

Araştırma Makalesi

PlanetScope ve Landsat-8 Uydu Görüntülerinden YOLOv9 Algoritması ile Dairesel Hareketli Sulama Sistemlerinin Tespit Edilmesi

Emre Tunca^{1*} 

¹Düzce Üniversitesi, Ziraat Fakültesi, Biyosistem Mühendisliği Bölümü, Düzce, Türkiye.

*Sorumlu yazar: emretunca@duzce.edu.tr

Geliş Tarihi: 23.03.2024

Kabul Tarihi: 11.07.2024

Öz

Dünya nüfusundaki hızlı artış, sürdürülebilir tarımsal üretimin önemini ve suyun etkin kullanımını kritik hale getirmektedir. Suyun verimli kullanılması ise basınçlı sulama sistemlerinin kullanımını gerektirmektedir. Bu sulama sistemleri arasından dairesel hareketli sulama sistemi (DHSS) etkinliği ile öne çıkmaktadır. Söz konusu sistemlerin sayısı ve kullanımı gibi bilgiler su kaynakları yönetimi konusunda oldukça önemlidir. Bu çalışmada DHSS'nin farklı konumsal çözünürlüğe sahip PlanetScope ve Landsat 8 uydu görüntülerinde Sadece Bir Kez Bakarsınız_v9 (YOLOv9) algoritması kullanılarak tespiti amaçlanmıştır. Bu amaçla yakın tarihli PlanetScope ve Landsat 8 uydu görüntüleri YOLOv9 algoritması ile eğitilmiş ve modellerin başarısı kesinlik, duyarlılık ve F1 skoru ile değerlendirilmiştir. Ayrıca modellerin tespit ettiği DHSS sayıları ile manuel sayılan DHSS sayıları ve modellerin eğitim süreleri de karşılaştırılmıştır. Elde edilen sonuçlara göre PlanetScope ve Landsat 8 uydu görüntülerinde kesinlik, duyarlılık ve F1 skoru değerleri sırasıyla 0,970, 0,928, 0,945 ve 0,966, 0,851, 0,897 olarak hesaplanmıştır. PlanetScope ve Landsat 8 görüntülerine dayalı olarak oluşturulan modeller, DHSS sayısı tahminlerinde benzerlik göstermiştir; bu oranlar sırasıyla %96,1 ve %93,2 olarak belirlenmiştir. Ancak, modelin eğitim süreleri arasında önemli bir farklılık gözlemlenmiştir. PlanetScope görüntülerinin model eğitim süresi 1,810 saat olarak kaydedilirken, Landsat 8 görüntülerinin model eğitim süresi 1,414 saat olarak tespit edilmiştir. Araştırmadan elde edilen sonuçlar, YOLOv9 algoritmasının PlanetScope ve Landsat 8 uydu görüntülerinde DHSS'yi benzer başarı oranları ile tespit edilebildiğini ve bu yöntem su kaynaklarının yönetiminde hızlı ve doğru DHSS tespiti ile kaynak kullanımlarının izlenmesine olanak sağlamaktadır. Ayrıca, elde edilen bulgular ışığında, geliştirilen metodolojinin su kaynakları üzerine politika yapıcılara ve yöneticilere planlama ve karar verme süreçlerinde değerli bir karar destek aracı olarak hizmet edebileceği ortaya konmuştur. Sonuç olarak, bu yaklaşım sürdürülebilir su yönetimine katkıda bulunan potansiyel bir araç olarak kullanılabilirliği değerlendirilmektedir.

Anahtar Kelimeler: YOLO, Nesne tespiti, PlanetScope, Landsat 8, Dairesel hareketli sulama sistemi.

Detection of Center Pivot Irrigation Systems in PlanetScope and Landsat-8 Satellite Imagery Using YOLOv9 Algorithm

Abstract

The exponential increase in global population have been made the critical to sustainable agricultural production and efficient water use. In this regard, pressurized irrigation systems, particularly center pivot irrigation, have emerged as a preeminent technology. Accurate information about the center pivot status such as quantity and availability are crucial for water resource management. In this study, detection of center pivot irrigation areas is aimed using PlanetScope and Landsat 8 satellite image through You Only Look Once_v9 (Yolov9) algorithm. The performance of the YOLOv9 model was evaluated using precision, recall and F1 score. Furthermore, a comparative assessment was conducted between the algorithmically determined count of center pivots and that obtained through manual enumeration. Results showed that, precision, recall and F1 score for PlanetScope imagery were 0.970, 0.928 and 0.945, while for Landsat 8 satellite images were 0.966, 0.851 and 0.897. Trained models for images with different resolutions showed similar number of DHSS estimates (96.1% for PlanetScope and 93.2% for Landsat 8), while the training times for the model were measured as 1,810 hours for PlanetScope images and 1,414 hours for Landsat 8 images. According to the study results, YOLOv9

performs comparably across different spatial resolution datasets, demonstrating its potential as a viable tool for the water resources management.

Keywords: YOLO, Object detection, Landsat 8, PlanetScope, Center pivot irrigation system.

