

Ayçiçeği Çiçek Tablalarının Mask R-CNN Derin Sinir Ağı ile RGB ve Multispektral İHA Ortomozaiklerinden Örnek Segmentasyonu

Instance Segmentation of Sunflower Inflorescences from RGB and Multispectral UAV Orthomosaics with Mask R-CNN Deep Neural Network

Esra Yıldırım^{1*}, İsmail Çölkesen¹, Umut Güneş Sefercik¹

¹Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 41400, Kocaeli/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Esra Yıldırım
esrayildirim@gtu.edu.tr

doi: 10.48123/rsgis.1602369

Yayın süreci

Geliş tarihi: 16.12.2024
Kabul tarihi: 13.02.2025
Basım tarihi: 26.03.2025

Özet

Ayçiçeği, ülkemiz için önemli bir yağlı tohum kaynağı olup, büyük ve kendine özgü çiçek tablasıyla diğer tarımsal bitkilerden ayrılır. Ayçiçeği tablasının doğru bir şekilde tespit edilmesi, verim tahmini ve sürdürülebilir üretim planlaması açısından çok önemlidir. Bu çalışmanın temel amacı, derin öğrenme tabanlı Mask R-CNN modelinin RGB ve multispektral İHA ortomozaiklerinden ayçiçeği çiçek tablasını tespit etme performansının değerlendirilmesidir. Bu amaçla, Sakarya'nın Arifiye ilçesindeki çalışma alanı üzerinde İHA hava fotoğrafları toplanmış ve yüksek çözünürlüklü ortomozaikler üretilmiştir. ResNet-50 omurgalı Maske R-CNN modeli, RGB ve multispektral İHA ortomozaiklerinden manuel olarak etiketlenmiş veri kümeleri üzerinde eğitilmiş ve test edilmiştir. Sonuçlar, modelin multispektral verilerle daha yüksek doğruluk elde ettiğini, tahmin edilen ve gerçek tespitler arasındaki örtüşmeyi ölçen 0,50 birleşim üzerinde kesişim eşiğinde %94,74 Ortalama Hassasiyete ve %96,73 F1 Skoruna ulaştığını göstermektedir. RGB verileriyle, model en iyi performansı 0,75 eşiğinde göstererek %78,19 F1 Skoru ve %63,50 Ortalama Hassasiyet elde etmiştir. Bu bulgular, multispektral İHA verilerinin ayçiçeği çiçek tablalarının tespit edilmesinde daha etkili olduğunu, RGB İHA verilerinin ise daha iyi lokalizasyon doğruluğu sağladığını göstermektedir.

Anahtar kelimeler: Derin öğrenme, Örnek segmentasyonu, Mask R-CNN, İnsansız hava aracı (İHA), Hassas tarım, Ayçiçeği

Abstract

Sunflower is an important oilseed source for our country, distinguished from other agricultural plants by its large and unique inflorescence. Accurately detecting sunflower inflorescence is crucial for yield estimation and sustainable production planning. The main goal of this study is to evaluate the performance of the deep learning-based Mask R-CNN model in detecting sunflower inflorescences from RGB and multispectral UAV orthomosaics. For this purpose, UAV aerial photos were captured over the study area in Arifiye district of Sakarya, and high-resolution orthomosaics were produced. The Mask R-CNN model with a ResNet-50 backbone was trained and tested on manually labeled datasets from RGB and multispectral UAV orthomosaics. The results indicate that the model achieved higher accuracy with multispectral data, reaching an F1 Score of 96.73% and an Average Precision of 94.74% at a 0.50 intersection over union threshold, which measures the overlap between predicted and actual detections. With RGB data, the model performed best at a 0.75 threshold, obtaining an F1 Score of 78.19% and an Average Precision of 63.50%. These findings suggest that multispectral UAV data are more effective in detecting sunflower inflorescences, while RGB UAV data provide better localization accuracy.

Keywords: Deep learning, Instance segmentation, Mask R-CNN, Unmanned aerial vehicle (UAV), Precision agriculture, Sunflower

1. Giriş

Ayçiçeği (*Helianthus annuus* L.) dünyanın farklı bölgelerinde yaygın olarak yetiştirilen, ekonomik, tıbbi ve besin değeri yüksek bir tarımsal üründür. Ülkemizde ekimi yapılan yağlı tohumlu bitkiler arasında üretim bakımından birinci sırayı alan yağlık ayçiçeği, bitkisel yağ tüketiminde %80-85 civarındaki payı nedeniyle ülkemizin en önemli yağlı tohum bitkisidir (Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü Müdürlüğü, 2023). Bitki, plastik, kimya, boya, sabun, kozmetik, motor yağı, cila ve biyodizel sanayi için de önemli bir hammadde olmakla birlikte küspesi hayvan yemi üretimi için kullanılmaktadır. Ayçiçeği, belirgin şekilde büyük bir çiçek tablasına sahip tek bir gövdesi ile diğer tarım bitkilerinden ayrılabilir. Çiçek tablasının sayısı ve boyutu, verimi ve tohum kalitesini doğrudan etkileyen kritik tarımsal özelliklerdir (Seiler, 1997). Dolayısıyla çiçek tablasının doğru ve hassas bir şekilde tespiti, verim tahminlemesi, fenotip analizi, fenolojik takip ve sürdürülebilir üretim planlaması için önemlidir (Jing vd., 2024). Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) verilerine göre Dünya'da ayçiçeği üretimi 1961'de 6,7 milyon hektar alanda ekilen 6,8 milyon ton iken, 2022'de 29,3 milyon hektarda ekilen 54,3 milyon ton olarak gerçekleşmiştir (Food and Agriculture Organization, 2022). Dünya'daki ayçiçeği üretimi göz önüne alındığında 2022 yılı itibarıyla en büyük paya 16,4 milyon ton ile Rusya sahipken Türkiye 2,6 milyon ton ile beşinci sırada yer almaktadır (Food and Agriculture Organization, 2022). Türkiye İstatistik Kurumu (TÜİK) verilerine göre Türkiye'de ayçiçeği ekim alanları 2004 yılında 5,5 milyon dekar iken, 2023 yılı itibarıyla ekili alan miktarı %73 artış göstererek 9,5 milyon dekar olarak gerçekleşmiştir (Türkiye İstatistik Kurumu, 2023). Üretim ise 2004 yılında 0,9 milyon ton iken, 2023 yılı itibarıyla %144 artış ile 2,2 milyon ton olarak gerçekleşmiş ve dolayısıyla birim alandan elde edilen verim %137 artış göstererek 498 kg/dekara ulaşmıştır (Türkiye İstatistik Kurumu, 2023). Öte yandan, birincil olarak insanlar için önemli bir besin kaynağı olan yenilebilir yağların çıkarılması için yetiştirilen yağlı tohumlu bitkiler arasında üretimin yaklaşık %80'ini oluşturan ayçiçeğinin ürün verimindeki farklılıkların gıda sektörünü ve ülke ekonomisini önemli ölçüde etkileyeceği açıktır. Bu bağlamda, sensör teknolojileri ve yapay zekâ destekli akıllı tarım uygulamaları; ürün ekim kalitesinin analizi, fenolojik evre takibi, verim tahmini, hastalık tespit ve takibi, yetiştirme programlarının düzenlenmesi, gelecek ekim takvimleri için ürün yönetiminde karar verme noktasında sürdürülebilir üretim ve tarla yönetiminde büyük rol oynamaktadır (Centorame vd., 2024a; Centorame vd., 2024b).

Dünya çapında hızlı nüfus artışı ve sanayileşme gibi faktörler nedeniyle ayçiçeği dahil olmak üzere birçok tarımsal üründe üretim artışı yaşanmaktadır. Artan üretim talepleri doğrultusunda hassas tarım; tarımsal üretimi artırmak, işgücünü azaltmak, gübre ve sulama süreçlerinin etkin yönetimini içerisine alan önemli hususlarda dünya çapında benimsenen bir kavram olarak ortaya çıkmıştır (Singh vd., 2020). 2024'te Uluslararası Hassas Tarım Topluluğu (ISPA) hassas tarımı, zamansal, mekânsal ve bireysel bitki ve hayvan verilerini toplayan, işleyen ve analiz eden ve bunları tarımsal üretimin gelişmiş kaynak kullanımı verimliliğini, üretkenliğini, kalitesini, kârlılığını ve sürdürülebilirliğini artırmak için tahmini değişkenliğe göre yönetim kararlarını desteklemek üzere diğer bilgilerle birleştiren bir yönetim stratejisi olarak tanımlamıştır (International Society of Precision Agriculture, 2024). Bu bağlamda, bitki örtüsünün gelişimi, verimi, sağlığı, fiziko-kimyasal içeriği, besin durumu, toprak durumu, gübre ve ilaç etkisi gibi değişkenlerin gözlemlenmesi ve ölçülmesi için uzaktan algılama ve yapay zekâ gibi yeni gelişen teknolojiler hassas tarım uygulamaları için önemli birer araç olarak kullanılmaktadır (Singh vd., 2020).

Uzaktan algılama teknolojileri, dünya yüzeyinin doğal ve yapay özellikleri hakkında hedef objelerle doğrudan fiziksel temas kurmadan yüksek konumsal, spektral, radyometrik ve zamansal çözünürlüklerde veri toplamaya olanak tanıdığından uzaktan algılanmış veriler hızlı, hassas ve dinamik tarım uygulamalarında önemli bir kaynak durumundadır. Bu uygulamalar arasında sürdürülebilir üretim planlaması ve yüksek doğrulukta verim tahminlemesi için büyük önem arz eden tarımsal ürünlerin tespiti, takibi, fenolojik gelişiminin izlenmesi, sağlığı ve hastalıklarının takibi üzerine gerçekleştirilen çalışmalar öne çıkmaktadır. Söz konusu çalışmaların gerçekleştirilmesinde literatürde özellikle uydu ve İnsansız Hava Aracı (İHA) verileri temel altlık olarak kullanılmaktadır. Ancak, uydu sensörlerinin mekânsal, spektral ve zamansal çözünürlüğündeki gelişmelere rağmen yüksek maliyeti, bulut ve sis problemi (optik uydularda), gerçek zamanlı veri alınamaması gibi problemler hassas tarımsal uygulamalarda uydu görüntülerinin kullanımını kısıtlamaktadır. Buna karşın İHA teknolojileri uygun maliyetli olmaları, ihtiyaç duyulan verileri ihtiyaç duyulan zamanda ve yerde istenilen görüntüleme geometrilerinde (nadir bakışlı, oblik, polinomal, grid, çift-grid, dairesel vb.) elde edebilmeleri, uydular ve diğer uzaktan algılama platformlarına kıyasla alçak uçuş irtifaları sayesinde daha yüksek mekânsal çözünürlük sağlayabilmeleri ve periyodik veri alım kabiliyetleri gibi nedenlerle tarımsal uygulamalarda büyük avantajlar sağlamaktadır (Bouguettaya vd., 2022). Bu doğrultuda, İHA teknolojileri tarımsal ürünlerin tespiti ve haritalanması (Popescu vd., 2020), verim tahmini (Yang vd., 2019), hastalık tespiti (Guo vd., 2021) ve yabancı ot tespiti (Huang vd., 2018) gibi çeşitli hassas tarım çalışmalarında literatürde yaygın olarak kullanılmaktadır.

