv9 algoritmasının trafik sayımlarındaki uygulanabilirliği incelenmiş ve mimarinin trafik yönetimi verimliliğini artırabileceği gösterilmiştir. Savunma ve güvenlik alanında ise (Atmaca 2024), YOLOv9 kullanarak gerçek zamanlı güvenlik kamerası görüntülerinden suçun önceden tespitine yönelik bir erken uyarı sistemi geliştirmiştir. Bu çalışmalar, YOLO mimarisinin ileri sürümlerinin yüksek doğruluk ve gerçek zamanlı performans sunduğunu ortaya koymaktadır.

Tarımsal meyve tespitine yönelik mimari iyileştirme çalışmalarından biri (Li, vd 2023) tarafından sunulmuştur. Bu çalışmada, geleneksel YOLOv5 mimarisi ASFF (Adaptive Spatial Feature Fusion) modülü ile iyileştirilerek çok aşamalı bir çilek tespit algoritması sunulmuştur. YOLOv5-ASFF, yoğun meyve dağılımı ve gölgeleme gibi çevresel zorlukları aşarak akıllı çilek tarlası yönetiminde verim tahmini ve hasat planlamasına teknik destek sağlayabilecek potansiyele sahiptir bu yönüyle de klasik YOLOv5 mimarisine göre anlamlı performans iyileştirmeleri sağlamıştır. Bununla birlikte, çalışma iki boyutlu nesne tespiti ile sınırlı kalmış ve meyvelerin mekânsal konumlarının belirlenmesine yönelik bir analiz sunmamıştır.

Villalobos-Salazar ve ark. (2026) tarafından gerçekleştirilen çalışmada, artan dünya nüfusuna bağlı olarak yükselen gıda talebine karşılık tarımsal üretimde yaşanan kayıpların azaltılmasına yönelik olarak, YOLOv8 tabanlı gerçek zamanlı bir tespit sistemi önerilmiştir. Çalışmada, yaygın olarak Lahana olarak bilinen Brassica oleracea var capitata L. bitkisinde Hellula undalis zararlısının neden olduğu yaprak hasarlarının belirlenmesi amaçlanmış ve veri seti, drone ile kaydedilen videolardan elde edilen 1981 adet hasarlı ve eş sayıda hasarsız yaprak görüntüsünden oluşturulmuştur. Model, bu veri seti ile eğitilmiş ve serada otonom olarak hareket eden drone sistemi, SLAM tabanlı yönlendirme ile gerçek zamanlı tespit gerçekleştirmiştir. Elde edilen sonuçlara göre sistem %60 tespit hassasiyeti sağlamış ve özellikle bitkinin büyümesinin ikinci haftasından itibaren erken zararlı belirtilerinin tespitinde etkili olduğu belirlenmiştir. Bu çalışma, tarımsal görüntü işleme uygulamalarında gerçek zamanlı tespit öneminin ortaya koymaktadır.

(Erşahin ve Keskin 2025), mango, badem, üzüm ve elma görüntülerinden oluşan birden fazla tarımsal veri seti üzerinde farklı derin öğrenme tabanlı nesne tespit mimarilerinin performanslarını karşılaştırmalı olarak incelemiştir. Çalışmada, her bir meyve türü için ayrı veri setleri kullanılarak modellerin tespit doğruluğu ve genellenebilirliği değerlendirilmiş; elde edilen sonuçlar RetinaNet mimarisinin, özellikle sınıf dengesizliğinin bulunduğu veri setlerinde, diğer mimarilere kıyasla daha tutarlı ve göreceli olarak daha yüksek başarı sağladığını ortaya koymuştur. Bu yönüyle çalışma, farklı meyve türlerinde mimari tercihinin performans üzerindeki etkisini nesnel olarak göstermesi açısından literatüre önemli bir katkı sunmaktadır. Bununla birlikte, çalışmada değerlendirme ağırlıklı olarak model mimarileri arasındaki nicel karşılaştırmalarla sınırlı kalmış, veri setlerinin sahne karmaşıklığı, arka plan çeşitliliği veya doğal ortam koşullarının model performansına etkisi ayrıntılı olarak ele alınmamıştır. Bu durum, ilerleyen çalışmalarda mimari performansının farklı görsel koşullar ve saha gerçekliğine daha yakın senaryolar altında yeniden değerlendirilmesi gerekliliğine işaret etmektedir.

Fotogrametri ve 3B modelleme alanında (Gülmez 2024) tarafından yapılan çalışmada, İHA ve yersel fotogrametri yöntemlerinin entegrasyonu ile yüksek hassasiyetli bina modelleme süreçleri incelenmiştir. Hareketten Nesne Oluşturma (SfM) algoritması kullanılarak yürütülen bu çalışma; karmaşık yapıların üst örtü detayları için İHA verilerini, cephe detayları için ise yersel görüntüleri birleştirerek bütüncül bir model üretmesi bakımından önem taşımaktadır. Analiz sonuçlarında elde edilen 2 cm altındaki konumsal doğruluk değerleri, fotogrametrik veri birleştirme tekniklerinin metrik güvenilirliğini kanıtlamaktadır. Bu çalışma hem

hava hem de yersel görüntülerin hibrit kullanımına odaklanmasıyla, tarımsal alanlardaki ağaçların dal ve yapraklarını İHA yardımıyla gövde detaylarını ise kamera kullanarak modelleyen güncel araştırmalarla metodolojik olarak doğrudan paralellik göstermektedir.

(Alami ve Remondino 2025) tarafından yürütülen çalışmada, hava fotogrametrisi ile üretilen nokta bulutlarının sınıflandırılmasında geleneksel denetimli 3B derin öğrenme ağı ile eğitim gerektirmeyen açık sözlüklü (open-vocabulary) yöntemler karşılaştırmalı olarak incelenmiştir. Geleneksel modellerin yoğun etiketli veri ihtiyacına ve sabit sınıf kısıtlamalarına karşın; önerilen esnek strateji, nesneleri önce 2B görüntüler üzerinde tespit etmekte ve ardından kamera parametreleri yardımıyla bu tespitleri 3B uzaya yansıtmaktadır. Analiz sonuçları, denetimli yöntemlerin nesne sınırlarını belirlemede geometrik olarak daha hassas olduğunu; ancak 2B'den 3B'ye yansıtma tabanlı yaklaşımların etiketleme maliyetini ortadan kaldırarak sahne anlamlandırma süreçlerinde güçlü, dinamik ve uygulanabilir bir alternatif sunduğunu ortaya koymaktadır.

(Hajjaji vd. 2025) tarafından yapılan çalışmada, palm ağacı görüntülerinden oluşan bir veri seti üzerinde YOLOv5 (YOLOv5-6l, YOLOv5-L ve YOLOv5-L-HighAug) ile YOLOv8 (YOLOv8-HighAug) modelleri karşılaştırmalı olarak değerlendirilmiştir. Elde edilen bulgulara göre, YOLOv8-HighAug modeli 0.88 Ortalama Hassasiyet (AP), 0.87 kesinlik (precision) ve 0.86 duyarlılık (recall) değerleriyle en yüksek performansı sergilerken; YOLOv5-L-HighAug modeli de 0.83'lük AP@50 değeri ile kaynak verimliliği ve tespit hassasiyeti arasında başarılı bir denge kurmuştur. Sonuç olarak, İHA ve derin öğrenme teknolojilerinin entegrasyonunun insan hatalarını azaltıp veri toplama hızını artırarak, palm endüstrisinde karar verme, kaynak optimizasyonu ve sürdürülebilirlik süreçlerine doğrudan katkı sağladığı ortaya konmuştur.