Giriş

Dünya nüfusundaki hızlı artış, gıda talebinde önemli bir yükselişe neden olmaktadır. Bu artan ihtiyacın karşılanabilmesi için tarımsal üretimin sürdürülebilir bir şekilde artırılması gerekmektedir. Bu noktada, tarımsal sulama kritik bir rol oynamaktadır (Akyüz ve Cemek). Ancak, su kısıtlı bir kaynak olduğundan, etkin kullanımı büyük önem taşımaktadır. Dünya genelinde olduğu gibi Türkiye'de de tarım, en fazla su tüketen sektör konumundadır (Karacalar ve İrik, 2024). Bu nedenle, tarımda suyun verimli kullanılmasını sağlamak için basınçlı sulama sistemlerinin yaygınlaştırılması gerekmektedir (Özkaya ve Uçar, 2023). Basınçlı sulama sistemleri arasında ise dairesel hareketli sulama sistemleri (DHSS), su kullanım etkinliği ve işgücü tasarrufu sağlaması nedeniyle en etkili yöntemlerden biri olarak öne çıkmaktadır. Bu sistemlerin doğru planlanması ve yönetimi, tarımsal üretimin sürdürülebilirliği ve verimliliği açısından büyük önem taşımaktadır.

Uzaktan algılama teknolojileri, büyük ölçekli tarım alanlarının izlenmesi, analiz edilmesi ve haritalanması amacıyla etkili araçlar sunmaktadır (Köksal, 2007). Uydu platformları, hava (uçak ve insansız hava araçları) ve yer platformlarına kıyasla daha geniş alanlar için hızlı, ücretsiz veya ucuz veri sağlama gibi avantajlara sahiptir (Köksal ve ark., 2022). Uydu görüntüleri kullanılarak tarımda verim tahmini (Peng ve ark., 2020), bitki su tüketimi tahmini (Dile ve ark., 2020), bitki boyu (Xie ve ark., 2021) ve biyokütle (He ve ark., 2021) haritalama gibi çeşitli uygulamalar başarıyla gerçekleştirilmiştir. Son yıllarda, yapay zekâ teknolojilerinin gelişmesiyle birlikte makine ve derin öğrenme algoritmaları uydu görüntülerine uygulanarak uzaktan algılama tabanlı tarımsal çalışmalarda önemli ilerlemeler kaydedilmiştir. Literatürde, Rassal Orman, Destek Vektör Makinesi, Evrişimli Sinir Ağları (CNN), Uzun-Kısa Süreli Bellek (LSTM) ağları ve Tekrarlayan Sinir Ağları (RNN) gibi derin öğrenme mimarileri kullanılarak ürün sınıflandırma (Kasinathan ve ark., 2021), hastalık tespiti (Harakannavar ve ark., 2022) ve sulama yönetimi (Abioye ve ark., 2022) gibi alanlarda başarılı sonuçlar elde edilmiştir. Bu algoritmalara ek olarak, son yıllarda nesne tespiti için özellikle YOLO (You Only Look Once) algoritması öne çıkmaktadır.