Tarımsal ürünlerin tespiti ve izlenmesinde geleneksel görüntü işleme yaklaşımları yaygın olarak kullanılsa da manuel özellik çıkarımı gereksinimi bu yaklaşımların kullanılabilirliğini kısıtlamaktadır. Geleneksel yaklaşımlarda görüntü üzerinde ilgi duyulan nesnelere ilişkin özellikler renk, doku ve morfolojik işlemler kullanılarak çıkarılmaktadır (Bakhshipour vd., 2018). Ancak arka plan, aydınlanma, toprak rengi, gölge, bitkinin baş kısmının şekli ve boyutu gibi çeşitli faktörler bu nesnelere otomatik tespitini etkileyebilmektedir (Karami vd., 2021).

Literatürde sunulan çeşitli yöntemler bu etkilerin azaltılmasını hedeflese de bu yaklaşımların gerçek dünya koşulları ve karmaşık yapılı veri setlerine uygulanabilirliğini sağlamak halen önemli bir sorun olarak varlığını sürdürmektedir (Sanaeifar vd., 2023). Son yıllarda, derin öğrenme yaklaşımının ortaya çıkmasıyla birlikte, görüntü segmentasyonu, nesne tespiti ve görüntü sınıflandırma gibi görüntü işleme uygulamalarında önemli başarılar elde edilmiştir (Redmon vd., 2016; Badrinarayanan vd., 2017; Yang vd., 2018). Derin öğrenme algoritmaları, derin bir sinir ağı oluşturarak kendi kendine öğrenme yaklaşımıyla verilerden otomatik ve uyarlanabilir bir şekilde görüntü üzerinde aranan nesneye ilişkin özellikleri çıkarabilme kabiliyetine sahiptir. Bu avantajı sayesinde geleneksel yöntemler ve uzman deneyimine dayalı olarak gerçekleştirilen nesne tespiti çalışmalarında karşılaşılan sorunların üstesinden gelebilmektedir. Örneğin, bir evrimsel sinir ağı (ESA) mimarisi olan AlexNet'in, 2012'deki ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'ndaki üstün başarısıyla ESA'ların görüntü işleme alanındaki uygulamaları popülerlik kazanmaya başlamış ve güçlü özellik temsil yetenekleri nedeniyle uzaktan algılanan görüntülerden tarımsal ürün tespiti gibi hassas tarım uygulamalarında yaygın olarak kullanılmaya başlanmıştır (Albahar, 2023; Kamilaris & Prenafeta-Boldú, 2018).

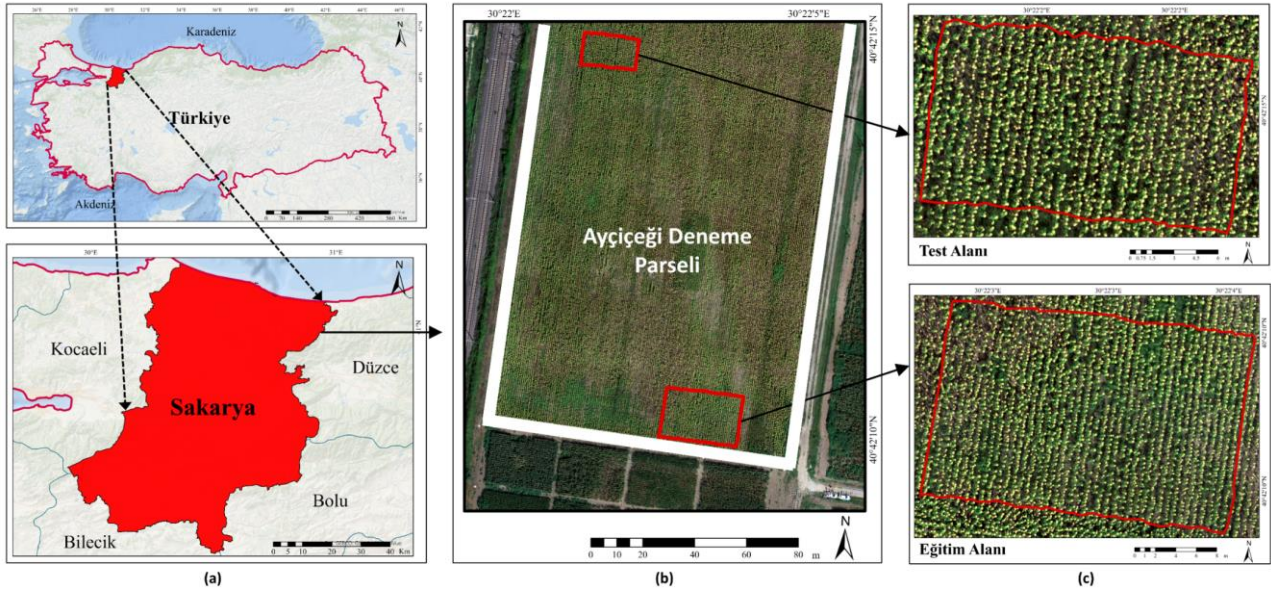
İHA teknolojisi ve derin öğrenme kombinasyonu tarımsal ürünün tespiti, ürünlerin fiziksel ve spektral yapısı, hastalık/zarar durumu ve toprak türü gibi hususlarda anlık bilgi sağlayabilmektedir (Bouguettaya vd., 2022). İHA tabanlı uzaktan algılama görüntüleri ve derin öğrenme tekniklerini kullanan hassas ve otomatik tarımsal ürün tespiti; ürün haritalama ve izleme (Xiao vd., 2023), ürün verim tahmini (Yang vd., 2019), su stresi izleme (Gao vd., 2020), hastalık/böceklenme tespiti (Kerkech vd., 2018) dahil olmak üzere birçok hassas tarım uygulaması için anahtar bir role sahiptir. Bu bağlamda, literatürde birçok çalışma ayçiçeği çiçek tablalarının (kapitulum) tespiti, ayçiçeği büyüme aşamalarının tespiti, tıbbi bitki tespiti gibi uygulamalarda İHA verileri ve derin öğrenme algoritmalarının entegrasyonunu önermektedir. Örneğin, Jing vd. (2024) RGB İHA görüntülerinden ayçiçeği kapitulumlarının tespitinde iyileştirilmiş bir YOLOv7-Tiny yaklaşımının kullanımını ele almıştır. Ayçiçeğinin büyüme aşamalarının tespiti için Song vd. (2023) DeepLab V3 +, SegNet ve PSPNet semantik segmentasyon ağları ve multispektral İHA görüntülerinden yararlanmıştır. Diğer bir çalışmada, Poleshchenko vd. (2023) İHA görüntülerinden ayçiçeği bitkisinin segmentasyonunda U-Net ve FPN mimarilerinin performansını incelemiştir. Ding vd. (2023) tarafından gerçekleştirilen uygulamada, İHA ortomozaiklerinden tıbbi bitkilerin tespiti ve verim tahminlemesi için Mask R-CNN modeli kullanılmıştır. Li vd. (2023), kanola bitkisi çiçek tablasının RGB İHA ortofotolarından tespiti ve verim tahminlemesini amaçlayan çalışmada YOLOv5 tabanlı bir yaklaşım geliştirmiştir. Farklı fenolojik aşamalardaki ayçiçeklerinin çok zamanlı RGB İHA ortomozaiklerinden tespitine yönelik gerçekleştirilen güncel bir çalışmada ise U-Net ve DeepLab V3 derin semantik segmentasyon ağlarının performansı ele alınmıştır (Yıldırım vd., 2024a).

Bu çalışmanın temel amacı ayçiçeği çiçek tablalarının İHA ortomozaiklerinden tespitinde derin öğrenme tabanlı örnek segmentasyonu modeli Mask R-CNN'in performansının araştırılması ve model eğitiminde veriseti olarak RGB ve multispektral ortomozaiklerin kullanılmasının modelin tespit doğruluğu üzerindeki etkilerinin incelenmesidir. Mask R-CNN, obje tespit ve segmentasyon aşamalarını birleştirerek tespit edilen her bir nesne örneği için piksel düzeyinde segmentasyon maskesi üretebilmektedir. Bu çalışmada tercih edilmiş olmasının temel sebepleri ise ayçiçeği çiçek tablalarının tespitinde piksel bazında hassas bir şekilde nesne sınırlarını belirleyebilmesi ve literatürde ayçiçeği özelinde kullanılmamış bir model olmasıdır. Çalışmanın amaçları doğrultusunda, Sakarya ili Arifiye ilçesinde belirlenen bir çalışma alanının RGB ve multispektral hava fotoğrafları İHA uçuşları ile toplanmış ve yüksek çözünürlüklü ortomozaikler üretilmiştir. Oluşturulan her iki ortomozaik üzerindeki ayçiçeği çiçek tablaları ArcGIS Pro yazılımında manuel olarak etiketlenmiş ve ortomozaikler 256x256 piksel boyutunda görüntü parçalarına bölünerek iki farklı veriseti oluşturulmuştur. Oluşturulan verisetleri ile Mask R-CNN modeli ResNet-50 omurga ağı ile birleştirilerek transfer öğrenme yaklaşımıyla eğitilmiş ve modelin farklı spektral ve mekânsal çözünürlüklere sahip veri setleri kullanımında ayçiçeği çiçek tablası tespitine yönelik performansı irdelenmiştir.

2. Çalışma Alanı

Çalışma, Sakarya ili Arifiye ilçesinde, Sakarya Mısır Araştırma Enstitüsü tarafından yönetilen parseller içerisinde yer alan bir ayçiçeği tarlasında yürütülmüştür. Sakarya ili, Türkiye'nin kuzeybatısında 29°57' ve 30°53' doğu boylamları ile 40°17' ve 41°13' kuzey enlemleri arasında yer almakta olup kuzeyden Karadeniz, doğudan Düzce ili, güneydoğudan Bolu ili, güneyden Bilecik ili, batıdan Kocaeli ili ile çevrilmiştir (Şekil 1a). Karadeniz ve Akdeniz iklimlerinin etki gösterdiği bir geçiş iklim alanı olan ilde yazlar sıcak ve nemli, kışlar ise yağışlı ve ılıktır. Yüzölçümü 5.015 km² olan ve %44'ü platolar, %34'ü dağlar ve %22'si ovalardan oluşan ilde tarla bitkileri ile sebze ve meyve yetiştirilen tarım alanları il topraklarının yaklaşık %48'ini kapsamaktadır (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2024). Sahip olduğu zengin bitki örtüsünün başında ormanlar gelmekle birlikte ilde buğday, patates, kabak, pancar, mısır, ayçiçeği ve fındık gibi önemli tarımsal ürünler yetişmektedir. 10.970 tonluk ayçiçeği üretimi ile Sakarya ili, Türkiye ayçiçeği üretiminin %0,57'sini karşılamaktadır (Türkiye İstatistik Kurumu, 2023). Ayçiçeği farklı iklim koşullarında ve toprak türlerinde yetiştirilebilmesi sayesinde güçlü bir adaptasyona sahip ve toprağın derinliklerine kadar inebilen kök yapısı nedeniyle kuraklığa nispeten dayanıklı bir bitkidir (T.C. Tarım ve Orman Bakanlığı, 2007).