Tüm bu çalışmalar ışığında incelenen literatür, derin öğrenme tabanlı nesne tespiti yaklaşımlarının ulaşımın güvenliğe ve tarıma kadar geniş bir uygulama alanına sahip olduğunu ortaya koymaktadır. Genel olarak değerlendirildiğinde, literatürde YOLO tabanlı nesne tespit algoritmalarının hem tarımsal hem de endüstriyel uygulamalarda yüksek doğruluk ve hız sağladığı açıkça görülmektedir. Ancak mevcut çalışmaların büyük çoğunluğu sabit kamera sistemleri veya kontrollü ortamlarda gerçekleştirilmiş olup, doğal ortamda ağaç üzerindeki meyvelerin tespiti gibi karmaşık senaryolarda sınırlı sayıda çalışma bulunmaktadır. Ayrıca tespit edilen nesnelerin çoğunlukla yalnızca 2B olarak görüntü düzlemindeki konumları ele alınmış, 3B mekânsal konum bilgisi literatürde yeterince değerlendirilmemiştir.

Bu çalışma, söz konusu araştırma boşluğunu ele alarak, doğal ortamda ağaç üzerinde bulunan şeftali meyvelerinin konumlarının derin öğrenme tabanlı yöntemlerle yüksek doğrulukla tespit edilmesini hedeflemektedir. Literatürdeki çalışmalardan farklı olarak, farklı kaynaklardan elde edilen görüntülerle oluşturulmuş birleşik bir veri seti kullanılmış, YOLOv8 mimarisi ile nesne tespiti gerçekleştirilip gerçek dünya koordinatlarına dönüştürülmüştür ve çalışma ileride mobil veya robotik sistemlere entegre edilebilecek bir altyapı sunacak şekilde kurgulanmıştır. Bu yönüyle çalışma, mevcut literatürün üzerine anlamlı bir katkı koymaktadır.

2. KULLANILAN YÖNTEM

2.1. Fotogrametrik Model Oluşturma

Fotogrametrik modelleme sürecinin başarısı, görüntü toplama stratejisinin doğruluğuna doğrudan bağlıdır. Bu nedenle görüntülerin farklı açılardan, yüksek bindirme oranlarıyla ve uygun ışık koşullarında elde edilmesi büyük önem taşır. Tripod, mobil kamera veya İHA gibi platformlarla alınan görüntüler, stereoskopik eşleştirme ve SfM algoritmalarının çalışabilmesi için yeterli paralaksın sağlanmasına imkân verir.

Bu çalışmanın görüntü tabanlı nesne tespiti altyapısını oluşturmak amacıyla, şeftali meyvesini belirgin biçimde üzerinde barındıran bir ağacın görsel olarak bütüncül biçimde temsil edildiği üç boyutlu bir dijital model oluşturulmuştur. Fotogrametrik modelleme yaklaşımı, geleneksel harita mühendisliği tekniklerinden biri olup, çok açılı bindirmeli görüntülerden sayısal yüzey modelinin üretilmesine imkân tanımaktadır.

Modelin oluşum aşamasında Agisoft Metashape yazılımı kullanılmış; RGB kamera ile elde edilen görüntüler belirli bir stratejiyle işlenerek oldukça gerçekçi ve detaylı bir nokta bulutu elde edilmiştir.

2.2. Veri Toplama ve Veri İşleme

Veri toplama süreci, DJI Air 3 model insansız hava aracı (İHA) üzerine entegre yüksek çözünürlüklü RGB kamera ile gerçekleştirilmiştir. Cihazın uçuş kontrol hassasiyeti ve sabit görüntüleme yeteneği, fotogrametrik çekimlerde gerekli olan kararlılığı sağlayarak kaliteli veri elde edilmesine imkân tanımıştır. Çekim sırasında uçuşlar güneşin yer değiştirmesinin görüntülerde yaratabileceği farklılıkların önüne geçmek amacıyla sabit ışık koşulları sağlamak adına olabildiğince hızlı gerçekleştirilmiş, doğrudan güneş ışığı ve gölge etkisi minimize edilmiştir.

Fotogrametrik veri elde etme çalışmaları, Çanakkale'nin Umurbey Köyünde bir şeftali bahçesinde mevsimsel olarak olgunlaşmış şeftali meyvesi taşıyan sağlıklı bir ağaç üzerinde, doğal tarımsal alan koşullarında yapılmıştır. Çalışma için bu alandaki bir şeftali bahçesinin seçilme sebebi diğerlerine kıyasla ağaç çevresinin açık ve engelsiz olmasından ve ağaç üzerindeki meyvelerin sağlıklı, olgunlaşmış, ayırt edilebilir olmasından kaynaklanmaktadır. Görüntüler farklı yükseklik ve açılardan alınacak şekilde uçuş rotaları önceden belirlenmiş; özellikle meyve bulunan kısımlar ve yaprak örtüsünün görünürlüğü dikkate alınarak çekim konumları optimize edilmiştir. Toplamda 3 farklı irtifa düzeyinden (1m, 2 m ve 3 m) yaklaşık 30° aralıklarla dönme pozisyonları belirlenmiş; her bir pozisyondan yeterli bindirme oranına sahip olacak şekilde görüntüler elde edilmiştir.

Fotogrametrik veri elde etme çalışması, 14 Ağustos 2025 tarihinde, saat 20.09 ile 20.24 arasındaki zaman aralığında gerçekleştirilmiştir. Çalışmanın gerçekleştirildiği gün, Meteoroloji Genel Müdürlüğü verilerine göre Çanakkale'de nemli bir hava hâkim olmuştur. Gün içinde en yüksek sıcaklık 32°C, en düşük sıcaklık ise 24°C olarak ölçülmüştür. Nem oranı %74 seviyesinde gerçekleşmiş, kuzeydoğudan esen rüzgârın ortalama hızı 32 km/sa olmuştur.

Veri elde etme işleminde toplamda 131 adet yüksek çözünürlüklü görüntü elde edilmiştir. Görseller .jpg formatında, İHA kamerasının varsayılan çözünürlüğü olan 48 MP (8064×6048 piksel) ile kaydedilmiştir. Görüntüler, doğrudan ham hâlde yazılıma aktarılmadan önce görsel kontrol sürecinden geçirilmiş; aşırı parlama, bulanıklık veya hareket kaynaklı bozulmalar içeren fotoğraflar elenmiştir. Son aşamada model üretimi için işlenilmek üzere seçilen nihai görüntü seti, görüntünün netliği, ağaç yapısı, dal dağılımı ve meyve konumlarını detaylı biçimde içermesi öncelenecek seçilmiştir.