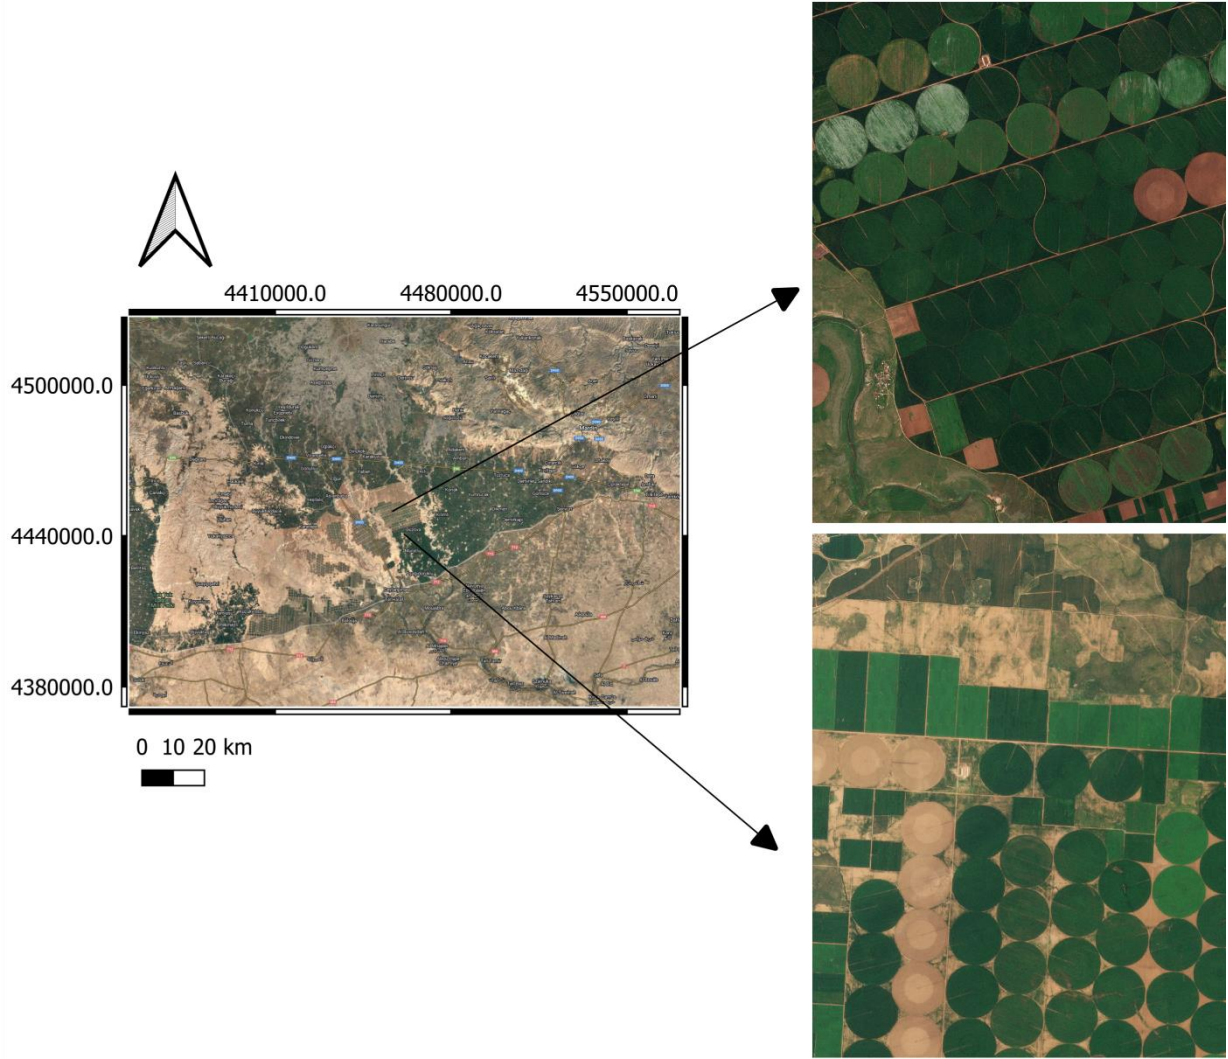
YOLO, gerçek zamanlı nesne tespiti için hızlı ve doğru sonuçlar üreten popüler bir derin öğrenme mimarisidir. Diğer nesne tespit algoritmaları ile karşılaştırıldığında, YOLO daha yüksek doğruluk oranları ve daha kısa işlem süreleri sunmaktadır (Bayram ve Nabeev, 2023). YOLO algoritması, görüntüyü tek bir geçişte işleyerek nesne sınırlarını ve olasılıklarını tahmin eder (Özel ve ark., 2021). Bu sayede, gerçek zamanlı uygulamalar için uygun hale gelmektedir. Literatürde, YOLO algoritması kullanılarak tarımsal nesnelere tespiti üzerine çeşitli araştırmalar gerçekleştirilmiştir. Örneğin, meyve sayımı (Mirhaji ve ark., 2021), hasat zamanının belirlenmesi (An ve ark., 2022), yabancı ot tespiti (Dang ve ark., 2022) ve hastalık belirti tespiti (Mathew ve Mahesh, 2022) gibi uygulamalarda YOLO algoritması başarıyla kullanılmıştır. Literatürde, YOLO algoritması kullanılarak belirli çalışmalar yapılmış olmasına rağmen farklı konumsal çözünürlükteki uydu görüntülerinin karşılaştırmalı olarak değerlendirildiği ve YOLOv9 algoritmasının bu amaçla kullanıldığı kapsamlı bir çalışma henüz mevcut değildir.

Bu çalışmanın temel amacı, farklı konumsal çözünürlüğe sahip PlanetScope ve Landsat 8 uydu görüntülerinde YOLOv9 algoritmasının DHSS alanlarının tespiti üzerindeki performansının değerlendirilmesidir. Ayrıca farklı çözünürlüklü görüntüler ile oluşturulan modellerin eğitim süreleri ile tespit ettikleri DHSS sayılarının manuel sayımlarla karşılaştırılarak modelin farklı çözünürlüklü görüntülerdeki performansının ortaya konulmasıdır.

Materyal ve Yöntem

Çalışma Alanı

Çalışma 2023 yılında Şanlıurfa ilinde yer alan Ceylanpınar Tarım İşletmesi Müdürlüğü'ne ait DHSS alanlarında gerçekleştirilmiştir (Şekil 1). Çalışma alanı Thornthwaite iklim sınıflandırmasına göre yarı kurak iklim özelliği göstermektedir. Uzun yıllar iklim verilerine göre ortalama yıllık toplam yağış miktarı 460.4 mm, ortalama en yüksek sıcaklık 38,8 °C ile Temmuz ayında iken ortalama en düşük sıcaklıklar ise 2,1 °C ile Ocak ayında ölçülmüştür. Çalışma alanındaki toprak bünyesi killi-tınlı ve pH değeri ise 7,47'dir.



Şekil 1. Çalışma alanı konumu ve PlanetScope görüntülerinden dairesel hareketli sulama sistemlerinin genel görünümü.

Figure 1. Study Area Location and overview of Center Pivot Irrigation Systems from PlanetScope Imagery

Çalışmada Kullanılan Uydu Görüntüleri

Çalışmada 2023 yılına ait 4 adet PlanetScope (15 Nisan, 17 Haziran, 16 Temmuz ve 26 Ağustos) ve 4 adet Landsat 8 (17 Nisan, 16 Haziran, 18 Temmuz ve 19 Ağustos) uydu görüntülerinin Kırmızı, Yeşil ve Mavi bantlarından RGB görüntüler oluşturularak kullanılmıştır. Araştırmada, söz konusu iki uydunun seçilmesinde uyduların farklı konumsal, zamansal ve spektral çözünürlüklere sahip olması göz önünde bulundurulmuştur. Böylece farklı özelliklere sahip uydu görüntülerinde YOLOv9 algoritmasının performansını farklı veri setleri üzerinde karşılaştırma fırsatı oluşmuştur. PlanetScope, PlanetLabs Inc. tarafından geliştirilen uydular topluluğudur. Çok sayıda nano uyduların çoklu fırlatılmalarını içeren bu gelişim, dünya yüzeyinin her gün ve dört spektral bantta (Mavi, Yeşil, Kırmızı, NIR) yüksek çözünürlüklü görüntülenmesini sağlar (Çizelge 1).