Bitki gelişimine göre ayçiçeği büyümesi iki ana aşamada gerçekleşir: (i) vejetatif evre (vegetative stage), (ii) üreme evresi (reproductive stage) (Schneider & Miller, 1981). Vejetatif evre (V), çıkış evresi (VE) ve gerçek yaprak gelişimi (V(N)) olmak üzere iki alt aşamaya ayrılır. Üreme evresi (R) bitki çiçek tablasının ilk oluşumu ile başlayan ve bitki fizyolojik olgunluğunun tamamlanmasıyla son bulan dokuz alt evrede gerçekleşir. Bu çalışmada, Sakarya Mısır Araştırma Enstitüsü tarafından yönetilen Kirazca Tarımsal Araştırma Alanı'nda üreme aşamasındaki ayçiçeği bitkisinin çiçek tablalarının tespiti amacıyla arazi çalışmaları yürütülmüş ve deneysel araştırmalarda kullanılmak üzere tasarlanan ayçiçeği tarlasında eğitim ve test bölgeleri oluşturulmuştur (Şekil 1b ve 1c).



Şekil 1. Çalışma alanı konumu: (a) Sakarya ili haritası, (b) Kirazca tarımsal araştırma alanı ayçiçeği tarlası, (c) eğitim ve test için tasarlanan deneysel sahalar

3. Metodoloji

Derin öğrenme ve İHA teknolojilerinin entegrasyonu ile ayçiçeği çiçek tablasının tespitini amaçlayan bu çalışmada derin öğrenme modeli olarak Mask R-CNN değerlendirmeye alınırken; temel veri kaynağı olarak RGB ve multispektral İHA ortomozaikleri kullanılmıştır. Bu amaç doğrultusunda spesifik olarak derin öğrenme modelinin farklı spektral ve mekânsal çözünürlüklere sahip verilerin kullanımına ilişkin ürün tespit performansı detaylı olarak incelenmiştir. Çalışma amacına uygun olarak takip edilen metodoloji üç temel işlem adımından oluşmaktadır: (1) RGB ve multispektral İHA hava fotoğraflarının toplanması, fotogrametrik işleme ve ortomozaik üretimi, (2) ortomozaikler üzerinde manuel etiketleme ile gerçek zemin verisi oluşturulması, ortomozağin kırılması, veri artırımı ve veri setinin eğitim ve test veri setlerine bölünmesi, (3) Mask R-CNN modelinin kurulumu, hiperparametre optimizasyonu, transfer öğrenme yaklaşımıyla modelin eğitimi ve validasyonu, performans analizi ve modelin test edilmesi. Çalışmaya ait detaylı iş akış şeması Şekil 2'de verilmiştir.




Şekil 2. Çalışma kapsamında izlenen iş akış şeması

3.1. İHA Veri Toplama ve Ortomozaik Üretimi

İHA teknolojisi ile veri toplama yöntemleri, ihtiyaç duyulan veri ve sonuç ürünlerin niteliğine göre farklılık göstermektedir. Bu çalışmada, Mask-R CNN modelinin RGB ve multispektral İHA hava fotoğraflarından üretilen ortomozaikler üzerinde ayçiçeği çiçek tablasının otomatik tespit performansının ayrı ayrı değerlendirilmesi öncelikli hedef olarak belirlenmiştir. Bu hedef doğrultusunda, çalışma alanında hem RGB hem de multispektral İHA uçuşları ayrı ayrı gerçekleştirilmiş ve elde edilen yüksek çözünürlüklü hava fotoğraflarıyla en yüksek kalitede ortomozaiklerin üretimi amaçlanmıştır. RGB veri alımı için 20 MP çözünürlüklü ve 8,8 mm odak uzaklıklı Sony Exmor RGB kamerası sahip DJI Phantom 4 Pro V2 İHA, multispektral veri alımı içinse 2,08 MP çözünürlüklü ve 5,74 mm odak uzaklıklı DJI Phantom IV Multispektral İHA kullanılmıştır. İHA uçuşları, 29 Ağustos 2022 tarihinde, 50 m irtifada, %80 boyuna ve %60 enine bindirme oranlarıyla gerçekleştirilmiştir. RGB İHA uçuşları, ayçiçeklerinin 3B fiziksel yapısını her cepheden bakışla daha yüksek potansiyelde tasvir edebilmek amacıyla hem kuzey-güney hem de doğu-batı yönlü rotaları içerecek şekilde çift-grid (double-grid) modda ve 70° bakış açısında planlanmıştır. Multispektral İHA uçuşlarında ise RGB banda ek olarak ayrı ayrı R, G, B bant yanı sıra kırmızı kenar (red edge) ve yakın kızılötesi (NIR) görüntüleme ile spektral imza tasviri ön planda olduğundan poligonal modda kuzey-güney yönlü ve nadir bakışlı (90°) uçuşlar planlanmıştır. Uygulanan uçuş parametreleri doğrultusunda, oluşturulacak stereo modellerin her bölgesinin en az 9 hava fotoğrafı ile temsili sağlanmış, RGB ve multispektral hava fotoğrafları sırasıyla ~1,47 cm ve ~3,23 cm ortalama yer örnekleme aralıklı (YÖA) olarak elde edilmiştir. Elde edilen hava fotoğraflarının fotogrametrik işlemesi, Agisoft Metashape yazılımında gerçekleştirilmiştir. RGB ve multispektral hava fotoğraflarının karşılıklı yönlendirilmesi hareketten yapı (SfM) tekniği temelinde otomatik eşleştirme ile gerçekleştirilirken mutlak yönlendirmede arazide uçuş öncesinde tesis edilmiş 14 polikarbon mobil yer kontrol noktası (YKN) kullanılmıştır. Normal şartlarda, multispektral veri alımının gerçekleştirildiği İHA, gerçek zamanlı kinematik global navigasyon uydu sistemleri (RTK GNSS) alıcı anten donanımına sahip olduğundan YKN kullanım gereksinimi bulunmamaktadır. Ancak, İHA'lar üzerinde yer alan düşük maliyetli RTK GNSS donanımlarında bazı hava ve topoğrafya şartlarında sinyal kalitesinde düşüşler yaşanabilmekte hatta kesintiler oluşabilmekte ve pozisyonlama doğruluğu düşebilmektedir (Sefercik vd., 2024). Bu doğrultuda, çalışma alanının çok yakınında bulunan yüksek hızlı tren hattının RTK GNSS sinyali üzerinde oluşturabileceği olumsuz etkiler (sinyal kesilmesi, gecikmesi vb.) göz önünde tutularak geometrik yönlendirmede RGB İHA ile eşit koşullar sağlanması amacıyla multispektral İHA verilerinin mutlak yönlendirmesinde de arazide tesis edilmiş YKN'ler kullanılmıştır. RGB ve multispektral hava fotoğraflarının mutlak yönlendirmelerinde kullanılan YKN'lerin ortalama karesel ortalama hataları (KOH) sırasıyla $\pm 1,5$ cm ve $\pm 1,1$ cm olarak tespit edilmiştir.

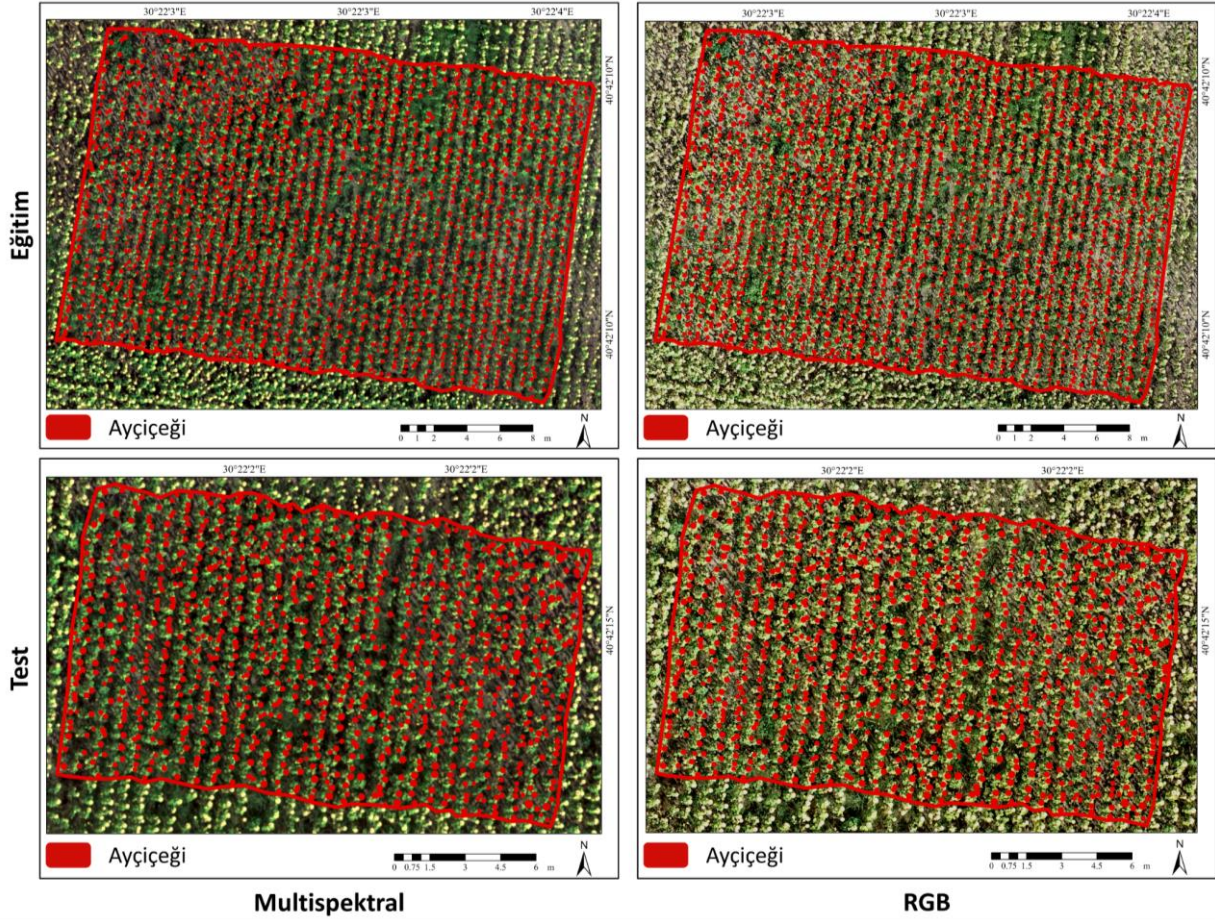
Multispektral İHA hava fotoğraflarının radyometrik kalibrasyonu MAPIR V2 kamera reflektans kalibrasyon paneli kullanılarak gerçekleştirilmiştir. Panel uçuşun hemen öncesinde çalışma alanına konumlandırılmış ve İHA kamerası ile fotoğraflanmıştır. Panelde beyaz, açık gri, koyu gri ve siyah olmak üzere dört temel hedef renk yer almakta olup bu hedeflere ilişkin reflektans değerleri distribütör firmadan sağlanmış ve hava fotoğraflarının radyometrik kalibrasyon işlemleri tamamlanmıştır. Geometrik yöneltme ve radyometrik kalibrasyon işlemlerinin tamamlanmasının ardından sırasıyla yoğun nokta bulutu, dijital yüzey modeli (DYM) ve ortomozaik üretimleri yüksek kalite parametreleri uygulanarak gerçekleştirilmiştir. RGB ve multispektral İHA ortomozaikleri sırasıyla 1,4 cm ve 2,6 cm YÖA'da elde edilmiştir (Şekil 3).