Çalışmada, üretilecek üç boyutlu modelin yalnızca görsel bir sunum aracı olarak değil; aynı zamanda mekânsal analiz, sayısal değerlendirme ve nesne tespiti gibi ileri düzey haritalama uygulamalarında kullanılabilecek yüksek doğruluklu bir veri altyapısı sağlaması hedeflenmiştir. Bu amaçla, modelin gerçek dünya koordinatlarına dönüştürülmesi için arazi çalışmasında şeftali ağacını homojen olarak çevreleyen 6 adet nokta (Şekil 1) tesis edilmiştir. Çalışmada kullanılan yer kontrol noktalarının koordinatları, Sino T300 model GNSS alıcısı kullanılarak ITRF96 referans çatısında ve TM27 projeksiyon sisteminde belirlenmiştir. Ölçümler sırasında CORS-TR (TUSAGA-Aktif) sisteminden alınan düzeltme verileriyle Ağ-RTK yöntemi uygulanmış; her bir noktada yüksek hassasiyetli "fix" (sabit) çözüm durumunda, 10 epokluk 3 bağımsız periyot halinde veri toplanmıştır. Farklı oturumlardan elde edilen bu konumsal verilerin içsel tutarlılığı kontrol edildikten sonra aritmetik ortalamaları alınarak, noktaların santimetre mertebesindeki nihai koordinat değerleri yüksek güvenilirlikle elde edilmiştir. (Tablo 1)

Nokta No	Periyot	Y (m)	X (m)	h (m)	vY (cm)	vX (cm)	vh (cm)	Standart Sapma (s) [cm]		
YKN-01	1. Periyot	461040.926	4453762.504	66.76	-1.2	-0.6	0.3	-	-	-
YKN-01	2. Periyot	461040.955	4453762.516	66.75	1.7	0.6	-0.5	-	-	-
YKN-01	3. Periyot	461040.934	4453762.509	66.76	-0.4	-0.1	0.2	-	-	-
	ORTALAMA	461040.938	4453762.510	66.76	-	-	-	Y:±1.2	X:±0.5	h:±0.4
YKN-02	1. Periyot	461038.912	4453762.233	66.75	0.5	-1.3	0.8	-	-	-
YKN-02	2. Periyot	461038.903	4453762.259	66.73	-0.4	1.3	-1.5	-	-	-
YKN-02	3. Periyot	461038.905	4453762.245	66.75	-0.2	-0.1	0.7	-	-	-
	ORTALAMA	461038.907	4453762.246	66.74	-	-	-	Y:±0.4	X:±1.1	h:±1.1
YKN-03	1. Periyot	461040.427	4453761.871	68.16	-0.2	-0.4	0.4	-	-	-
YKN-03	2. Periyot	461040.461	4453761.886	68.16	3.2	1.1	0.4	-	-	-
YKN-03	3. Periyot	461040.398	4453761.867	68.15	-3.1	-0.8	-0.8	-	-	-
	ORTALAMA	461040.429	4453761.875	68.16	-	-	-	Y:±2.6	X:±0.8	h:±0.6
YKN-04	1. Periyot	461039.695	4453761.963	67.34	1.0	-0.6	0.4	-	-	-
YKN-04	2. Periyot	461039.679	4453761.974	67.33	-0.6	0.5	-0.1	-	-	-
YKN-04	3. Periyot	461039.682	4453761.970	67.33	-0.3	0.1	-0.3	-	-	-
	ORTALAMA	461039.685	4453761.969	67.33	-	-	-	Y:±0.7	X:±0.5	h:±0.3
YKN-05	1. Periyot	461039.770	4453761.390	67.44	0.2	0.1	-0.7	-	-	-
YKN-05	2. Periyot	461039.779	4453761.381	67.45	1.1	-0.8	0.2	-	-	-
YKN-05	3. Periyot	461039.754	4453761.396	67.45	-1.4	0.7	0.5	-	-	-
	ORTALAMA	461039.768	4453761.389	67.45	-	-	-	Y:±1.0	X:±0.6	h:±0.5
YKN-06	1. Periyot	461040.402	4453760.948	66.73	1.5	0.3	1.1	-	-	-
YKN-06	2. Periyot	461040.373	4453760.941	66.71	-1.4	-0.4	-0.8	-	-	-
YKN-06	3. Periyot	461040.386	4453760.946	66.72	-0.1	0.1	-0.2	-	-	-
	ORTALAMA	461040.387	4453760.945	66.72	-	-	-	Y:±1.2	X:±0.3	h:±0.8

Tablo 1. Kontrol noktalarının GNSS ile alımı.

Arazi çalışmalarının ardından, fotogrametrik modelleme süreci Agisoft Metashape Professional 2.0.2 yazılımı kullanılarak gerçekleştirilmiştir. İşlem adımları, fotogrametrinin temel prensiplerine uygun olarak sırasıyla uygulanmıştır. İlk aşamada, sahadan elde edilen toplam 131 adet görüntü yazılıma aktarılmış ve görüntüler arasındaki özdeş resim noktaları (tie points) tespit edilerek görüntülerin bağıl konum ve yöneltme parametreleri hesaplanmıştır. 50 dakika süren bu işlem sonucunda 147.582 nokta içeren bir seyrek nokta bulutu (sparse point cloud) elde edilmiştir. Seyrek nokta bulutu üretiminin ardından, modelin ITRF96 / TM27 koordinat sistemine dönüştürülmesi (mutlak yöneltme) ve geometrik doğruluğunun artırılması amacıyla optimizasyon aşamasına geçilmiştir. Bu aşamada, koordinatları belirlenmiş olan 6 adet YKN'den 4 tanesi dengeleme modeli içerisinde sabit nokta olarak değerlendirilirken diğer 2 adet nokta dengelemenin doğruluğunun test edilebilmesi amacıyla test noktası (Check Point) olarak kullanılmıştır. Sadece YKN'ler referans alınarak kamera optimizasyonu yapılmış ve ışın demeti ile blok dengelemesi (bundle block adjustment) gerçekleştirilmiştir. Modelin mutlak yöneltmesinde referans alınan 4 adet Yer Kontrol Noktasının (YKN) karesel ortalama hataları incelendiğinde; yatayda ($RMSE_{XY}$) 0.95 cm, düşeyde ($RMSE_Z$) 1.15 cm ve üç boyutlu toplam ($RMSE_{XYZ}$) 1.49 cm'lik karesel ortalama hata ($RMSE_{3D}$) değeri elde edilerek, fotogrametrik ağın santimetre mertebesinde yüksek bir metrik doğruluğa ulaşılmıştır.

Dengeleme işleminin hemen ardından, optimizasyon algoritmasına dahil edilmeyen 2 adet Denetleme Noktasının (DN) üç boyutlu model üzerinden hesaplanan koordinatları ile arazide GNSS ile ölçülen gerçek koordinatları kontrol edilmiştir. Yapılan bu doğruluk analizi sonucunda, X, Y ve Z eksenlerinde meydana gelen konum ve yükseklik farkları (ΔX , ΔY , ΔZ) ve genel hata durumları hesaplanarak Tablo 2'te sunulmuştur. Elde

edilen bu hata metrikleri, üretilen modelin mekânsal sapmalarını göstermekte ve projenin nesne tespiti hedefleri için yeterli geometrik güvenilirliğe ulaşılmıştır.

	Model Koordinatları			İTRF96 Koordinatları			Koordinat Farkları		
	Y (m)	X (m)	Z (m)	Y (m)	X (m)	Z (m)	ΔY (m)	ΔX (m)	ΔZ (m)
DN4	461039.685	4453761.952	27.70	461039.685	4453761.969	27.72	0.000	0.017	0.02
DN5	461039.798	4453761.322	27.80	461039.768	4453761.389	27.84	-0.030	0.067	0.04

Tablo 2. Dengeleme öncesi ve sonrası test noktalarının koordinat farkları

Kamera parametrelerinin hesaplanmasından sonra, yoğun nokta bulutu oluşturulma aşamasına geçilmiştir. Demet dengelemesi sonucu elde edilen dış yöneltme parametreleri kullanılarak gerçekleştirilen yaklaşık 2 saatlik işlem sonucunda 102.030.208 nokta içeren ayrıntılı bir veri seti elde edilmiştir. Donanım performansını artırmak amacıyla, çalışma alanı dışındaki kullanılmayan bölgeler temizlenmiş ve nokta sayısı 11.915.180'e düşürülmüştür. Yoğun nokta bulutundan yararlanılarak, nesnenin geometrisini tanımlayan üçgen yüzeylerden oluşan mesh modeli üretilmiştir. Bu sonucunda 7.543.706 adet yüzey (face) ile birlikte üç boyutlu katı model oluşturulmuştur. Son aşamada ise modelin görsel gerçekçiliğini artırmak amacıyla Build Texture adımı uygulanmış ve 1 saat 32 dakikalık işlem süresinde 8192×8192 piksel çözünürlüğünde bir doku kaplaması oluşturularak model üzerine giydirilmiştir.