Table 1. PlanetScope Satellite Image Band Specifications

Çizelge 1. PlanetScope Uydu Görüntüleri Bant Özellikleri Tablosu

Bant No	Bant Adı	Dalgaboyu Aralığı (nm)	Uzamsal Çözünürlük (m)
1	Mavi	455 - 515	3
2	Yeşil	500 - 590	3
3	Kırmızı	590 - 670	3
4	Yakın Kızılötesi	780 - 860	3

Landsat 8, uzaktan algılama çalışmalarında kullanılan en önemli araçlardan biri olarak kabul edilen ve NASA ile USGS iş birliğiyle geliştirilen bir yer gözlem uydusudur. Söz konusu uydu, yer yüzünü orta çözünürlükte görüntüleyebilen iki ana algılayıcıya sahiptir: Operational Land Imager (OLI) ve Thermal Infrared Sensor (TIRS). OLI, multispektral verileri içerirken, TIRS ise termal bant ile yüzey sıcaklığı verisi sunmaktadır (Çizelge 2).

Table 2. Landsat 8 Satellite Image Band Specifications
Çizelge 2. Landsat 8 Uydusu Bant Özellikleri Tablosu

Bant No	Bant Adı	Dalga Boyu Aralığı (µm)	Konumsal Çözünürlük (m)
1	Kısa Dalga Kızılötesi 1	0,435 - 0,451	30
2	Mavi	0,452 - 0,512	30
3	Yeşil	0,533 - 0,590	30
4	Kırmızı	0,636 - 0,673	30
5	Yakın Kızılötesi	0,851 - 0,879	30
6	Kısa Dalga Kızılötesi 1	1,566 - 1,651	30
7	Kısa Dalga Kızılötesi 2	2,107 - 2,294	30
8	Pankromatik	0,503 - 0,676	15
9	Cirrus Bant	1,363 - 1,384	30
10	Termal Kızılötesi 1	10,60 - 11,19	100
11	Termal Kızılötesi 2	11,50 - 12,51	100

Yolov9 Algoritması

YOLO, 2015 yılında nesne tespiti görüntülerden nesne tespiti amacıyla geliştirilmiş bir algoritmadır. Açık kaynak kodu, çeşitli geliştirici ve toplulukların desteği ile hızlıca gelişti ve birçok veri bilimci, yapay zekâ mühendisi ve araştırmacılar tarafından büyük bir ilgi gördü. 2024 yılının Şubat ayında YOLO sürümünün 9.sürümü olan YOLOv9, Wang ve ark. (2024) tarafından tanıtıldı. Bu model, evrişim ve dönüşüm tabanlı mevcut tüm yaklaşımları aşmayı hedefleyen gelişmiş bir gerçek zamanlı nesne algılama modelidir. YOLOv9 algoritması, gerçek zamanlı nesne tespitinde önemli bir yeri olan Programlanabilir Gradyan Bilgisi (PGI) ve Genelleştirilmiş Verimli Katman Toplama Ağı (GELAN) gibi çığır açan teknikleri bünyesinde barındırmaktadır. PGI, ağın derinliği boyunca temel verilerin korunmasına yardımcı olarak daha güvenilir gradyan üretimi ve sonuç olarak daha iyi model yakınsaması ve performansı sağlar. GELAN ise daha hızlı ve daha doğru tahminler için modelin verimliliğini optimize eder. YOLOv9, YOLOv8'e kıyasla önemli ölçüde daha yüksek doğruluk ve hız sunmaktadır. Ayrıca, model COCO, VOC2007 ve PASCAL VOC2012 gibi çeşitli veri kümelerinde de eğitilmiştir.

Yolov9 Modelinin Eğitilmesi

Araştırmada, PlanetScope ve Landsat 8 uydu görüntülerinin Kırmızı, Yeşil ve Mavi bantları kullanılarak RGB görüntüler oluşturulmuştur. Bu görüntüler, araştırma alanını kapsayan vektörler ile kesilmiş ve sadece çalışma alanına ait görüntü hücreleri alınmıştır. Elde edilen görüntüler 256 x 256 piksel boyutlarında karelere ayrılarak toplam 116 adet görüntü elde edilmiştir. Veri setindeki eleman sayısını artırmak için veri çoğaltma tekniği kullanılmıştır. Bu kapsamda:

1. Görüntüler 2 x 2 satır ve sütuna sahip karelere ayrılmıştır.
2. Modelin nesnelerin yönüne olan hassasiyetini azaltmak için tüm görüntüler hem yatay hem de dikey yönde çevrilmiştir (Flip).
3. Tüm görüntüler hem saat yönünde hem de saat yönünün tersinde 90°C döndürülerek veri seti genişletilmiştir.

Son olarak, ilgisiz ve kalitesi düşük görüntüler veri setinden uzaklaştırılarak veri setinin son hali oluşturulmuştur (Tablo 3). Oluşturulan veri seti Google Drive'a aktarılmış ve Google Colab üzerinde modeller eğitilmiştir. Eğitim sonucunda oluşturulan ağırlık dosyaları lokal bilgisayara indirilerek oluşturulan modelin başarı düzeyleri test edilmiştir.