Şekil 3. Çalışma alanında üretilen ortomozaikler: (a) Multispektral, (b) RGB

3.2. Ayçiçeği Çiçek Tablası Veri Seti Oluşturma

Derin öğrenme tabanlı bireysel tarımsal ürün tespitinde hassas bir şekilde etiketlenmiş veri setinin oluşturulması model performansı açısından kritik öneme sahiptir. Model kurulumunda kullanılmak üzere ihtiyaç duyulan etiketli veri setinin oluşturulması amacıyla çalışma alanında üretilen RGB ve multispektral ortomozaikler üzerindeki ayçiçeği çiçek tablaları ArcGIS Pro 3.0.3 yazılımında görsel yorumlama ile manuel olarak "Ayçiçeği" sınıfı altında etiketlenmiştir. Bu bağlamda, her bir ortomozaik üzerinde ayrı ayrı olarak Şekil 4'te gösterilen eğitim bölgesi içerisinde 2.018, test bölgesi içerisinde ise 1.001 ayçiçeği örneği etiketlenmiştir. Eğitim bölgesinde etiketlenen örnekler Mask R-CNN modelinin eğitimi ve doğrulaması amacıyla, test bölgesinde etiketlenen örnekler ise eğitilen modelin tespit doğruluğunun detaylı olarak analiz edilmesinde kullanılmıştır. Çok yüksek çözünürlüklü İHA verilerinin işlenmesinin yoğun emek gerektiren zaman alıcı bir süreç olması ve evrimsel sinir ağlarının büyük veri setleriyle birlikte büyük hesaplama yükü gerektirmesi nedeniyle ortomozaik verilerin doğrudan model eğitiminde kullanılması uygun olmamaktadır (Yıldırım vd., 2024b). Bu sebeple GPU kısıtlamalarının önüne geçmek için ortomozaikler %50 bindirme (128×128 piksel) ile 256×256 piksel boyutunda görüntü parçalarına bölünmüştür. Görüntü bindirmesi eğitim örnek sayısını artırmak ve görüntü kenar bölgelerine denk gelen ayçiçekleri için sınır problemini önleyerek her örneğin en az bir görüntü parçası içerisine düşmesini sağlamak amacıyla kullanılmıştır. Ayrıca eğitim örneği sayısını artırmak ve model performansını iyileştirmek için eğitim veri setleri 90°, 180° ve 270° yönlerinde döndürülerek yapay veri artırımı işlemi gerçekleştirilmiştir. Sonuç olarak RGB eğitim veri seti toplamda 492 görüntü ve 24.912 örnek, multispektral eğitim veri seti ise 492 görüntü 24.852 örnek içermektedir. Ardından oluşturulan eğitim veri setleri modelin eğitimi ve doğrulaması için %80 ve %20 oranlarında rastgele olarak eğitim ve doğrulama veri setleri olarak ayrılmıştır.



Şekil 4. Multispektral ve RGB ortomozaikler üzerinde eğitim ve test bölgeleri için oluşturulan zemin gerçeği verileri


3.3. Mask R-CNN Model Eğitimi ve Performans Analizi

Derin öğrenme tabanlı iki aşamalı obje tespit yöntemi Faster R-CNN'in genişletilmiş bir versiyonu olan Mask R-CNN obje tespitini semantik segmentasyon ile birleştiren bir örnek segmentasyonu modelidir (He vd., 2017). Objeye tespiti görüntüdeki her bir nesnenin sınırları kutu ile konumlandırıldığı ve bu nesnelerin sınıflandırıldığı bir problemdir. Semantik segmentasyon ise görüntüdeki her pikseli nesne örnekleri ayırt edilmeksizin belli bir dizi sınıf değerlerine sınıflandırmayı amaçlar. Bu bağlamda örnek segmentasyonu görüntüdeki nesnelere sınırları kutu ile tespit eder ve eş zamanlı olarak her bir örneğin piksel bazlı segmentasyon maskesini oluşturur. Mask R-CNN çalışma prensibi olarak Faster R-CNN'e benzer iki aşamalı prosedürü esas almaktadır. İlk aşamada tüm görüntü taranır ve görüntüde nesne bulunan potansiyel alanlar için bölge önerileri oluşturulur. İkinci aşamada Faster R-CNN'de belirlenen bölgelerde sınırları kutu regresyonu ve sınıflandırma işlemi ile tahmin edilen kutu ofsetleri ve sınıflara ek olarak Mask R-CNN'de her bölge için ikili segmentasyon maskeleri tahmin edilir.

Temel mimarisi Şekil 5'te sunulan Mask R-CNN üç ana bileşenden oluşur: (i) özellik çıkarıcı ağ, (ii) bölge öneri ağı, (iii) üç farklı fonksiyon dalı için tam bağlantılı katmanlar ve tam evrişimli ağ. Omurga ağı olarak bilinen özellik çıkarıcı ağ, girdi görüntüler üzerinde özellikler çıkarmak ve özellik haritaları oluşturmaktan sorumlu olan genel olarak bir evrişimli sinir ağıdır (örneğin, ResNet-50 ve FPN). Bölge öneri ağı (Region Proposal Network-RPN), oluşturulan özellik haritalarında nesnelerin bulunabileceği olası alanlar için bir dizi bölge önerisinde (Region of Interest-RoI) bulunur. Önerilen bölgeler sınıflandırma, sınırları kutu regresyonu ve piksel bazında segmentasyon için tam evrişimli (Fully Connected-FC) katmanlara ve tam evrişimli ağa (Fully Convolutional Network-FCN) gönderilir. Modelin kayıp fonksiyonu sınıflandırma, konumlandırma ve maske kayıplarının kombinasyonundan oluşan bir çoklu görev kaybı fonksiyondur ve aşağıdaki şekilde tanımlanır:

$$L = L_{cls} + L_{box} + L_{mask} \quad (1)$$

Eşitlikte L_{cls} sınıflandırma kaybını, L_{box} sınırları kutu kaybını ve L_{mask} segmentasyon kaybını temsil etmektedir.



Şekil 5. Mask R-CNN mimarisi

Mask R-CNN modelinin ayçiçeği çiçek tablası tespit performansını değerlendirmek için derin öğrenme tabanlı obje tespit çalışmalarında yaygın olarak kullanılan Hassasiyet (precision), Duyarlılık (recall), F1 Skor, IoU (birleşim üzerinde kesişim) ve mAP (genel ortalama hassasiyet) doğruluk metrikleri kullanılmıştır (Denklem 2-6). Bu metriklerin hesaplanmasında hata matrisi bileşenlerinden Doğru Pozitif (DP), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) değerleri kullanılmaktadır. Gerçekte ayçiçeği olan nesnelerin model tarafından da ayçiçeği olarak tahmin edildiği durumlar DP, gerçekte ayçiçeği olmayan nesnelerin model tarafından ayçiçeği olarak tahmin edildiği durumlar YP, gerçekte ayçiçeği olan ancak model tarafından tahmin edilmeyen ayçiçekleri YN olarak temsil edilir. IoU metriği model tarafından tahmin edilen ayçiçeklerinin ve zemin gerçeği ayçiçeklerinin kesişim alanının birleşim alanına bölünmesi ile hesaplanır. Diğer bir ifadeyle, IoU, bir modelin tahmin ettiği sınırlayıcı kutu veya segmentasyon maskesinin, yer doğrulama verisiyle ne kadar örtüştüğünü ölçen bir performans göstergesidir. Objeye tespiti ve örnek segmentasyonu çalışmalarında sıklıkla kullanılan IoU metriği genellikle derin öğrenme modellerinde tahmin edilen her bir bireysel nesnenin DP, YP ve YN olarak nitelendirilmesinde bir eşik değeri olarak kullanılır ve bu eşik değeri genellikle 0,5 olarak kabul edilir (Maxwell vd., 2021). IoU metriği için kullanılan bu eşik değeri, bir tahminin doğru kabul edilmesi için gereken minimum örtüşme miktarını belirler. Örneğin model tarafından doğru olarak tahmin edilen ve IoU değeri 0,6'dan büyük olan ayçiçekleri DP, model tarafından kaçırılan ve IoU değeri 0,6'dan küçük olan ayçiçekleri YN olarak dikkate alınır. Hassasiyet modelin tahmin ettiği toplam DP sayısının toplam tahmin sayısına bölünmesi ile hesaplanır. Duyarlılık ise modelin tahmin ettiği toplam DP sayısının toplam zemin gerçeği nesne sayısına bölümüdür. F1 Skor, Hassasiyet ve Duyarlılığın harmonik ortalaması olarak hesaplanan bir performans metriğidir. Derin öğrenme uygulamalarında Hassasiyet-Duyarlılık grafiği altında kalan alan AP (ortalama hassasiyet) metriği olarak ifade edilir (Padilla vd., 2021). AP değeri sınıf bazında ve her IoU değeri için ayrı ayrı olarak hesaplanır. mAP ise tüm sınıflar için ve çok sayıda IoU eşliğinde, genellikle 0,5 ile 0,95 arasında 0,05'lik artışla değişen 10 eşik değerinde, hesaplanan AP değerlerinin ortalamasıdır (Gibril vd., 2024).