Modelin fotogrametrik çıktıları sonraki işlemlerde kullanılmak üzere farklı formatlarda dışa aktarılmıştır: yoğun nokta bulutu için .ply, katı yüzey modeli için .obj ve doku verisi için .jpg/.tif formatları tercih edilmiş, iç ve dış kamera parametreleri txt olarak dışarı aktarılmıştır.



Şekil 1. Nokta bulutunun farklı açılardan gösterimi.



Şekil 3. Katı (mesh) modelin farklı açılardan gösterimi.

2.3. Derin Öğrenme Tabanlı Nesne Tespiti

Görüntü tabanlı analizlerde, nesne tespiti; çalışma alanı içerisindeki belirli nesnelerin lokal konumlarının belirlenmesi ve sınıflandırılması işlemini ifade etmektedir. Bu tez çalışmasında şeftali meyvesinin görüntü üzerinden otomatik olarak algılanabilmesi için, bir evrişimli sinir ağı (CNN) mimarisi olan YOLOv8 algoritmasının kullanımı tercih edilmiştir. YOLO (You Only Look Once), bir görüntüdeki nesneleri tek adımda hem sınıflandıran hem de konumlandırabilen, gerçek zamanlı çalışmaya uygun altyapısı ile öne çıkan bir nesne tespiti modelidir (Redmon vd., 2016). YOLOv8, önceki sürümlerden ayrılarak hem model boyutu açısından daha hafif hem de tahmin doğruluğu açısından daha yüksek doğruluk oranlarına sahiptir. Bu sebeple çalışmada yararlanılacak yazılım olarak tercih edilmiştir. YOLOv8 mimarisinin tercih edilmesinin temel nedeni, modelin hem önceki hem de daha güncel sürümlere kıyasla hız, doğruluk ve donanım verimliliği açısından projenin hedeflerine en uygun dengeyi sunmasıdır. YOLOv5 ve YOLOv7 gibi önceki sürümlerle karşılaştırıldığında YOLOv8, daha hafif yapısına rağmen karmaşık tarımsal arka planlarda daha yüksek tahmin doğruluğu ve öznetelik çıkarımı sağlamaktadır. Öte yandan, YOLOv9 veya YOLOv10 gibi daha güncel sürümlerin zorlu tarımsal saha koşullarındaki kararlılığı literatürde henüz YOLOv8 kadar geniş çapta ve uzun süreli test edilmemiştir. Çalışmanın asıl hedefinin salt bir 2B doğruluk optimizasyonundan ziyade, tespitleri fotogrametrik altlık üzerinden 3B uzaya aktaracak bütünlük bir altyapı (proof of concept) sunmak olduğu göz önüne alındığında; YOLOv8n (Nano) varyantı, düşük hesaplama maliyeti ve gelecekteki mobil/robotik sistemlere entegrasyon potansiyeli ile en optimum mühendislik çözümü olarak değerlendirilmiştir.

2.4. Veri Seti Oluşturma

Derin öğrenme tabanlı nesne tespit modellerinin başarılı sonuçlanması, büyük oranda kullanılan veri setinin niteliğine göre şekillenmektedir. Veri setinin bulundurduğu örneklerin sayısı, çeşitliliği, görüntü kalitesi ve sınıflandırma doğruluğu, modelin hem eğitim sürecini hem de genelleme becerisini doğrudan etkilemektedir. Dolayısıyla çalışmanın temel nesnesi olan şeftali meyvesinin görüntülerinin toplanması ve işleme süreci, oldukça detaylı bir planlama ve çok kaynaklı veri entegrasyonu ile gerçekleştirilmiştir.

Görüntü toplama işlemleri üç farklı donanım üzerinden yürütülmüştür. İlk olarak, DJI Air 3 model İnsansız Hava Aracı (İHA) üzerindeki yüksek çözünürlüklü RGB kamera ile ağaç çevresinde gerçekleştirilen uçuşlarla, meyvelerin farklı açılardan ve yüksekliklerden görüntülenmesi sağlanmıştır. İkinci olarak, Canon EOS 250D dijital fotoğraf makinesi kullanılarak yer seviyesinden manuel olarak görüntüler elde edilmiştir. Bu çekim yöntemi, meyvelerin daha yakından ve daha yüksek detay içeriğiyle görüntülenmesi açısından tercih edilmiştir. Yapılan manuel çekim, yaprak örtüsü altında kalan veya kısmen gizlenmiş durumda bulunan meyve örneklerinin de doğal yapısından ayrıştırılmadan doğrudan ağaç üzerinde yalnızca üzerindeki yaprak ve diğer nesnelerden yer yer arındırılarak veri setine dâhil edilmesini mümkün kılmıştır. Üçüncü olarak, mobil cihaz olarak iPhone 14 Pro cep telefonu kullanılmış; bu cihazın gelişmiş kamerası ile farklı açılarda ve aydınlatma koşullarında ek görüntüler alınmıştır. İHA ile elde edilen görüntülerde; fotogrametri aşamasında kullanılan görüntüler, eğitim metriklerini olduğundan yüksek göstermemesi için Toplanan bu üç farklı donanıma ait görüntüler tek bir görsel havuzda birleştirilmiş ve boyutlandırma işleminden geçirilerek .jpg formatında, 640×640 piksel çözünürlükte yeniden düzenlenmiştir. Birbirini tekrarlayan ve birbirlerine benzeyen görüntüler manuel olarak elimine edilmiştir. Yalnızca sınıflandırma açısından anlamlı, net ve belirgin olanlar göz önüne alınarak 654 adet fotoğraf seçilmiştir.

Veri seti oluşturulurken yalnızca saha çalışmasından elde edilen görüntülerle sınırlı kalınmamış, aynı zamanda açık kaynaklı çevrimiçi veri platformlarından (Roboflow) benzer yapıdaki ve şeftali meyvesine ait olduğu doğrulanan sınıflandırılmış bazı minimal veri setleri (peach dataset-127 görüntü, peaches dataset-60 görüntü, seftali dataset-76 görüntü) seçilmiştir. Bu çeşitlilik, modelin belirli bir ağaç yapısına aşırı uyum (overfitting) sağlamasını engellemektedir. Etiketleme işlemi Roboflow platformu üzerinde gerçekleştirilmiş, her şeftali meyvesi dikdörtgen sınırlayıcı kutular (bounding box) içerisine alınarak manuel olarak işaretlenmiştir. Modelin farklı ışık, açı ve yön değişimlerine karşı daha dayanıklı olmasını sağlamak amacıyla

veri setine çeşitli veri artırma (augmentation) işlemleri uygulanmıştır. Bu kapsamda görüntüler rastgele döndürülmüş, yatay–dikey eksenlerde yansıtılmış ve belirli örneklerde parlaklık ile kontrast değerleri değiştirilmiştir. Veri artırma (augmentation) işlemi gerçekleştirilirken aynı görüntünün farklı türevlerinin test setine sızması için (data leakage) veri artırma işlemi sadece train setinde yapılmıştır. Bu işlemler sonucunda veri seti yaklaşık iki katına çıkarak toplam 1985 görüntüde 3463 adet etiket elde edilmiş ve tüm etiketler YOLOv8 formatına uygun hâle getirilip Roboflow üzerinden dışa aktarılmıştır. Bu süreç, modelin öğrenme kapasitesini genişletmiş ve YOLOv8n’in nitelikli bir eğitim veri setiyle beslenmesini sağlamıştır. Oluşturulan her etiket dosyası, YOLOv8 mimarisine uygun olarak .txt uzantısında kaydedilmiş; her satırda sırasıyla sınıf etiketi, kutunun merkez koordinatları (x, y) ve kutunun genişlik–yükseklik değerleri (w, h) yer alacak şekilde yapılandırılmıştır. Etiketleme işlemi başarıyla tamamlandıktan sonra, veri seti eğitim (%80), doğrulama (%10) ve test (%10) olmak üzere üç gruba farklı ayrılmıştır.