Table 3. YOLOv9 modelinin eğitilmesi için kullanılan örnek görüntü sayıları.
Çizelge 3. YOLOv9 modelinin eğitilmesi için kullanılan örnek görüntü sayıları.

	Eğitim	Test	Doğrulama
PlanetScope	944	49	92
Landsat 8	768	36	76

Analiz ve Değerlendirme

YOLOv9 algoritmasının farklı çözünürlükteki uydu görüntüleri üzerindeki performansını değerlendirmek için kesinlik (precision), duyarlılık (recall) ve F1 skoru metrikleri kullanılmıştır.

Kesinlik, eğitilen modelin tahmin ettiği nesnelerin ne ölçüde doğru olduğunu ifade etmektedir. Düşük kesinlik değeri, modelin birçok hatalı nesne tespit ettiği anlamına gelmektedir. Yüksek kesinlik değeri ise modelin tahmin ettiği nesnelerin önemli ölçüde doğru olduğunu göstermektedir. Bu araştırmada kesinlik değerleri Eşitlik 1 kullanılarak hesaplanmıştır.

$$Kesinlik = \frac{TP}{TP + FP} \quad (1)$$

Eşitlikte TP ve FP değerleri sırasıyla doğru tahmin ve yanlış tahmin sayısıdır.

Duyarlılık, modelin gerçekte pozitif olarak tahmin etmesi gerekenlerin ne kadarını pozitif olarak algıladığının bir göstergesidir. Düşük duyarlılık değeri, modelin birçok nesneyi gözden kaçırdığı anlamına gelmektedir. Yüksek duyarlılık değeri ise eğitilen modelin gerçekte var olan nesnelere çoğunu algıladığını ifade etmektedir. Modeller için duyarlılık değerleri Eşitlik 2'ye göre hesaplanmıştır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (2)$$

F1 skoru ise kesinlik ve duyarlılık değerlerinin bir araya getirilerek hesaplandığı bir metriktir. F1 skoru hem modelin doğru hem de tutarlı bir şekilde nesnelere tespit ettiğini göstermektedir. Yüksek F1 skoru modelin genel olarak iyi bir performans gösterdiğini işaret etmektedir. F1 skoru Eşitlik 3 ile hesaplanmıştır.

$$F1 Skoru = \frac{2 \times Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3)$$

Bulgular ve Tartışma

PlanetScope Uydu Görüntüsü Sonuçları

PlanetScope uydu görüntüleri kullanılarak eğitilen YOLOv9 algoritması, validasyon veri seti üzerinde çalıştırılmış ve elde edilen sonuçlardan bazı örnek görseller Şekil 2'de verilmiştir. Farklı bitki gelişme dönemleri ve zaman dilimlerini kapsayan bu görüntüler incelendiğinde model dairesel hareketli sulama sistemi alanlarını oldukça başarılı bir biçimde tespit ettiği görülmektedir. Sadece vejetasyon olan alanları değil aynı zamanda vejetasyon olmayan dairesel hareketli sulama bölgelerini de başarılı bir biçimde tespit ettiği görülmektedir. Model genel olarak oldukça başarılı tespitler gerçekleştirmesine rağmen bazı dairesel hareketli sulama sistemi alanlarını hatalı/eksik olarak tespit etmiştir (Şekil 3). Şekil 3 incelendiğinde kesikli çizgiler ile gösterilen bölgelerde hatalı tahminler gerçekleştirilmiştir. Söz konusu bölgelerin dairesel bir şekilde olmaması, modelin hatalı tahminde bulunmasının en önemli gerekçesi olarak değerlendirilmektedir. Sınıflandırma sonucu hesaplanan model performans göstergeleri incelendiğinde kesinlik değeri 0,970, duyarlılık değeri 0,928 ve F1 skoru 0,945 olarak hesaplanmıştır. Mekhalfi ve ark. (2021) tarafından gerçekleştirilen bir çalışmada YOLOv5 algoritması kullanılarak doğrusal hareketli sulama sistemi alanlarının tespiti için modelin duyarlılık değeri farklı çalışma alanları için sırasıyla 0,98 ve 0,82 olarak hesaplanmıştır. Söz konusu değerlerin 1,0'e yakın olması YOLOv9 algoritmasının PlanetScope görüntülerinde oldukça başarılı sonuçlar elde ettiğini göstermektedir.

PlanetScope Uydu Görüntüleri



Şekil 2. Yüksek çözünürlüklü PlanetScope görüntülerinde YOLOv9 algoritması ile tahmin edilen dairesel hareketli sulama sistemi alanları

Figure 2. Center pivot irrigation system areas detected by the YOLOv9 algorithm in high-resolution PlanetScope imagery.



Şekil 3. PlanetScope görüntülerinde YOLOv9 algoritması ile eksik/hatalı tahmin edilen dairesel hareketli sulama sistemi alanları

Figure 3. Center pivot irrigation system areas incompletely/incorrectly predicted by the yolov9 algorithm in Planetscope imagery.