$$\text{Hassasiyet} = \frac{DP}{DP+YP} \quad (2)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3)$$

$$\text{F1 Skor} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4)$$

$$IoU = \frac{\text{Kesişim Alanı}}{\text{Birleşim Alanı}} = \frac{\text{Alan}(B_{\text{gerçek}} \cap B_{\text{tahmin}})}{\text{Alan}(B_{\text{gerçek}} \cup B_{\text{tahmin}})} \quad (5)$$

$$mAP = \left(\frac{1}{N}\right) \sum_{i=1}^N (AP)_i \quad (6)$$

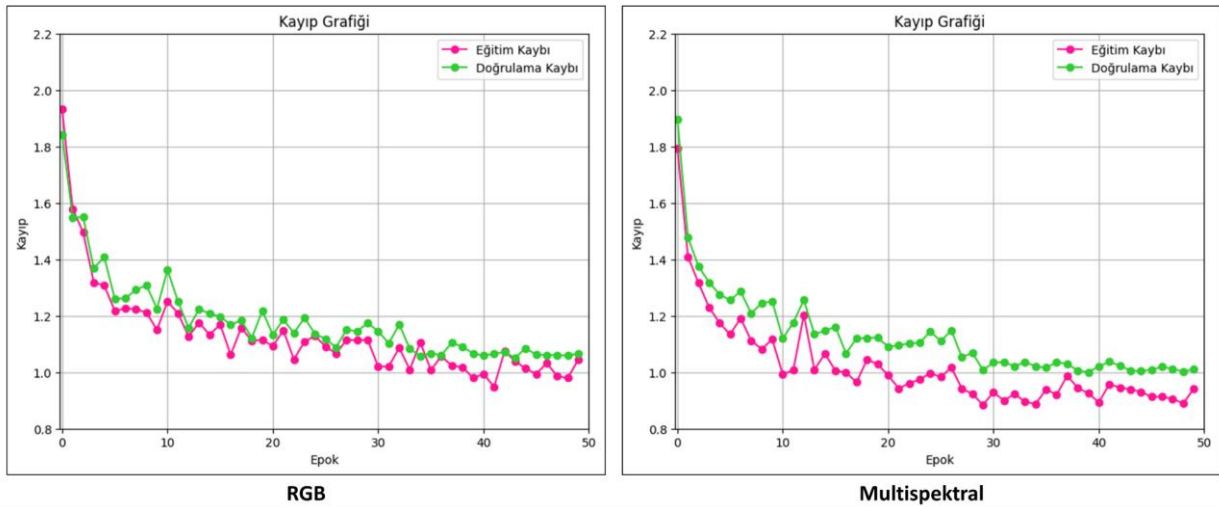
4. Bulgular ve Tartışma

Ayçiçeği çiçek tablalarının tespiti için oluşturulan iki farklı veri seti ile Mask R-CNN modelinin eğitimi ve testi ArcGIS Pro yazılımı Python Uygulama Programlama Arayüzü (API) ve PyTorch derin öğrenme kütüphanesi kullanılarak gerçekleştirilmiştir. Tüm uygulamalarda Intel® Core™ i5-10200H işlemci, 8 GB RAM ve NVIDIA GeForce RTX 1650 Ti ekran kartına sahip bir bilgisayar kullanılmıştır. Mask R-CNN modeli, omurga ağı olarak ResNet-50 mimarisi kullanılarak transfer öğrenme yaklaşımı ile eğitilmiştir. ResNet-50 (Residual Network) (He vd., 2016) ImageNet veriseti üzerinde eğitilmiş 50 katmanlı bir evrimsel sinir ağı olup Mask R-CNN model eğitiminde hızı ve doğruluğu artırmak amacıyla omurga ağı olarak tercih edilmiştir. Öğrenme oranının optimum değerinin tespiti için otomatik öğrenme oranı bulucu (Smith, 2017) fonksiyonu kullanılmış ve modelin omurga ağının eski katmanlarının optimizasyonu için daha küçük bir öğrenme oranı ve ayçiçeği tespiti için yeni eklenen katmanların eğitilmesi için daha büyük bir öğrenme oranı belirlenmiştir. Model girdi boyutu orijinal görüntü boyutlarını korumak amacıyla 256×256 piksel olarak ayarlanmış, yüksek işlem yükü ve ekran kartı sınırlamaları nedeniyle yığın boyutu 2 olarak belirlenmiştir. RGB ve multispektral veri setleri ile ayrı ayrı oluşturulan Mask R-CNN modeli Tablo 1’de verilen hiperparametre kombinasyonları kullanılarak 50 epok boyunca eğitilmiştir.

Tablo 1. Mask R-CNN modeli hiperparametre konfigürasyonu

Hiperparametre	Değer	
	RGB	Multispektral
Omurga Ağı	ResNet-50	ResNet-50
Epok	50	50
Yığın Boyutu	2	2
Öğrenme Oranı (Omurga, Model)	(0,000016, 0,00016)	(0,000013, 0,00013)
Görüntü Boyutu	256×256	256×256

Model eğitim ve doğrulama sürecine ilişkin kayıp grafikleri Şekil 6’da verilmiştir. Her iki grafikten de görüleceği üzere eğitim ve doğrulama kaybı eğitim süresince azalmakta ve yaklaşık 40 epoktan sonra stabil hale gelmektedir. Eğitim kaybı ile doğrulama kaybının birlikte azalma eğilimi göstermesi modellerde aşırı öğrenmenin (overfitting) gözlemlenmediğini, modellerin eğitim veri setinde öğrendiklerini doğrulama veri seti üzerinde genellebildiğini ifade etmektedir. Öte yandan multispektral veri seti ile eğitilen modelin kayıp değerlerinin RGB veri setine göre daha çok yakınsadığı görülmektedir.



Şekil 6. Mask R-CNN modeli eğitim ve doğrulama kaybı

Eğitim sonucunda Mask R-CNN modeli RGB ve multispektral doğrulama veri setleri üzerinde 0,50 IoU eşik değerinde sırasıyla %78,25 ve %84,68 AP değerleri elde etmiştir. Modelin multispektral veri seti üzerinde yaklaşık %6'lık daha yüksek bir AP skoru ile üstün performans göstermesi ayçiçeği çiçek tablası tespitinde çok bantlı görüntülerin kullanılmasının model doğruluğunu arttırdığını göstermektedir. Modelin performansını daha detaylı analiz etmek için eğitilen modellerin test bölgesindeki genelleştirme yeteneği incelenmiştir. Ayçiçeği çiçek tablalarının tespiti için minimum tahmin eşik değeri 0,50 olarak ayarlanmıştır. Buna göre model belli bir güven skoru ile tahmin ettiği ayçiçeklerinden sadece %50'den daha yüksek güven skoruna sahip tahminleri çıktıya dahil etmektedir. Tahmin aşamasında test bölgesinden çıkarılan 256×256'lık piksel boyutlu görüntü parçalarını dört yığın boyutuyla işleme alan model için dolgu (padding) boyutu 64 piksel olarak ayarlanmıştır. Bu sayede model çıkarım sırasında birden fazla görüntü parçasına denk düşen görüntü kenarlarındaki kırılmış ayçiçeği örneklerinin bulunduğu bu bölgeleri sonuca dahil etmemektedir. Bu bölgelerdeki ayçiçekleri bindirmeli olarak bölünen görüntü parçalarından en az birinin içine düştüğü için bir sonraki görüntü parçasında tespit edilmektedir. Böylece modelin, görüntülerin dört bir kenarından 64 piksel içeri dolgu yapılarak sadece merkezi bu dolgulu bölgenin içine düşen nesnelere algılaması sağlanmıştır. Modelin aynı nesne için tahmin ettiği birden fazla çakışan maskelerin elimine edilmesi ve nihai tek bir çıktının elde edilebilmesi için Maksimum Olmayan Bastırma (Non-Maximum Suppression) algoritması uygulanmıştır. Buna göre maksimum bindirme oranı 0,25 olarak belirlenmiş ve böylece aynı nesne için tahmin edilen iki maske arasındaki bindirme oranı %25'ten büyükse o maskeler arasında düşük güven skoruna sahip olan silinerek nihai tespit sonucu elde edilmiştir.

Mask R-CNN modelinin test bölgesindeki RGB ve multispektral veri setleri üzerinde ayçiçeği çiçek tablası tespit doğruluğu 0,50 ve 0,75 IoU eşik değerleri göz önüne alınarak hesaplanmış ve sonuçlar Tablo 2'de verilmiştir. Multispektral veri seti, beş bantlı (R, G, B, kırmızı-kenar (RE) ve yakın kızılötesi (NIR)) bir yapıya sahip olup konumsal çözünürlüğü yaklaşık 2,6 cm iken, RGB veri seti ise daha yüksek bir konumsal çözünürlüğe (yaklaşık 1,4 cm) sahiptir. IoU eşik değeri 0,50 olarak değerlendirildiğinde model multispektral veri seti üzerinde F1 Skor, AP metrikleri için sırasıyla %96,73 ve %94,74 değerlerini elde ederek RGB veri setinden daha üstün performans göstermiştir. Bu fark, multispektral verinin sunduğu spektral veri zenginliğinin, özellikle RE ve NIR gibi bitki ve vejetasyon özelliklerinin spektral olarak ayırt edilmesi noktasında önemli bilgiler sağlayan bantların modelin performansını artırmasıyla ilişkilidir. Spektral bantların bu katkısı, multispektral verinin daha düşük konumsal çözünürlüğüne rağmen doğruluğunun yüksek olmasını sağlamıştır. Diğer taraftan RGB veri setinde multispektrale göre yaklaşık üç kat daha fazla YN tespit edilmiştir. Bu durum, RGB veri setindeki spektral bilginin sınırlı olması nedeniyle modelin daha fazla ayçiçeği örneğini tespit edemediğini göstermektedir. Bununla birlikte, RGB veri setinin daha yüksek konumsal çözünürlüğü, segmentasyon maskelerinin sınırlarını daha net belirlemeye olanak sağlamakta ancak spektral verideki eksiklik, bu avantajı IoU \geq 0,50 durumunda yeterince dengeleyememektedir. Öte yandan IoU eşik değeri 0,75 olarak değerlendirildiğinde, RGB veri seti tüm metriklerde multispektral veriden daha yüksek doğruluk sağlamıştır. Örneğin, F1 Skoru RGB için %78,19 iken multispektral veri setinde %73,57 olarak hesaplanmıştır. Benzer şekilde, AP değeri RGB için %63,50, multispektral veri seti için ise %56,57 olarak bulunmuştur.