Şekil 4. YOLO modeli için hazırlanan etiketler.

2.5. Model Eğitimi

Veri setinin oluşturulmasının ardından şeftali meyvesinin otomatik olarak tespit edilebilmesi amacıyla YOLOv8 mimarisinin YOLOv8n varyantı kullanılarak model eğitimi gerçekleştirilmiştir. PyTorch tabanlı Ultralytics YOLOv8n altyapısı kullanılarak görüntüler eğitim (%80), doğrulama (%10) ve test (%10) olacak şekilde ayrılmış; görüntüler ve onlara karşılık gelen .txt etiket dosyaları YOLO formatına uygun biçimde “images/train”, “images/val” ve “images/test” klasörlerinde yapılandırılmıştır. Eğitimde transfer öğrenme yöntemi kullanılarak önceden eğitilmiş modelden yararlanılmış ve böylece daha az veriyle daha yüksek performans elde edilmesi sağlanmıştır.

Modelin eğitiminde görüntü boyutları 640×640 piksel olarak belirlenmiş ve toplam 100 epoch boyunca eğitim gerçekleştirilmiştir. Her epoch sonrasında doğrulama seti üzerinden model performansı izlenmiştir. Başarı değerlendirmesinde nesne tespitinde yaygın kullanılan Ortalama Kesinlik (mAP - mean Average Precision), Kesinlik (Precision) ve Geri Çağırma (Recall) kullanılmıştır.




Şekil 5. YOLO modelinin eğitim sonucu grafiği.


Eğitim çıktıları incelendiğinde YOLOv8 modelinin yüksek bir algılama performansı gösterdiği görülmüştür. Model, doğrulama seti üzerinde mAP50 değerinde %84,62 ve daha sıkı bir örtüşme kriteri sunan mAP50-95 değerinde %60,33 başarı elde etmiştir. Güven eğrisinde (F1), 0.416 güven eşiğinde (confidence threshold) 0.83 F1 skoru elde edilmiştir. Bu bulgular, modelin şeftali meyvesini yalnızca tespit etmekle kalmadığını, aynı zamanda sınır kutularını konumsal olarak doğru şekilde belirleyebildiğini göstermektedir.

Parametre	Değer	Açıklama
Model Varyantı	YOLOv8n (Nano)	En hafif ve hızlı mimari
Görüntü Boyutu (imgsz)	640 x 640	Giriş çözünürlüğü
Batch Size	16	Her iterasyondaki görüntü sayısı
Epoch	100	Toplam eğitim döngüsü
Optimizer	SGD (Auto)	Optimizasyon algoritması
Learning Rate (lr0)	0.01	Başlangıç öğrenme hızı
Momentum	0.937	Gradyan momentum katsayısı
Weight Decay	0.0005	Düzenleştirme katsayısı
IoU Threshold	0.70	Eğitim sırasındaki çakışma eşiği
Augmentation (Mosaic)	1.0 (Aktif)	Görüntü birleştirme tekniği

Tablo 3. YOLO modelinin eğitim hiperparametreler.



Şekil 6. Eğitilmiş YOLO modelinin test sonuçları.




Şekil 7. Eğitilmiş YOLO modelinin test sonuçları.

2.6. Model Görüntüsü Bazlı Nesne Tespiti

Bu aşamada, 3B modelin oluşturulmasında kullanılan görüntüler üzerinde eğitilen YOLOv8 modeli çalıştırılarak şeftali tespiti yapılmıştır. İşlemlerin daha hızlı ve otomatik yürütülebilmesi amacıyla Python tabanlı bir masaüstü yazılımı geliştirilmiştir. Geliştirilen uygulama, birden fazla görüntüyü ardışık biçimde işleyerek her fotoğraf üzerinde nesne tespiti yapabilmekte, tespit edilen nesnelerin merkez resim koordinatlarını hesaplayarak düzenli bir veri formatında kaydedebilmektedir. Yazılım; veri okuma, modelin çalıştırılması, sonuçların işlenmesi, koordinat çıkartımı ve çıktıların metin dosyalarına aktarılması gibi modüler bileşenlerden oluşmakta ve farklı bilgisayarlarda sorunsuz şekilde çalışabilecek esnek bir yapıya sahiptir.


Gerçekleştirilen testlerde yazılım toplam 131 görüntü üzerinde uygulanmış ve model tarafından 354 adet geçerli tespit yapılmıştır. Yaklaşık görüntü başına 2.7 tespit düşmesi, nesne yoğunluğunun düşük olmasına rağmen modelin farklı açılardan alınmış görüntülerde hedef nesneleri tutarlı biçimde belirleyebildiğini göstermektedir. Elde edilen ortalama güven skoru 0.6621 olup, eğitim verisi ile kullanım verisi arasındaki farklılıklara rağmen modelin performansını koruyabildiğini ortaya koymaktadır. Yüksek çözünürlüklü görüntülerden elde edilen sınır kutuları ve merkez koordinatları, 3B modelleme aşamasında doğru noktalarla eşleşme olasılığını artırmaktadır.



Şekil 8. Geliştirilen python tabanlı masaüstü yazılımı.


2.7. 2D Sonuçlarını 3D Nokta Bulutuna Projeksiyonu

Çalışmanın önemli bileşenlerinden biri, 2D görüntülerde YOLO tarafından tespit edilen nesne merkezlerinin 3B yüzey modeli üzerinde gerçek konumlarına yansıtılmasını sağlayan ışın izleme (ray casting) temelli projeksiyon işlemidir. Bu amaçla, geliştirilen Python tabanlı yazılıma ek modüller eklenmiş ve sistem; kamera pozisyonları, iç/dış yöneltme parametreleri ve üç boyutlu mesh model geometrisiyle entegre çalışacak şekilde tasarlanmıştır. Yazılım, YOLO tarafından üretilen 2D merkez koordinatlarını normalize edilmiş görüntü düzlemine dönüştürmekte ve bu noktalardan başlayan ışınları hesaplanan kamera parametreleri yardımıyla 3B mesh yüzeyine doğru uzatarak kesişim noktalarını hesaplamaktadır. Bu süreçte kullanılan ışın denklemi şu şekilde ifade edilir; $R(t) = O + t \cdot d$, $t > 0$ burada O: Kameranın optik merkezini (dış yöneltme parametreleri), d: Görüntü düzlemindeki pikselin normalize edilmiş 3B doğrultu vektörünü (iç yöneltme parametreleri), t: Işın üzerindeki mesafe parametresini temsil etmektedir. Böylece her tespit edilen nesnenin 3B uzaydaki karşılık gelen konumu belirlenmiştir.