Landsat Uydu Görüntüsü Sonuçları

Bu çalışmada, Landsat uydu görüntülerinde YOLOv9 algoritması kullanılarak dairesel hareketli sulama sistemi alanlarının tespiti gerçekleştirilmiş ve sonuçlar Şekil 4'te verilmiştir. Şekil 4 incelendiğinde, genel olarak oldukça başarılı sonuçlar elde ettiği gözlemlenmiştir. Dairesel hareketli sulama sistemi alanlarının çoğu doğru bir şekilde tespit edilmiş ve sınırlayıcı kutular bu alanları tam olarak çevrelemiştir. Ayrıca, yanlış pozitiflerin sayısı da oldukça düşük olduğu görülmektedir. Modelin kesinlik değeri 0.970, duyarlılık değeri 0.928 ve F1 skoru 0.945 olarak hesaplanmıştır. Bu metrikler, modelin dairesel hareketli sulama sistemi alanlarını yüksek doğrulukla tespit ettiğini göstermektedir. Elde edilen yüksek kesinlik değeri, modelin yanlış pozitifleri minimize ettiğini ve tespit edilen alanların gerçekten dairesel hareketli sulama sistemleri olduğunu göstermektedir. Yüksek

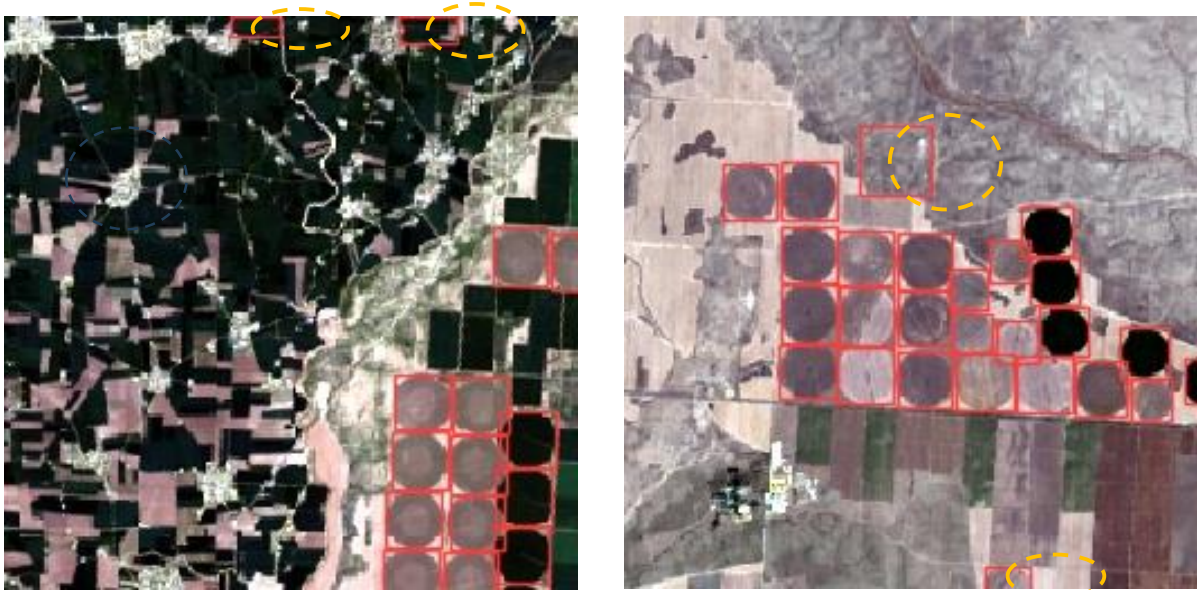
duyarlılık değeri ise modelin çoğu dairesel hareketli sulama sistemi alanını başarıyla tespit ettiğini ortaya koymaktadır. F1 skorunun 0.945 gibi yüksek bir değerde olması, kesinlik ve duyarlılık arasında iyi bir denge kurulduğunu ifade etmektedir. Saraiva ve ark. (2020)'de Landsat uydu görüntülerinden dairesel hareketli sulama sistemi tespiti için kesinlik, duyarlılık ve F1 skoru değerleri sırasıyla 0,99, 0,88 ve 0,93 olarak hesaplanmıştır. Model genel anlamda başarılı sonuçlar üretmesine rağmen, PlanetScope görüntülerinde olduğu gibi, bazı görüntülerde hatalı tahminler gerçekleştirmiştir (Şekil 5). Bu hatalı tespitler, uydu görüntülerindeki gölgeler, bulutlar veya diğer arazi özelliklerinden kaynaklanmış olabilir. Ayrıca bazı dairesel hareketli sulama sistemi alanlarının küçük olması veya görüntü (Landsat) çözünürlüğünün düşük olması da hatalı tespitlere neden olabilmektedir (Liu ve ark., 2020).

Landsat Uydu Görüntüleri



Şekil 4. Landsat 8 uydu görüntülerinde YOLOv9 algoritması ile tahmin edilen dairesel hareketli sulama sistemi alanları

Figure 4. Center pivot irrigation system areas predicted by the yolov9 algorithm in landsat 8 satellite imagery




Şekil 5. Landsat 8 uydu görüntülerinde YOLOv9 algoritması ile eksik/hatalı tahmin edilen dairesel hareketli sulama sistemi alanları

Figure 5. Center pivot irrigation system areas incompletely/incorrectly predicted by the yolov9 algorithm in Landsat 8 imagery

