



## AI-Powered Digital Monitoring and Decision Support Model for Smart Farming Applications

Ender Şahinaslan<sup>1,a,\*</sup>

<sup>1</sup>Mudanya Üniversitesi, SSBF Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Bursa, Türkiye.

\*Corresponding author

ARTICLE INFO	ABSTRACT
<p><i>Research Article</i></p> <p>Received : 28.01.2026 Accepted : 01.03.2026</p> <p><b>Keywords:</b> Smart agriculture Artificial intelligence Image analysis Decision support system Information systems</p>	<p>The increase in global population, the impact of climate change on agricultural production, and the limited availability of agricultural land necessitate increasing agricultural productivity and developing digital monitoring systems focused on smart farming. Maintaining genetic purity in seed production is particularly important for crop quality and economic sustainability. However, traditional manual field inspections are insufficient in terms of time, labor, and accuracy across large areas. This study develops a digital monitoring and decision support model integrating AI-powered drones and mobile systems to monitor agricultural production areas and examines its effectiveness in field conditions. The application scenario focuses on monitoring isolation boundaries in seed sunflower production areas and detecting tassels to prevent foreign pollen contamination in seed maize production. The high-resolution aerial images obtained are analyzed using deep learning-based object recognition and pattern recognition algorithms YOLOv5, integrated into mobile and web-based decision support platforms. Field applications demonstrate that the developed model achieves accuracy between 85-96% under different crops and scenarios, maintains low false negative rates, and completes inspections that take hours or days with manual methods in minutes. In addition, approximately 40% of cost savings were achieved in operational processes. The results show that AI-powered digital monitoring systems offer an effective smart farming solution in terms of technical reliability, operational efficiency, and sustainability in agricultural production.</p>

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 14(3): 829-838, 2026

## Akıllı Tarım Uygulamaları için Yapay Zekâ Destekli Dijital İzleme ve Karar Destek Modeli

MAKALE BİLGİSİ	ÖZ
<p><i>Araştırma Makalesi</i></p> <p>Geliş : 28.01.2026 Kabul : 01.03.2026</p> <p><b>Anahtar Kelimeler:</b> Akıllı tarım Yapay zekâ Görüntü analizi Karar destek sistemi Bilişim sistemleri</p>	<p>Küresel nüfusun artması, iklim değişikliğinin tarımsal üretime olan etkisi ve tarım alanlarının sınırlı olması, tarımsal üretkenliği yükseltmeyi ve akıllı tarım odaklı dijital izleme sistemlerinin geliştirilmesini zorunlu hale getirmektedir. Tohum üretiminde genetik saflığın korunması, ürün kalitesi ve ekonomik sürdürülebilirlik için özellikle önemlidir. Bununla birlikte, geleneksel manuel saha incelemeleri, geniş alanlarda zaman, iş gücü ve doğruluk açısından yetersiz kalmaktadır. Bu çalışma, tarımsal üretim alanlarını izlemek için yapay zekâ destekli dronları ve mobil sistemleri entegre eden bir dijital izleme ve karar destek modeli geliştirmekte ve saha koşullarındaki etkinliğini incelemektedir. Uygulama senaryosu, tohumluk ayçiçeği üretim alanlarında izolasyon sınırlarının izlenmesine ve tohumluk mısır üretiminde yabancı polen kontaminasyonunu önlemek için püsküllerin tespitine odaklanmaktadır. Elde edilen yüksek çözünürlüklü hava görüntüleri, derin öğrenme tabanlı nesne tanıma ve desen tanıma algoritmaları YOLOv5 kullanılarak analiz edilmekte, mobil ve web tabanlı karar destek platformlarına entegre edilmektedir. Saha uygulamaları, geliştirilen modelin farklı ürünler ve senaryolar altında %85-96 arasında doğruluk elde ettiğini, düşük yanlış negatif oranlarını koruduğunu ve manuel yöntemlerle saatler veya günler süren incelemeleri dakikalar içinde tamamladığını göstermektedir. Ek olarak, operasyonel süreçlerde yaklaşık %40 oranında maliyet tasarrufu sağlanmıştır. Sonuçlar, yapay zekâ destekli dijital izleme sistemlerinin, tarımsal üretimde teknik güvenilirlik, operasyonel verimlilik ve sürdürülebilirlik açısından etkili bir akıllı tarım çözümü sunduğunu göstermektedir.</p>

<sup>a</sup> [ender.sahinaslan@mudanya.edu.tr](mailto:ender.sahinaslan@mudanya.edu.tr) <https://orcid.org/0000-0001-8519-7612>



This work is licensed under Creative Commons Attribution 4.0 International License

## Giriş

Küresel nüfus artışı, iklim değişikliğinin tarımsal üretim üzerindeki baskıları ve doğal kaynakların giderek sınırlanması, tarım sektörünü daha verimli, sürdürülebilir ve kalite odaklı üretim modellerine yöneltmektedir. Birleşmiş Milletler tarafından yayımlanan nüfus projeksiyonları, dünya nüfusunun 2050 yılı itibarıyla yaklaşık 9,7 milyara ulaşacağını ve gıda üretiminin bu artışı karşılayacak biçimde yeniden yapılandırılması gerektiğini ortaya koymaktadır (United Nations DESA, 2019). Bu gelişmeler doğrultusunda tarım sektörü, yalnızca üretim miktarını artırmaya odaklanan geleneksel yaklaşımlardan uzaklaşarak, veriye dayalı ve dijital teknolojilerle desteklenen bir dönüşüm sürecine girmiştir.