Şekil 9. Katı model üzerinde kamera konumlarının (mavi dikdörtgenler) ve ışınların gösterimi.


Işın izleme işlemi sürecinde üretilen ışınların önemli bir kısmı mesh yüzeyi ile geçerli kesişim oluşturmuş ve başarılı ışın oranı sistemin kararlılığını göstermiştir. YOLO çıktılarının ışın izleme yöntemiyle 3B modele projeksiyonu sonrasında elde edilen kesişim noktaları, aynı şeftalinin farklı görüntülerde birden fazla kez temsil edilmesi nedeniyle ham hâliyle gerçek nesne sayılarını yansıtmamaktadır. Bu nedenle çalışmada, çoklu kesişim noktalarını tekil nesne temsillerine indirmek amacıyla mekânsal yakınlık temelli bir kümelenme yaklaşımı uygulanmıştır. Işınlardan elde edilen tüm 3B noktalar normalize edilmiş ve konumsal yoğunluk yapısını dikkate alan DBSCAN tabanlı bir algoritma ile analiz edilmiştir. Kümeleme için noktaların komşu sayılması için maksimum mesafe (eps) 4 cm ve gereken minimum nokta sayısı (min_samples) 4 olarak belirlenmiştir. Böylece birbirine geometrik olarak yakın noktalar aynı fiziksel şeftaliyi temsil eden tek bir grup altında birleştirilmiş, gürültü niteliğindeki noktalar elenmiştir.



Şekil 10. DBSCAN Duyarlılık Analiz

Şekil 10'da görüldüğü üzere, DBSCAN algoritmasının parametre duyarlılık analizi gerçekleştirilmiştir. Grafikteki Mavi eğri ($\text{min_samples}=2$), sistemin gürültüye çok açık olduğunu ve kararsız bir yapı sergilediğini göstermektedir. Buna karşın, çalışma kapsamında tercih edilen Turuncu eğri ($\text{min_samples}=4$), özellikle $\text{eps}=0.04\text{m}$ ile $\text{eps}=0.06\text{m}$ aralığında kararlı bir plato oluşturmuştur. Bu aralıkta tespit edilen nesne sayısının (13 adet) değişmemesi, seçilen 0.04m parametresinin uzamsal değişimlere karşı dirençli olduğunu ve meyvelerin fiziksel boyutlarıyla en iyi örtüşen değer olduğunu kanıtlamaktadır. Eps değeri 0.07m 'nin üzerine çıktığında ise nesne sayısında gözlemlenen düşüş, birbirine yakın meyvelerin küme birleşmesi sorunu nedeniyle tek nesne olarak algılanmasından kaynaklanmaktadır.

Her küme için hesaplanan merkez noktaları, çalışma alanındaki şeftalilerin kesin ve tekil üç boyutlu konumlarını oluşturmuş; bu yöntem hem konumlama doğruluğunu artırmış hem de gerçek nesne sayısının güvenilir biçimde belirlenmesini sağlamıştır.



Şekil 11. Tespit edilen şeftalilerin katı model üzerinde gösterimleri (sarı küreler).

Geliştirilen yazılım, ışıın-yüzey kesişim hesaplamalarını ve kamera kalibrasyon parametrelerini otomatik olarak işleyerek tüm 3B koordinatları sıralı biçimde çıktı dosyalarına aktarmaktadır. Bu yaklaşım sayesinde başlangıçta yalnızca 2D görüntülere dayanan tespitler, fotogrametrik doğruluk taşıyan tam konumlandırılmış 3B işaret noktalarına dönüştürülmüş; sistemin mekânsal analiz ve nesne temsil kapasitesi önemli ölçüde artırılmıştır.

Tespit Edilen Obje	İTRF96 Koordinatları		
	Y (m)	X (m)	h (m)
seftali_01	461039.309	4453761.718	67.99
seftali_02	461039.730	4453761.765	67.12
seftali_03	461040.415	4453761.847	67.92
seftali_04	461040.281	4453761.847	67.68
seftali_05	461039.340	4453761.822	67.72
seftali_06	461039.692	4453761.711	67.04
seftali_07	461039.337	4453761.876	67.79
seftali_08	461039.704	4453761.826	67.12
seftali_09	461039.520	4453761.903	67.53
seftali_10	461039.329	4453761.772	67.88
seftali_11	461039.501	4453761.971	67.51
seftali_12	461039.482	4453761.838	67.53
seftali_13	461039.754	4453761.665	67.04

Tablo 4. Tespit edilen şeftali koordinatları

3. SONUÇ VE ÖNERİLER



Şekil 12. Sırasıyla gerçek görüntü, katı model, tespitlerin model üzerinde gösterimi.

Bu çalışma, farklı açılardan elde edilen görüntüleri derin öğrenme tabanlı nesne tespiti ve fotogrametrik 3B modelleme yöntemleriyle bütünleştirerek tarım alanlarındaki şeftali meyvelerinin hem 2B hem de 3B ortamda konumlandırılmasını mümkün kılan özgün bir yaklaşım ortaya koymuştur. Tarım alanlarındaki meyvelerin üç boyutlu uzayda yüksek hassasiyetle konumlandırılabilmesi amacıyla öncelikle metrik doğruluğu yüksek bir fotogrametrik altyapı oluşturulmuştur. Şeftali ağacına ait 131 adet yüksek çözünürlüklü görüntü Agisoft Metashape yazılımında işlenerek ışın demetleri ile blok dengelemesi (bundle block adjustment) yöntemi uygulanmıştır. Üretilen modelin gerçek dünya koordinatlarına (ITRF96 / TM27) dönüştürülmesi sürecinde, arazide Ağ-RTK GNSS yöntemiyle ölçülen 4 adet Yer Kontrol Noktası (YKN) ve 2 adet Denetleme Noktası (DN) sisteme entegre edilmiştir. Yapılan kamera optimizasyonu neticesinde, YKN'ler üzerinden hesaplanan karesel ortalama hata ($RMSE_{XYZ}$) 1.49 cm. Santimetre mertebesindeki bu geometrik başarı, üretilen 3B mesh modelin ileri düzey nesne tespiti algoritmaları için güvenilir bir mekânsal altlık oluşturduğunu kanıtlamıştır.

YOLOv8 mimarisi ile eğitilen model, değişen görüntü koşullarına rağmen yüksek doğrulukla çalışmış; mAP50 ve mAP50-95 değerleri sırasıyla %84,62 ve %60,33 olarak elde edilerek modelin güvenilir performansını kanıtlamıştır. Modelin F1 eğrisinde maksimum değere (0.83) ulaştığı 0.416 güven eşiği (confidence threshold), yaprak örtüsü ve gölge gibi doğal zorluklara karşı optimum tespit dengesinin sağlandığını göstermiştir. Uygulama aşamasında kullanılan 131 görüntü üzerinde 2B olarak 354 şeftali tespit edilmiştir, geliştirilen Python tabanlı yazılım aracılığıyla kamera parametreleri kullanılarak ışın izleme (ray casting) yöntemiyle 3B modele yansıtılmış, toplam 354 tespitten %40 üzeri doğruluk oranına sahip 340 ışın gönderilmiştir. 340 ışıdan 268 adedi model yüzeyi ile başarılı bir şekilde kesişmiştir, kesişmeyen ışınlar oluşturulan ağaç modeli dışında zemine dökülen şeftaliler ve etrafta ki diğer görünür ağaçlar üzerinde bulunan şeftalilerdir. Ardından mesh yüzeyle kesişen aynı şeftaliye ait farklı noktalar DBSCAN tabanlı kümelenme metodu ile elimine edilmiştir ve toplamda 13 adet şeftali tespit edilip sarı renkte küreler olarak işaretlenmiştir. Ağaçta bulunan gerçek şeftali sayısı 14 olmasına rağmen yazılım tarafından 13 adet tespit edilmiştir. Tespit edilemeyen şeftali, ağacın yaprakları arasında kalması sebebiyle fotoğraflarda görünmemektedir. Önceki aşamalarda sağlanan yüksek fotogrametrik tutarlılık sayesinde, ışın izleme ve kümelenme işlemleri sonucunda tespit edilen bu 13 şeftalinin 3B konumları, harici bir koordinat dönüşümüne gerek kalmaksızın doğrudan gerçek dünya koordinatlarında elde edilmiştir. Elde edilen bu sonuçlar, derin öğrenme ve fotogrametri birlikteliğinin tarımsal ürün rekolte tahmini ve konumlandırma süreçlerinde son derece başarılı, metrik olarak güvenilir ve uygulanabilir bir yöntem olduğunu açıkça göstermektedir.