PlanetScope ve Landsat Uydu Görüntülerinin Karşılaştırılması

Araştırmada YOLOv9 ile farklı çözünürlükteki uydu görüntüleri için eğitilen modellerin performansları kesinlik, duyarlılık ve F1 skorları ile değerlendirilmiştir. Ayrıca, modellerin farklı çözünürlüğe sahip uydu görüntüleri üzerinde belirlediği dairesel hareketli sulama sistemi alanı sayıları, manuel olarak sayım değerleri ile karşılaştırılmıştır. Son olarak, farklı çözünürlükteki uydu görüntüleri için model eğitim süreleri de incelenmiştir. PlanetScope uydu görüntüleri için eğitilen modelin kesinlik değeri 0.970, duyarlılık değeri 0.928 ve F1 skoru 0.945 olarak hesaplanmıştır. Landsat uydu görüntüleri için eğitilen modelin kesinlik değeri 0.966, duyarlılık değeri 0.851 ve F1 skoru 0.897 olarak hesaplanmıştır. Bu sonuçlar, YOLOv9 algoritmasının her iki uydu görüntüsü için de dairesel hareketli sulama sistemi alanlarını yüksek doğrulukla tespit ettiğini göstermektedir. Bununla birlikte, PlanetScope modeli daha yüksek kesinlik, duyarlılık ve F1 skorlarına sahiptir. Bu durum, PlanetScope uydu görüntülerinin daha yüksek çözünürlüğe sahip olmasından kaynaklanmaktadır. Redmon ve ark. (2016) farklı çözünürlüklerdeki görüntüler kullanarak YOLO algoritmasında nesne tespiti gerçekleştirmiştir. Araştırma sonucunda yüksek çözünürlüklü görüntülerde modelin daha başarılı olduğu değerlendirilmiştir. Tan ve Le (2019)'da nesne tespitinde yüksek çözünürlüklü görüntülerin, karmaşık çevrelerde daha iyi performans gösterdiği vurgulanmıştır.

Modellerin görsel üzerinde belirlediği nesne sayıları ve manuel sayım değerleri karşılaştırıldığında, her iki modelin de genel olarak manuel sayım değerlerine yakın sonuçlar verdiği görülmektedir (Şekil 6). Ancak, bazı durumlarda modellerin tespit ettikleri nesne sayısında sapma gösterdiği de gözlemlenmiştir. Bu sapmaların başlıca sebepleri arasında bazı dairesel hareketli sulama alanlarının küçük olması veya görüntü kalitesinin düşük olması da gösterilebilir.



Şekil 6. PlanetScope, Landsat 8 uydu görüntülerinde YOLOv9 ile sayılan dairesel hareketli sulama sistemi sayısı ile manuel sayım sonuçları.

Figure 6. Comparison of center pivot manuel caunting and auto detected by the YOLOv9 in PlanetScope and Landsat8 images

Model eğitim süreleri incelendiğinde, PlanetScope modeli için 1,810 saat, Landsat modeli için 1,414 saat süre harcandığı görülmektedir. Bu sürelerin, uydu görüntülerinin boyutları ve çözünürlükleri ile ilişkili olduğu şeklinde değerlendirilmektedir. Daha yüksek çözünürlüklü PlanetScope görüntülerinde nesne tespiti daha başarılı yapılabilmesine rağmen modelin eğitimi düşük çözünürlüklü görüntülere oranla daha fazla süre gerektirmektedir.

Sonuç ve Öneriler

Bu çalışma kapsamında, farklı konumsal çözünürlüğe sahip PlanetScope ve Landsat uydu görüntülerinde YOLOv9 algoritması kullanılarak dairesel hareketli sulama sistemi alanlarının tespiti gerçekleştirilmiştir. Elde edilen bulgulara göre, YOLOv9 algoritması ile her iki tür uydu görüntüsünde de (PlanetScope ve Landsat 8) dairesel hareketli sulama sistemlerini yüksek doğrulukla tespit edilebildiği ortaya konulmuştur.

PlanetScope uydu görüntüleri üzerinde eğitilen modelin yüksek kesinlik, duyarlılık ve F1 skoru değerleri, algoritmanın vejetasyon varlığına bakılmaksızın dairesel hareketli sulama sistemi alanlarını etkili bir şekilde tespit edebildiğini göstermektedir. Ayrıca model, farklı bitki gelişme dönemleri ve zaman dilimleri içinde yüksek doğruluklu sonuçlar üretmiştir. Ancak, modelin bazı dairesel olmayan alanlarda hatalı tahminler yapması, algoritmanın şekil algılama kabiliyetinin sınırlarını da ortaya koymuştur. Landsat uydu görüntüleri üzerinde eğitilen modelin performansı da yüksektir, ancak PlanetScope modeline kıyasla bir miktar daha düşük kesinlik ve duyarlılık değerleri gözlemlenmiştir. Bu durum, Landsat görüntülerinin daha düşük konumsal çözünürlüğe sahip olmasından kaynaklanmaktadır. Modelin bazı durumlarda hatalı tespitler yapması, uydu görüntülerinin kalitesi ve çözünürlüğünün yanı sıra, eğitim veri setinin kapsamı ve çeşitliliği gibi faktörlerden etkilendiği değerlendirilmektedir.

Sonuç olarak, YOLOv9 algoritması, dairesel hareketli sulama sistemlerinin tespiti için güçlü bir araç olarak öne çıkmakta ve farklı çözünürlükteki uydu görüntüleri üzerinde etkili sonuçlar sunmaktadır. Gelecekteki çalışmalarda, farklı spektral ve konumsal çözünürlüğe sahip uydu görüntülerinden ve farklı coğrafi bölgelere ait veri setleri kullanılarak algoritmanın performansı test edilmelidir.