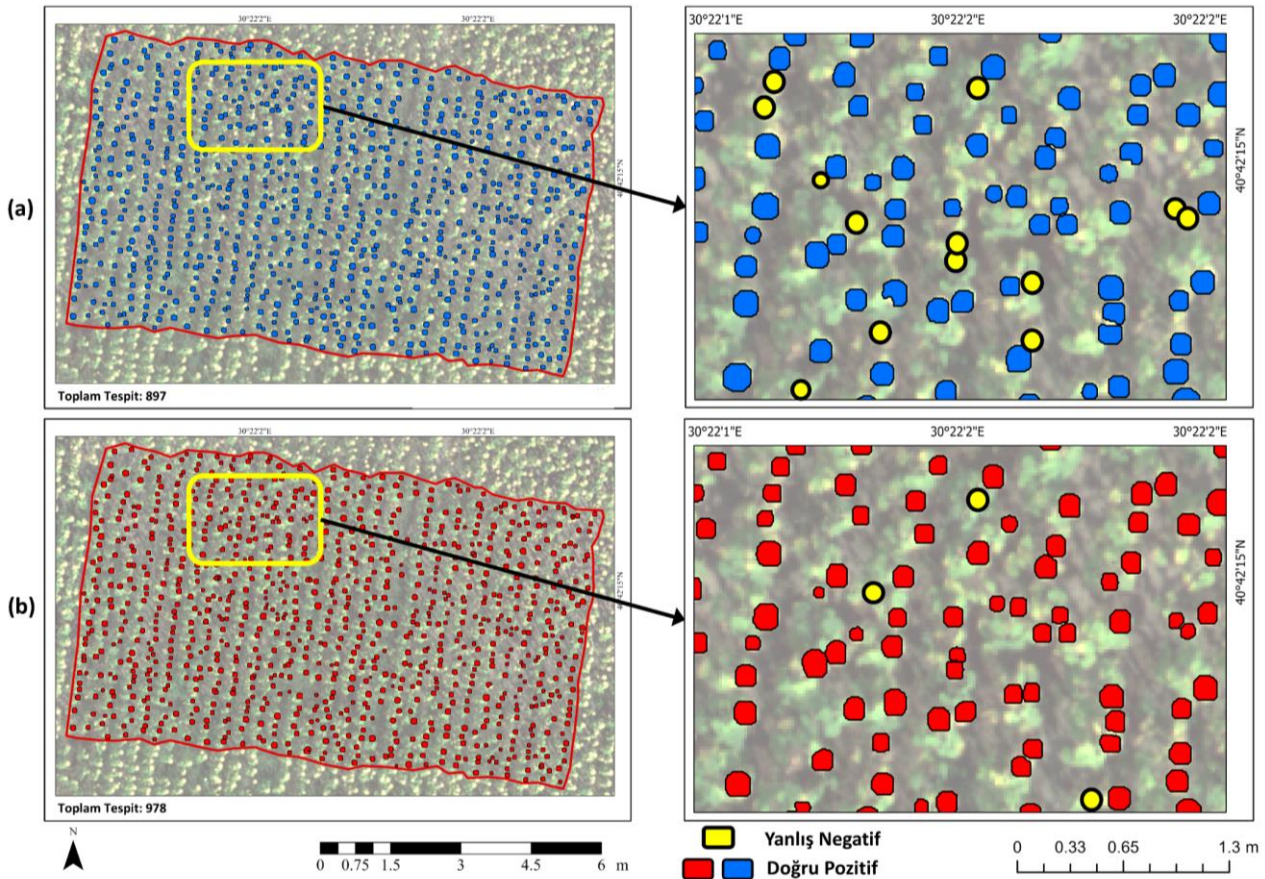
Tablo 2. RGB ve multispektral test veri setleri için 0,50 ve 0,75 IoU eşik değeri için hesaplanan doğruluk metrikleri

Eşik değer	Veri seti	Hassasiyet	Duyarlılık	F1 Skor	AP	DP	YP	YN
IoU \geq 0,50	RGB	<u>0,9810</u>	0,8791	0,9273	0,8746	880	17	121
	Multispektral	0,9785	<u>0,9560</u>	<u>0,9672</u>	<u>0,9474</u>	957	21	44
IoU \geq 0,75	RGB	<u>0,8272</u>	<u>0,7413</u>	<u>0,7819</u>	<u>0,6350</u>	742	155	259
	Multispektral	0,7444	0,7273	0,7357	0,5657	728	250	273

IoU metriği, modelin tahmin ettiği segmentasyon maskelerinin gerçek zemin değerleriyle örtüşüm oranını ölçen bir metrik olup, yüksek eşik değerleri modelin konumsal olarak daha hassas segmentasyonlar üretmeye zorlar. Bu bağlamda, RGB veri setinin konumsal çözünürlüğünün multispektral veri setinden daha yüksek olması, artan IoU eşik değerlerinde (IoU \geq 0,75) RGB veri setinin daha üstün performans göstermesine neden olmuştur. Bu sonuçlar modelin RGB veri seti üzerinde tahmin ettiği ayçiçeği maskelerinin multispektrale göre konumsal olarak daha doğru ve gerçek zemin değerine daha yakın olduğunu ortaya koymaktadır. Bu durum ise RGB veri setinin konumsal çözünürlüğünün yüksek olması ve görüntüde artan detaylar dolayısıyla ayçiçeği nesnelere konumsal olarak ayırt edilebilirliğinin artması ile ilişkilendirilmektedir. Multispektral verinin daha düşük konumsal çözünürlükte olması, bu eşik değerinde segmentasyon doğruluğunu olumsuz yönde etkilemiştir. Ancak, sağladığı spektral verideki zenginlik, özellikle düşük IoU eşik değerlerinde multispektral veriye avantaj sağlamaktadır.

Son olarak, [0,50-0,95] aralığında 10 farklı IoU eşik değeri için hesaplanan AP değerlerinin ortalaması alınarak elde edilen mAP metriği değerlendirildiğinde, RGB ve multispektral veri setleri için sırasıyla %53,43 ve %53,46 değerleri elde edilmiştir. Bu sonuçlar, iki veri setinin genel performansının birbirine oldukça yakın olduğunu ifade etmektedir. Düşük IoU eşik değerlerinde multispektral verinin spektral bilgi içeriği sayesinde üstün performans sergilemesi, yüksek IoU eşik değerlerinde ise RGB verisinin yüksek çözünürlüğünün avantaj sağlaması bu yakın mAP değerlerini açıklamaktadır. Model performansı açısından, her iki veri setinin de belirli senaryolarda önemli avantajlar sunduğu, dolayısıyla kullanım bağlamına göre veri seti seçiminin yapılması gerektiği ifade edilebilir.


RGB ve multispektral veri setleri ile ayrı ayrı oluşturulan nihai Mask R-CNN modelleri ortomozaiklere uygulanmış ve Şekil 7'de kırmızı çizgi ile gösterilen test bölgesi içerisinde yer alan ayçiçeği tablalarına ilişkin tahminlemeler yapılmıştır. Mask R-CNN modellerinin tahmin performanslarının görsel olarak analizi ve karşılaştırılması amacıyla sarı çizgi ile işaretlenen alan özelinde model tahminleri örnek olarak şekilde verilmiştir. Model tahminleri incelendiğinde, her iki veride de modelin ayçiçeklerinin yoğunlaştığı ve birbirine çok yakın konumlandığı bölgelerde daha çok sayıda YN ürettiği görülmektedir. Test bölgesinin 1.001 ayçiçeği örneği içerdiği göz önüne alındığında RGB ortomozaik üzerinde toplam 897 ayçiçeği örneği tahmin edilerek 121 ayçiçeği model tarafından tespit edilememiştir (Şekil 7a). Multispektral ortomozaikte ise 978 ayçiçeği tahmin edilmiş ve RGB'ye kıyasla daha az sayıda (44) ayçiçeği örneği kaçırılarak daha hassas bir ayçiçeği tablası dağılımını gösteren harita üretilebilmiştir (Şekil 7b). Bu durum ise multispektral veride spektral çözünürlüğün artmasıyla birlikte modelin nesnelere spektral karakteristiği hakkında daha çok bilgiye sahip olması ve tespit yeteneğinin artması ile açıklanabilir. Öte yandan artan spektral çözünürlükle birlikte düşen konumsal çözünürlük ise modelin tespit ettiği nesnelere konumlandırmadaki hassasiyetinin düşmesi ile sonuçlanmaktadır. Ancak bölgedeki toplam ayçiçeği tablası sayımı göz önüne alındığında gerçek değere en yakın sonuç multispektral veride elde edildiği için sayımın önemli olduğu verim tahminlemesi gibi hassas tarım uygulamalarında daha önemli envanter verisi sağlayacağı söylenebilir.



Şekil 7. Test veri seti üzerinde tahmin edilen ayçiçeği çiçek tablası haritası: (a) RGB, (b) Multispektral

Model tarafından yapılan hatalı tespitlere ilişkin örnek görseller Şekil 8'de verilmiştir. Modelin özellikle RGB veride, birden fazla ayçiçeğinin bitişik veya üst üste bindiği durumlarda daha çok YN üretme eğiliminde olduğu gözlemlenmektedir.

Derin öğrenme tabanlı obje tespitinde sıklıkla karşılaşılan küçük nesne tespiti problemi göz önüne alındığında modelin RGB veride nispeten daha küçük boyutlu ayçiçeklerinin tespitinde problem yaşadığı görülmektedir. Öte yandan RGB veride tahmin edilemeyen örnekler multispektral veride tespit edilebilse bile hassas bir şekilde nesne sınırlandırması gerçekleştirilememiştir. Özellikle çok sayıda içe içe geçmiş ayçiçeği çiçek tablaları söz konusu olduğunda gerek görüntüdeki konumsal detayın yetersiz oluşu ve gerekse nesne sınırlarının belirgin olmayışı nedeniyle doğru nesne sınırları üretilmemiştir.



Şekil 8. Modelin test veri seti üzerindeki hatalı tespit sonuçları: (a) Örnek 1, (b) Örnek 2

5. Sonuçlar ve Öneriler

Üreme aşamasındaki ayçiçeğinin çiçek tablasının sayısı ve boyutu, tohum verimi ve kalitesini doğrudan etkilediğinden hassas ve otomatik bir şekilde tespiti ve sayımı hassas tarım uygulamaları için son derece önemlidir. Bu çalışmada ayçiçeği çiçek tablalarının İHA ortomozaiklerinden tespiti için derin öğrenme tabanlı örnek segmentasyonu modeli Mask R-CNN'nin performansı araştırılmıştır. Ayrıca RGB ve beş bantlı multispektral verilerin model doğruluğu üzerindeki etkisi irdelenmiştir. Literatürde İHA verilerinden ayçiçeğinin tespiti için çeşitli derin öğrenme tekniklerini kullanan çalışmalar gerçekleştirilmiştir (Jing vd., 2024; Song vd., 2023; Poleshenko vd., 2023). Genel olarak semantik segmentasyon ve obje tespit mimarilerinin kullanıldığı çalışmalarda tek tür veri kaynağı (RGB veya multispektral) kullanılarak model performansı karşılaştırılmasına odaklanılmıştır. Farklı İHA verilerinin konumsal ve spektral çözünürlüklerinin avantaj ve dezavantajlarının incelenmesi noktasında mevcut çalışmada detaylı analizler gerçekleştirilerek literatürdeki araştırma boşluğunun doldurulması amaçlanmıştır. Ayrıca ayçiçeği çiçek tablası tespiti bu çalışmada örnek segmentasyonu problemi olarak ele alınarak literatürde daha önce çalışılmamış Mask R-CNN modeli bu bağlamda ilk kez değerlendirilmiştir.