Elde edilen bu bulgular, literatürdeki benzer tarımsal nesne tespiti çalışmalarıyla karşılaştırıldığında, modelin zorlu saha koşullarına rağmen rekabetçi ve yenilikçi bir performans sergilediği görülmektedir.

Tarımsal zararlı tespiti üzerine odaklanan Biçgi ve Karaca (2022), patates böceği tespiti için geliştirdikleri YOLOv4 modeli ile %87,53 mAP ve %0,81 F1 skoru elde etmiştir. Bu çalışmada ulaşılan %84,62'lik mAP değerinin, söz konusu çalışmaya kıyasla marjinal düzeyde düşük kalmasının temel nedeni, hedef nesnenin morfolojik yapısı ve sahne karmaşıklığıdır. Patates böceği, yaprak yüzeyinde genellikle belirgin bir kontrast oluştururken; bu çalışmaya konu olan şeftali meyveleri, yoğun yaprak örtüsü altında kısmen gizlenmekte ve rüzgâr etkisiyle dinamik bir arka plan içerisinde yer almaktadır. Ayrıca, Biçgi ve Karaca'nın (2022) kullandığı YOLOv4 mimarisi parametre yoğunluğu açısından daha ağır bir model iken, bu çalışmada gerçek zamanlı çalışmaya ve mobil entegrasyona daha uygun olan hafif siklet YOLOv8n (Nano) varyantı tercih edilmiştir. Buna rağmen performans farkının %3 bandında kalması, YOLOv8 mimarisinin öznetelik çıkarımındaki başarısını ve modelin genelleme yeteneğini ortaya koymaktadır.

Benzer şekilde Gündüz (2023), kamkat meyvesi tespiti için YOLOv7 mimarisini kullanarak %93 doğruluk oranına ulaşmıştır. Gündüz'ün çalışmasında kullanılan sabit kamera düzenekleri ve kontrollü ışık koşulları, tespit başarısını artıran faktörler olarak öne çıkmaktadır. Ancak bu çalışmada görüntüler, İHA ve yer tabanlı hareketli platformlardan, farklı aydınlatma koşulları (güneş/gölge geçişleri) altında toplanmıştır. Doğal tarım sahalarındaki bu kontrolsüz değişkenlere rağmen elde edilen 84,62'lik ortalama güven skoru ve 354 tespitin fotogrametrik modelle tutarlı olması, önerilen yöntemin laboratuvar ortamından ziyade gerçek saha koşullarında uygulanabilirliğini kanıtlamaktadır.

Literatürdeki çalışmaların önemli bir bölümü (Li vd., 2023; Erşahin ve Keskin, 2025), başarı kriteri olarak ağırlıklı biçimde 2B tespit metriklerini (mAP, F1-Score) esas almaktadır. Örneğin Li vd. (2023), YOLOv5-ASFF ile çilek tespitinde mimari iyileştirmelere odaklansa da meyvenin uzamsal konumuna dair bir analiz sunmamıştır. Bu çalışmanın literatürden ayrılan en özgün yönü, %84,62'lik 2B tespit başarısını nihai bir çıktı olarak değil, gerçek dünya koordinatlarının çıkarımı için bir ara girdi olarak değerlendirmesidir. Ağaç üzerindeki 14 meyveden 13'ünün 3B gerçek dünya koordinatlarıyla konumlandırılması, önerilen bütünleşik yöntemin, salt görüntü tabanlı tespit yapan çalışmalara kıyasla rekolte tahmini ve robotik hasat planlaması için daha güvenilir bir veri altyapısı sunduğunu ortaya koymaktadır.

Bu çalışmada geliştirilen 2B-3B entegrasyonlu metodolojinin uygulamasının tek bir ağaç modeli ve kısıtlı bir sahne ile sınırlandırılması, sistemin genellenebilirliği açısından değerlendirilmesi gereken temel bir kısıttır. Algoritmanın ışın izleme ve fotogrametrik metrik konumlandırma yeteneğini öncelikle kavramsal düzeyde (proof of concept) ve santimetre hassasiyetinde kanıtlamak amacıyla, bu aşamada bilinçli olarak kontrollü ve sınırlandırılmış bir test alanı tercih edilmiştir. Bu mühendislik yaklaşımıyla, geniş alanlara geçmeden önce sistemin matematiksel altyapısı minimum referans verisi ve hesaplama maliyetiyle doğrulanmıştır. Ancak, tarımsal meyve sayım doğruluğunun ve model esnekliğinin tam anlamıyla ortaya konabilmesi için tek sahne yaklaşımının ötesine geçilmesi gerektiği açıktır. Bu bağlamda, sunulan metodolojinin mekânsal homojenliğini ve genellenebilirliğini maksimize etmek amacıyla; gelecekte yapılacak çalışmalarda farklı ağaç morfolojileri, değişen ışık koşulları ve farklı gün/saat dinamiklerini barındıran farklı senaryolar üzerinden kapsamlı sayım doğruluğu analizlerinin gerçekleştirilmesi gelecek araştırmalar için önemli bir potansiyel barındırmaktadır.

Gelecek çalışmalar kapsamında, fotogrametrik modellemenin LİDAR gibi aktif algılayıcılarla desteklenmesi, özellikle yoğun yaprak örtüsü altında kalan meyvelerin tespiti için 3B konum doğruluğunu ve veri bütünlüğünü daha da iyileştirebilir. Benzer şekilde, yüksek hesaplama yükü gerektiren ışın izleme (ray casting) sürecinin GPU tabanlı paralel mimarilerle hızlandırılması, sistemin büyük ölçekli bahçelerde yüksek verimli kullanımına imkân sağlayacaktır. Bunun yanı sıra, DBSCAN dışında alternatif veya daha gelişmiş kümelenme algoritmalarının denenmesi, çoklu ışın kesişimlerinin daha hassas bir şekilde filtrelenmesine ve tekilleştirilmesine katkı sunabilir. Son olarak, geliştirilen yazılımın gerçek zamanlı İHA (drone) uçuşlarına entegre edilmesi; anlık olarak ürün tespiti, rekolte analizi ve otonom hasat planlaması gibi ileri seviye hassas tarım uygulamaları için güçlü bir altyapı oluşturacaktır.