Araştırmacıların Katkı Oranı Beyanı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder (Makale tek yazarlıdır).

Çıkar Çatışması Beyanı

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Kaynaklar

- Abioye, E.A., Hensel, O., Esau, T.J., Elijah, O., Abidin, M.S.Z., Ayobami, A.S., Yerima, O., Nasirahmadi, A., 2022. Precision irrigation management using machine learning and digital farming solutions. *AgriEngineering* 4, 70-103.
- Akyüz, A., Cemek, B., Development of Leaf Area Model in Chokeberry Plant Grown in Different Irrigation Water Quality. *Anadolu Tarım Bilimleri Dergisi* 39, 207-218.
- An, Q., Wang, K., Li, Z., Song, C., Tang, X., Song, J., 2022. Real-time monitoring method of strawberry fruit growth state based on YOLO improved model. *IEEE Access* 10, 124363-124372.
- Bayram, A.F., Nabiye, V., 2023. Derin öğrenme tabanlı saklanan kamufle tankların tespiti: son teknoloji YOLO ağlarının karşılaştırmalı analizi. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi* 13, 1082-1093.
- Dang, F., Chen, D., Lu, Y., Li, Z., 2022. YOLOWeeds: A novel benchmark of YOLO object detectors for weed detection in cotton production systems. *Computers and Electronics in Agriculture*, July.
- Dile, Y.T., Ayana, E.K., Worqlul, A.W., Xie, H., Srinivasan, R., Lefore, N., You, L., Clarke, N., 2020. Evaluating satellite-based evapotranspiration estimates for hydrological applications in data-scarce regions: A case in Ethiopia. *Sci Total Environ* 743, 140702.
- Harakannavar, S.S., Rudagi, J.M., Puranikmath, V.I., Siddiqua, A., Pramodhini, R., 2022. Plant leaf disease detection using computer vision and machine learning algorithms. *Global Transitions Proceedings* 3, 305-310.
- He, L., Wang, R., Mostovoy, G., Liu, J., Chen, J.M., Shang, J., Liu, J., McNairn, H., Powers, J., 2021. Crop biomass mapping based on ecosystem modeling at regional scale using high resolution Sentinel-2 data. *Remote Sens-Basel* 13, 806.
- Karacalar, H., İrik, H.A., 2024. Paşaköy Sulama Birliğinde Sulama Performansının Analizi. *Türk Tarım ve Doğa Bilimleri Dergisi* 11, 1-8.
- Kasinathan, T., Singaraju, D., Uyyala, S.R., 2021. Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture* 8, 446-457.
- Köksal, E.S., 2007. Sulama Suyu Yönetiminde Uzaktan Algılama Tekniklerinin Kullanımı. *Anadolu Tarım Bilimleri Dergisi* 22, 306-315.
- Köksal, E.S., Tunca, E., Taner, S.Ç., 2022. Irrigation management by using digital technologies. *Water and Wastewater Management: Global Problems and Measures*, 247-267.
- Liu, M., Wang, X., Zhou, A., Fu, X., Ma, Y., Piao, C., 2020. Uav-yolo: Small object detection on unmanned aerial vehicle perspective. *Sensors* 20, 2238.
- Mathew, M.P., Mahesh, T.Y., 2022. Leaf-based disease detection in bell pepper plant using YOLO v5. *Signal, Image and Video Processing*, 1-7.

- Mekhalfi, M.L., Nicolò, C., Bazi, Y., Al Rahhal, M.M., Alsharif, N.A., Al Maghayreh, E., 2021. Contrasting YOLOv5, transformer, and EfficientDet detectors for crop circle detection in desert. *IEEE Geoscience and Remote Sensing Letters* 19, 1-5.
- Mirhaji, H., Soleymani, M., Asakereh, A., Mehdizadeh, S.A., 2021. Fruit detection and load estimation of an orange orchard using the YOLO models through simple approaches in different imaging and illumination conditions. *Comput Electron Agr* 191, 106533.
- Özel, M.A., Baysal, S.S., Şahin, M., 2021. Derin öğrenme algoritması (YOLO) ile dinamik test süresince süspansiyon parçalarında çatlak tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 1-5.
- Özkaya, C., Uçar, Y., 2023. Basınçlı Sulama Sistemlerinin COPAM Yazılımı ile Performans Analizi: Burdur Çavdır-Küçükalan Örneği. *Ziraat Fakültesi Dergisi* 18, 50-58.
- Peng, B., Guan, K., Zhou, W., Jiang, C., Frankenberg, C., Sun, Y., He, L., Köhler, P., 2020. Assessing the benefit of satellite-based Solar-Induced Chlorophyll Fluorescence in crop yield prediction. *International Journal of Applied Earth Observation and Geoinformation* 90, 102126.
- 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*, pp. 779-788.
- Saraiva, M., Protas, É., Salgado, M., Souza Jr, C., 2020. Automatic mapping of center pivot irrigation systems from satellite images using deep learning. *Remote Sens-Basel* 12, 558.
- Tan, M., Le, Q., 2019. Efficientnet: Rethinking model scaling for convolutional neural networks, *International conference on machine learning*. PMLR, pp. 6105-6114.



This work is licensed under a Creative Commons Attribution CC BY 4.0 International License.