Deneysel bulgulara göre Mask R-CNN modeli multispektral doğrulama veri setinde 0,50 IoU eşik değerinde %84,68 AP ile RGB veri setinden %6,43 daha yüksek doğruluk elde etmiştir. Eğitilen model ile test veri seti üzerinde yapılan detaylı doğruluk analizi sonuçlarına göre model 0,50 IoU eşik değerinde multispektral veri setinde %96,72 F1 Skor ve %94,74 AP ile daha üstün performans göstermiştir. Öte yandan 0,75 IoU eşik değerinde model RGB veri setinde %78,19 F1 Skor ve %63,50 AP değerlerine ulaşarak multispektral veriden daha yüksek doğruluk elde etmiştir. Bu durum iki ortomozaik arasındaki konumsal ve spektral çözünürlük farklılıkları ile açıklanabilmektedir.

Multispektral ortomozaikte RGB bantlara ek olarak kırmızı-kenar ve yakın kızın ötesi bantlar bulunmakta olup multispektral veri ile eğitilen model ayçiçeği çiçek tablalarının spektral karakteristiği hakkında daha detaylı bilgi öğrenebilmektedir. Buna karşın RGB ortomozaikte yaklaşık 1,4 cm olan konumsal çözünürlük multispektral ortomozaikte yaklaşık 2,7 cm'ye düşmekte ve ayçiçeği detay seviyesinde yaşanan kayıp modelin konumlandırma performansını önemli ölçüde etkilemektedir. Derin öğrenme tabanlı obje tespit çalışmalarında doğruluk analizinde genel olarak temel alınan 0,50 IoU eşik değerine göre çalışmada multispektral veri setinin daha yüksek doğruluk elde etmesi spektral çözünürlüğün yüksek olması ile ilişkilendirilmektedir. Ancak artan IoU eşik değerlerinde modelin konumsal olarak daha hassas tahminleri doğru olarak nitelendirildiği için RGB veri setinde daha yüksek performans göstermesi verinin konumsal çözünürlüğüne dayanmaktadır. Dolayısıyla mevcut çalışma bulgularına göre ayçiçeği çiçek tablasının konum bilgisinin ön planda olduğu çalışmalarda RGB verilerin kullanılmasının, verim tahmini gibi ürün sayısı ile doğrudan ilişkili uygulamalarda ise multispektral verilerin kullanılmasının daha faydalı olacağı sonucuna ulaşılmaktadır.

Bu bulgular İHA verilerinden tarımsal ürünlerin tespiti kapsamında literatürde gerçekleştirilen benzer çalışmalar tarafından da desteklenmektedir. Örneğin, Zheng vd. (2020) İHA görüntülerinden pirinç bitkilerini tespit etmek için karar ağacı tabanlı bir metodoloji uygulamış ve RGB, NIR ve multispektral veriler için genel sınıflandırma doğruluklarını sırasıyla %91,25, %92,88 ve %93,53 olarak elde etmiştir. Çalışmada kullanılan RGB, NIR ve multispektral görüntülerin yer örneklemeye aralıklarının 1,3 cm, 1,4 cm ve 5,4 cm olduğu göz önüne alındığında multispektral verinin düşük konumsal çözünürlüğüne rağmen üstün performans göstermesi çalışma bulgularının mevcut çalışma ile tutarlılık gösterdiğini ortaya koymaktadır. Benzer şekilde Jurišić vd. (2022) tarafından yapılan bir diğer çalışmada İHA görüntülerinden rastgele orman yöntemiyle mısır bitkisinin sınıflandırılmasında en yüksek genel doğruluk değeri RE, NIR ve NDVI kombinasyonunda elde edilirken bunu multispektral ve RGB veri setleri takip etmiştir. Öte yandan Mask R-CNN modeli ile gerçekleştirilen çalışmalara bakıldığında Gao vd. (2023) RGB İHA görüntülerinden Mask R-CNN ile mısır fidelerinin tespitinde konumsal çözünürlüğün etkisini incelemiş ve 30 m, 40 m, 50 m uçuş irtifasında 0,50 IoU eşik değerindeki AP değerlerini sırasıyla %88,7, %87,5, %85,2 olarak elde etmiştir. Konumsal çözünürlüğün 30 m uçuş irtifası için 0,8 cm, 40 m için 1,1 cm ve 50 m için 1,4 cm olduğu göz önüne alındığında uçuş yüksekliğinin azalması ve dolayısıyla konumsal çözünürlüğün artmasıyla model performansının da arttığı görülmüştür. Kozalaklı ağaç fidelerinin tespitinde Fromm vd. (2019) 0,3 cm, 1,5 cm, 2,7 cm ve 6,3 cm konumsal çözünürlüğe sahip RGB İHA görüntülerinden Mask R-CNN modeli ile en yüksek performansı (mAP@0,50=%81) 0,3 cm konumsal çözünürlüğünde elde etmiştir.

Ayrıca çalışma bulgularını etkileyebilecek bir diğer husus ise model eğitiminde kullanılan hiperparametrelerin optimizasyonudur. Çalışmada model eğitiminde donanım kapasitesine uygun olarak en iyi performans gösteren parametreler seçilmiştir. Bu bağlamda model ResNet-50 omurga ağıyla 2 yığın boyutuyla eğitilmiştir. Ancak yüksek donanım kapasitesinin mevcut olması durumunda daha derin bir omurga ağının (ResNet-101 ResNet-152, Inception ResNet vb.) kullanılması hesaplama yükü ile birlikte model performansı da artırabilmektedir. Örneğin, erken aşamada otların RGB İHA görüntülerinden tespiti için Qureshi vd. (2023) tarafından yapılan çalışmada ResNet-50, ResNet-101, ResNeXt-101 omurga ağları ile eğitilen Mask R-CNN modelinin en yüksek doğruluğa 89 milyon parametre ile en kompleks yapıya sahip ResNeXt-101 omurga ağı ile ulaştığı görülmüştür. Bunu %1 farkla 45 milyon parametreye sahip ResNet-101 ağı ve devamında 26 milyon parametreye sahip ResNet-50 ağı takip ederek omurga ağ karmaşıklığı azaldıkça model doğruluğunun da düştüğü gözlemlenmiştir. Bu doğrultuda hiperparametre konfigürasyonunun derin öğrenme modellerinin doğruluğu ve hızı üzerinde önemli bir etkiye sahip olduğu ve mevcut çalışma sonuçlarının daha yüksek başarılı hiperparametreler kullanılarak iyileştirilebileceği de vurgulanmalıdır (Yıldırım & Kavzoglu, 2025).

Genel olarak çalışmanın sonuçları Mask R-CNN modeli ve İHA verilerinin ayçiçeği tespiti ve sayımında hassas ve güvenilir birer araç olarak kullanılabilirliğini vurgulamaktadır. Ayçiçeği tespiti ile ayçiçeği yoğunluğunun belirlenmesi hasat öncesi dönemde verim tahmini konusunda önemli bir veri kaynağıdır. Belirli bir bölgedeki ayçiçeği tespiti ve sayımı özellikle çiftçilere ve uygulayıcılara bireysel ayçiçeğinin büyüme durumu ve fenolojik aşamalarının belirlenmesi noktasında yardımcı olur. Dolayısıyla tarım uygulayıcıları ayçiçeğinin yetiştirme sürecine uygun tarımsal strateji ve politikalar uygulayabilirler. Bu noktada endüstrilerin sulama ve tozlaşma stratejilerini uygun zamanda, miktarda ve yöntemle ayarlamasına yardımcı olacak veriler sağlayarak tohum verimini ve kalitesini artırır.

Çalışmada derin öğrenme teknikleri ve İHA verilerinin hassas tarım uygulamaları kapsamında tarımsal ürünlerin tespitindeki performansı incelenmiş ve özellikle ayçiçeği özelinde literatürde sınırlı sayıda bulunan çalışmalara bir örnek teşkil ederek katkı sağlanmış olsa da halen geliştirilmesi gereken ve gelecek çalışmalarda gerçekleştirilmesi planlanan bazı noktalar bulunmaktadır. Bunlardan ilki derin öğrenme modelinin eğitiminde veri seti olarak İHA yükseklik verilerinin (Sayısal Yükseklik Modeli, Kanopi Yükseklik Modeli vb.) ve NDVI gibi çeşitli vejetasyon indekslerinin ve bunların çeşitli kombinasyonlarının kullanılması ve model performansı üzerine etkilerinin incelenmesi gerekmektedir. Bir diğeri modelin genelleştirilebilirliğinin testi için farklı bir bölgeden alınan ayçiçeği tarlası görüntüsü üzerinde model performansı incelenmelidir. Ürün gelişiminin takibi ve izlenmesi noktasında çalışmada incelenen üreme aşamasına ek olarak farklı fenolojik evrelerde ayçiçeğinin tespit edilebilirliği incelenebilir ve elde edilen sonuçlar ile ürün verim ilişkisi kurulabilir. Model tahminlerinin yorumlanabilmesi için Grad-CAM gibi açıklanabilir yapay zekâ tekniklerinden faydalanılmalı ve bu doğrultuda model performansı iyileştirilmelidir.

Son yıllarda transformatör tabanlı mimarilerin kullandıkları dikkat mekanizmaları sayesinde görüntüdeki küresel bağımlılıkları ve bağlamsal bilgileri kolayca yakalama yetenekleri tarımsal uygulamalarda potansiyel kullanım alanlarını artırmıştır. Dolayısıyla, ileriki çalışmalar obje tespiti ve sınıflandırmada popüler olarak kullanılan DETR gibi Transformatör tabanlı modellerin ayıççeği tablalarının tespiti noktasındaki performansının incelenmesine odaklanacaktır.