Tüm bu yönleriyle çalışma, yalnızca ele alınan mevcut araştırma problemini çözmekle kalmamış; aynı zamanda hassas tarım teknolojileri, haritacılık (fotogrametri) ve derin öğrenme disiplinlerinin entegrasyonunda yapılacak gelecekteki bilimsel çalışmalara metodolojik anlamda rehberlik eden özgün, güvenilir ve değerli bir mühendislik katkısı sunmuştur.

EXTENDED SUMMARY

Introduction

The digitalization of agricultural production increasingly requires fast, objective, and reproducible measurement methods for tasks such as fruit detection, crop counting, and yield analysis. While deep learning-based object detection methods—particularly YOLO architectures—are widely used in agricultural applications, the majority of existing studies evaluate detection results solely on a two-dimensional (2D) image plane. The integration of 2D object detection with three-dimensional (3D) spatial localization remains limited in the literature. This study addresses this gap by presenting an integrated deep learning and photogrammetry-based method designed to automatically detect peach fruits and determine their highly accurate 3D real-world coordinates directly on a photogrammetric tree model.

Method

The methodology comprises three main stages: photogrammetric model generation, dataset creation, and the 2D-to-3D projection of the detected objects. First, a highly accurate 3D mesh model of a peach tree was produced using multi-angle images captured by a DJI Air 3 UAV. To ensure the model was accurately represented in real-world coordinates, 6 Ground Control Points (GCPs) were established using an RTK GNSS receiver, enabling direct transformation into the ITRF96 (TM27) coordinate system via Bundle Block Adjustment. For the object detection phase, a robust dataset of 3463 labels was created by combining UAV images, ground-based camera images, and open-source data. The YOLOv8n architecture was then trained to detect the fruits. Finally, a custom Python-based software was developed to project the 2D bounding box centers onto the 3D photogrammetric mesh model using a ray-casting algorithm, guided by the camera's interior and exterior orientation parameters. To eliminate multiple ray intersections belonging to the same fruit, a spatial proximity-based DBSCAN clustering algorithm was applied.

Findings and Results

The trained YOLOv8 model demonstrated strong performance, achieving an mAP50 of 84.62% and an mAP50-95 of 60.33% on the validation set. During the application phase, the model made 354 valid 2D detections across 131 images. Through the ray-casting process, 340 rays were projected, and 268 of them successfully intersected with the 3D mesh surface. Following the DBSCAN clustering process—optimized with a maximum distance (eps) of 0.04m and a minimum of 4 points—the system successfully identified and localized 13 individual peaches out of the 14 actually present on the tree. It was observed that the single undetected fruit was not visible in the images due to dense leaf cover. Crucially, the photogrammetric network achieved a root mean square error ($RMSE_{XYZ}$) of 1.49 cm, ensuring that the final spatial locations of the fruits were obtained with centimeter-level accuracy.

Discussion and Conclusions

This study demonstrates that the integration of deep learning and photogrammetry provides an innovative and highly accurate solution for determining the spatial distribution of agricultural products. By advancing beyond conventional studies that limit findings to visual 2D bounding boxes, this method transforms detections into metric, georeferenced engineering data. The proposed workflow offers a reliable infrastructure for precision agriculture applications, such as autonomous harvest planning and yield estimation. Future studies should aim to evaluate the system's generalizability across different tree morphologies and larger orchards, potentially incorporating LiDAR data and GPU-accelerated ray tracing to further enhance detection under dense canopies and reduce computational loads.

KAYNAKÇA

- Alami, A. and Remondino, F (2025).: Towards annotation-less semantic segmentation of aerial point clouds, Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.
- Albayrak E. (2021): Derin Öğrenme ile İHA Görüntülerinden Nesne Tespitinin Yapılması. Yüksek Lisans Tezi, Bilecik Şeyh Edebalı Üniversitesi, Fen Bilimleri Enstitüsü.
- Ataberdiev K. (2022) İnsansız Hava Aracı Sistemi ile Çekilen Multispektral Zaman Serisi Görüntüleri ve Makine Öğrenmesi ile Bazı Bitki Türlerinin Sınıflandırılması. Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü.
- Atmaca A.Ş. (2024) Derin Öğrenme Yaklaşımıyla Gerçek Zamanlı Görüntüler Üzerinde Tehlikeli Nesne Tespiti. Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü.
- Biçgi M. ve Karaca İ.: (2022) Nesne Tespit Algoritması (YOLOv4) Kullanarak Patates Böceğinin (*Leptinotarsa decemlineata*) (Say) Patates Bitkisi Üzerinde Tespiti ve Populasyon İzleme Olanakları. Turkish Journal of Science and Engineering.
- Demo. (2024). *Peaches Dataset* [Veri seti], 60 Görüntü. Roboflow.
- Gülmez F. (2024): İHA ve Yersel Fotogrametri Yöntemlerinin Entegrasyonu ile 3B Bina Modelleme: YTÜ Prototip Laboratuvarı Örneği. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Gündüz, T. (2023). Derinlik Kamerası ile Derin Öğrenme Tabanlı Nesne Tespiti. Yüksek Lisans Tezi, İskenderun Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Hajjaji, Y., Boulila, W., Farah, I. R., & Koubaa, A. (2025). Enhancing palm precision agriculture: An approach based on deep learning and UAVs for efficient palm tree detection. Ecological Informatics.
- İpek, C. (2025). *seftali Dataset* [Veri seti], 76 Görüntü. Roboflow.
- Karadağ B. ve Arı A. (2023): Akıllı Mobil Cihazlarda YOLOv7 Modeli ile Nesne Tespiti. Politeknik Dergisi.
- Li, Yaodi & Xue, Jianxin & Zhang, Mingyue & Yin, Junyi & Liu, Yang & Qiao, Xindan & Zheng, Decong & Li, Zezhen. (2023). YOLOv5-ASFF: A Multistage Strawberry Detection Algorithm Based on Improved YOLOv5.
- Mohammad M. T. (2020) Gezin Robotlar için İç Mekanlarda 3-B Stereo Kamerası Dayalı Nesne Tespiti ile Engellerden Kaçınma. Yüksek Lisans Tezi, Bahçeşehir Üniversitesi.
- Nergiz, M. (2023). Enhancing Strawberry Harvesting Efficiency through Yolo-v7 Object Detection Assessment. Turkish Journal of Science and Technology.
- 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.
- shj1864@naver.com. (2022). *peach Dataset* [Veri seti], 127 Görüntü. Roboflow.
- Sıkar, R. B., & Bozatlı Kartal, S. (2025). Smart traffic monitoring with YOLOv9 object detection algorithm. Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi.
- Şensu C. (2024): Makine Öğrenmesi ile Bitki Türü Sınıflandırma Projesi. İzmir Kâtip Çelebi Üniversitesi, Fen Bilimleri Enstitüsü.
- Toroman S. (2018) Derin Öğrenme ile İnsansız Hava Aracı Görüntülerinden Yaya Tespiti. Journal of Aviation
- Usta A. (2022): İnsansız Hava Aracından Çekilen Videolar Kullanılarak Derin Öğrenme Yaklaşımı ile Nesne Tespiti. Yüksek Lisans Tezi, Dicle Üniversitesi, Fen Bilimleri Enstitüsü.
- Villalobos-Salazar, R. D. J., Contreras Carlos, A., Juarez-Maldonado, A., & Morales-Diaz, A. (2026). Early detection of *Hellula undalis* in *Brassica oleracea* var *capitata* L.: A real-time drone based approach using YOLOv8. Smart Agricultural Technology.
- Wolf, P. R., & Dewitt, B. A. (2000). Elements of Photogrammetry with Applications in GIS. 3rd Edition.