Kaynaklar

- Albahar, M. (2023). A survey on deep learning and its impact on agriculture: Challenges and opportunities. *Agriculture*, 13(3), Article 540. <https://doi.org/10.3390/agriculture13030540>
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). SegNet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481–2495.
- Bakhsipour, A., Sanaeifar, A., Payman, S. H., & de la Guardia, M. (2018). Evaluation of data mining strategies for classification of black tea based on image-based features. *Food Analytical Methods*, 11, 1041–1050.
- Bouguettaya, A., Zarzour, H., Kechida, A., & Taberkit, A. M. (2022). Deep learning techniques to classify agricultural crops through UAV imagery: A review. *Neural Computing and Applications*, 34(12), 9511–9536.
- Centorame, L., Gasperini, T., Ilari, A., Del Gatto, A., & Foppa Pedretti, E. (2024b). An overview of machine learning applications on plant phenotyping, with a focus on sunflower. *Agronomy*, 14(4), Article 719. <https://doi.org/10.3390/agronomy14040719>
- Centorame, L., Ilari, A., Del Gatto, A., & Pedretti, E. F. (2024a). A systematic review on precision agriculture applied to sunflowers, the role of hyperspectral imaging. *Computers and Electronics in Agriculture*, 222, Article 109097. <https://doi.org/10.1016/j.compag.2024.109097>
- Ding, R., Luo, J., Wang, C., Yu, L., Yang, J., Wang, M., Zhong, S., & Gu, R. (2023). Identifying and mapping individual medicinal plant *Lamiophlomis rotata* at high elevations by using unmanned aerial vehicles and deep learning. *Plant Methods*, 19, Article 38. <https://doi.org/10.1186/s13007-023-01015-z>
- Food and Agriculture Organization. (2022). *Crops and livestock products*. <https://www.fao.org/faostat/en/#data/QCL>
- Fromm, M., Schubert, M., Castilla, G., Linke, J., & McDermid, G. (2019). Automated detection of conifer seedlings in drone imagery using convolutional neural networks. *Remote Sensing*, 11(21), Article 2585. <https://doi.org/10.3390/rs11212585>
- Gao, X., Zan, X., Yang, S., Zhang, R., Chen, S., Zhang, X., Liu, Z., Ma, Y., Zhao, Y., & Li, S. (2023). Maize seedling information extraction from UAV images based on semi-automatic sample generation and Mask R-CNN model. *European Journal of Agronomy*, 147, Article 126845. <https://doi.org/10.1016/j.eja.2023.126845>
- Gao, Z., Luo, Z., Zhang, W., Lv, Z., & Xu, Y. (2020). Deep learning application in plant stress imaging: A review. *AgriEngineering*, 2(3), Article 29. <https://doi.org/10.3390/agriengineering2030029>
- Gibril, M. B. A., Shafri, H. Z. M., Shanableh, A., Al-Ruzouq, R., bin Hashim, S. J., Wayayok, A., & Sachit, M. S. (2024). Large-scale assessment of date palm plantations based on UAV remote sensing and multiscale vision transformer. *Remote Sensing Applications: Society and Environment*, 34, Article 101195. <https://doi.org/10.1016/j.rsase.2024.101195>
- Guo, A., Huang, W., Dong, Y., Ye, H., Ma, H., Liu, B., Wu, W., Ren, Y., Ruan, C., & Geng, Y. (2021). Wheat yellow rust detection using UAV-based hyperspectral technology. *Remote Sensing*, 13(1), Article 123. <https://doi.org/10.3390/rs13010123>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016, June 27–30). *Deep residual learning for image recognition* [Conference presentation]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017, October 22–29). *Mask R-CNN* [Conference presentation]. IEEE International Conference on Computer Vision, Venice, Italy.
- Huang, Y., Reddy, K. N., Fletcher, R. S., & Pennington, D. (2018). UAV low-altitude remote sensing for precision weed management. *Weed Technology*, 32(1), 2–6. <https://doi.org/10.1017/wet.2017.89>
- International Society of Precision Agriculture. (2024). *Precision agriculture definition*. <https://www.ispag.org/about/definition>
- Jing, R., Niu, Q., Tian, Y., Zhang, H., Zhao, Q., Li, Z., Zhou, X., & Li, D. (2024). Sunflower-YOLO: Detection of sunflower capitula in UAV remote sensing images. *European Journal of Agronomy*, 160, Article 127332. <https://doi.org/10.1016/j.eja.2024.127332>
- Jurišić, M., Radočaj, D., Plaščak, I., Galić Subašić, D., & Petrović, D. (2022). The evaluation of the RGB and multispectral camera on the unmanned aerial vehicle (UAV) for the machine learning classification of maize. *Poljoprivreda*, 28(2), 74–80. <https://doi.org/10.18047/poljo.28.2.10>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Karami, A., Quijano, K., & Crawford, M. (2021). Advancing tassel detection and counting: Annotation and algorithms. *Remote Sensing*, 13(15), Article 2881. <https://doi.org/10.3390/rs13152881>

- Kerkech, M., Hafiane, A., & Canals, R. (2018). Deep learning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Computers and Electronics in Agriculture*, *155*, 237–243.
- Li, J., Li, Y., Qiao, J., Li, L., Wang, X., Yao, J., & Liao, G. (2023). Automatic counting of rapeseed inflorescences using deep learning method and UAV RGB imagery. *Frontiers in Plant Science*, *14*, Article 1101143. <https://doi.org/10.3389/fpls.2023.1101143>
- Maxwell, A. E., Warner, T. A., & Guillén, L. A. (2021). Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—Part 1: Literature review. *Remote Sensing*, *13*(13), Article 2450. <https://doi.org/10.3390/rs13132450>
- Padilla, R., Passos, W. L., Dias, T. L., Netto, S. L., & Da Silva, E. A. (2021). A comparative analysis of object detection metrics with a companion open-source toolkit. *Electronics*, *10*(3), Article 279. <https://doi.org/10.3390/electronics10030279>
- Poleshchenko, D., Mikhailov, I., & Petrov, V. (2023, March 29–31). *On the segmentation of sunflower plants in UAV photos* [Conference presentation]. 2023 25th International Conference on Digital Signal Processing and its Applications (DSPA 2023), Moscow, Russian Federation.
- Popescu, D., Stoican, F., Stamatescu, G., Ichim, L., & Dragana, C. (2020). Advanced UAV–WSN system for intelligent monitoring in precision agriculture. *Sensors*, *20*(3), Article 817. <https://doi.org/10.3390/s20030817>
- Qureshi, S., Ameer, A., Zia, A., Latif, A., & Karrila, S. (2023). *Comparing the effectiveness of classic Mask RCNN and vision transformer in early weed detection*. SSRN. <http://dx.doi.org/10.2139/ssrn.4436132>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016, June 27-30). *You only look once: Unified, real-time object detection* [Conference presentation]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA.
- Sanaeifar, A., Guindo, M. L., Bakhshipour, A., Fazayeli, H., Li, X., & Yang, C. (2023). Advancing precision agriculture: The potential of deep learning for cereal plant head detection. *Computers and Electronics in Agriculture*, *209*, Article 107875. <https://doi.org/10.1016/j.compag.2023.107875>
- Schneiter, A. A., & Miller, J. F. (1981). Description of sunflower growth stages. *Crop Science*, *21*(6), 901–903.
- Sefercik, U. G., Nazar, M., Aydın, I., Büyüksalih, G., Gazioglu, C., & Bayirhan, I. (2024). Comparative analyses for determining shallow water bathymetry potential of multispectral UAVs: Case study in Tavşan Island, Sea of Marmara. *Frontiers in Marine Science*, *11*, Article 1388704. <https://doi.org/10.3389/fmars.2024.1388704>
- Seiler, G. J. (1997). Anatomy and morphology of sunflower. In A. A. Schneiter (Ed.), *Sunflower technology and production* (pp. 67–111). American Society of Agronomy, Crop Science Society of America, Soil Science Society of America.
- Singh, P., Pandey, P. C., Petropoulos, G. P., Pavlides, A., Srivastava, P. K., Koutsias, N., Deng, K. A. K., & Bao, Y. (2020). Hyperspectral remote sensing in precision agriculture: Present status, challenges, and future trends. In P. C. Pandey, P. K. Srivastava, H. Balzter, B. Bhattacharya, & G. P. Petropoulos (Eds.), *Hyperspectral remote sensing* (pp. 121–146). Elsevier.
- Smith, L. N. (2017, March 24–31). *Cyclical learning rates for training neural networks* [Conference presentation]. 2017 IEEE Winter Conference on Applications of Computer Vision (WACV), Santa Rosa, CA, USA.
- Song, Z., Wang, P., Zhang, Z., Yang, S., & Ning, J. (2023). Recognition of sunflower growth period based on deep learning from UAV remote sensing images. *Precision Agriculture*, *24*(4), 1417–1438.
- T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı. (2024). *Sakarya İli 2023 Yılı Çevre Durum Raporu*. <https://webdosya.csb.gov.tr/db/ced/icerikler/sakarya-ilcdr-2023-1-20240614095821.pdf>
- T.C. Tarım ve Orman Bakanlığı. (2007). *Ayçiçeği tarımı*. <https://arastirma.tarimorman.gov.tr/etae/Belgeler/EgitimBrosur/2482012115736884.pdf>
- Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü Müdürlüğü. (2023). *2023 durum tahmin raporları*. <https://arastirma.tarimorman.gov.tr/tepege/Belgeler/PDF%20Durum-Tahmin%20Raporları/2023%20Durum-Tahmin%20Raporları/Ayçiçeği%20Durum-Tahmin%20Raporu%202023-392%20TEPGE.pdf>
- Türkiye İstatistik Kurumu. (2023). *Merkezi dağıtım sistemi*. <https://biruni.tuik.gov.tr/medas/?locale=tr>
- Xiao, J., Aggarwal, A. K., Rage, U. K., Katiyar, V., & Avtar, R. (2023). Deep learning-based spatiotemporal fusion of unmanned aerial vehicle and satellite reflectance images for crop monitoring. *IEEE Access*, *11*, 85600–85614.
- Yang, Q., Shi, L., Han, J., Zha, Y., & Zhu, P. (2019). Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images. *Field Crops Research*, *235*, 142–153.
- Yang, X., Ye, Y., Li, X., Lau, R. Y., Zhang, X., & Huang, X. (2018). Hyperspectral image classification with deep learning models. *IEEE Transactions on Geoscience and Remote Sensing*, *56*(9), 5408–5423.
- Yıldırım, E., & Kavzoglu, T. (2025). Deep convolutional neural networks for ship detection using refined DOTA and TGRS-HRRSD high-resolution image datasets. *Advances in Space Research*, *75*(2), 1871–1887. <https://doi.org/10.1016/j.asr.2024.10.028>

- Yıldırım, E., Colkesen, İ., & Sefercik, U. G. (2024a, July 9–10). *Identification of sunflowers (Helianthus annuus L.) from multi-temporal UAV orthomosaics using deep learning models* [Conference presentation]. 9th Advanced Engineering Days, Tabriz, Iran.
- Yıldırım, E., Sefercik, U. G., & Kavzoglu, T. (2024b). Automated identification of vehicles in very high-resolution UAV orthomosaics using YOLOv7 deep learning model. *Turkish Journal of Electrical Engineering and Computer Sciences*, 32(1), 144–165. <https://doi.org/10.55730/1300-0632.4060>
- Zheng, H., Zhou, X., He, J., Yao, X., Cheng, T., Zhu, Y., Cao, W., & Tian, Y. (2020). Early season detection of rice plants using RGB, NIR-G-B and multispectral images from unmanned aerial vehicle (UAV). *Computers and Electronics in Agriculture*, 169, Article 105223. <https://doi.org/10.1016/j.compag.2020.105223>