Dijitalleşme, toplumsal, ekonomik ve çevresel alanları dönüştürürken tarım sektörünü de köklü biçimde etkilemektedir (Dayıoğlu & Turker, 2021). Bu değişim, Tarım 4.0'ın dijital ve akıllı yeniliklerin üretime dahil edilmesini, Tarım 5.0'ın ise bu yeniliklerin insan merkezli, sürdürülebilir ve toplumsal faydayı önceliklendiren bir yaklaşımla kullanılmasını belirtmesiyle ortaya konmaktadır (Wolfert ve ark., 2017; Saiz-Rubio & Rovira-Más, 2020). Elde edilen bulgular, tarla bitkileri yetiştiriciliğinde dijital dönüşümün zorunlu olduğunu ve bu teknolojilerin yaygınlaşmasının tarımsal rekabet gücünü artırabileceğini göstermektedir (Severoğlu, 2025).

Günümüzde tarım, alışılmış üretim unsurlarının sınırlarını aşarak büyük veri, YZ ve nesnelerin interneti (IoT) gibi dijital yeniliklerle biçimlenen ileri teknoloji bir yapıya evrilmiştir (Kenney ve ark., 2020; Purnama & Sejati 2023). Bu bakımdan tarım sektörünün dijitalleşmesi, bunun yaygınlaştırılmasını desteklemek çok önemlidir (Pakdemirli ve ark., 2021). Türkiye’de dijital tarımda yeni teknolojilere geçiş artık öncelikli hale gelmiştir. Kamu destekleri ve özel sektör iş birlikleriyle tarım dronları, sensörler, YZ yazılımları ve mobil analiz çözümleri öne çıkan teknolojilerdir (Bağcı, 2025). Akıllı tarım teknolojileri planlama ve sürdürülebilirliğe katkı sağlamanın yanında sensörler, YZ ve otomasyon araçlarıyla iş gücü tasarrufu ve gıda güvenliğini

desteklediğini de ortaya koymaktadır (Yılmaz & Tunali, 2024). Akıllı tarım uygulamalarında YZ teknolojilerinin kullanım alanları giderek çeşitlenmekte olup, belli başlı uygulama alanları Çizelge 1’de sunulmaktadır.

Çizelgede yer alan veriler, YZ teknolojilerinin tarımsal üretimin çeşitli evrelerinde nasıl bütünsel bir biçimde kullanıldığını göstermektedir. Görüntü analizi, makine öğrenimi, IoT ve büyük veri analizi gibi bilgi teknolojileri üretim planlamasından sulama yönetimine, hastalık ve zararlıların tespit edilmesinden sera optimizasyonuna kadar pek çok alanda uygulanma imkânı sunmaktadır. Bu teknolojilerin entegrasyonu, maliyetlerin düşürülmesine, doğal kaynakların daha etkin kullanılmasına ve ürün verimliliğinin artırılması gibi birçok alanda işletmelere yardımcı olmaktadır. Ayrıca, karar destek sistemleri sayesinde gerek tarım işletmelerine gerekse çiftçilere daha isabetli ve zamanında kararlar alma fırsatı sunmakta, tarımsal faaliyetlerin sürdürülebilirliğine de katkı sunmaktadır.

Uygulama alanlarından biri de tarımsal üretimde izleme ve denetim faaliyetleridir. Geleneksel yöntemlerde tarla kontrolleri büyük ölçüde saha personelinin fiziksel gözlemlerine dayanmaktadır. Özellikle geniş alanlarda yüksek iş gücü ve zaman gereksinimi doğurmakta ve insan hatasına açık bir yapı sergilemektedir (Mulla, 2013). Bu nedenlerle geleneksel tarla kontrolleri, geniş üretim alanlarında sürdürülebilir olmaktan giderek uzaklaşmaktadır.

Bu sınırlılıkların aşılmasında sensör, dron ve YZ gibi dijital teknolojilerin kullanımı öne çıkmaktadır. Özellikle tohumluk üretim gibi kalite hassasiyeti yüksek alanlarda bu teknolojilere duyulan ihtiyaç giderek artmaktadır. Örneğin, tohumluk ayçiçeği üretiminde izolasyon mesafelerinin etkin biçimde denetlenememesi veya tohumluk mısır üretiminde yabancı tozlaşmayı önlemek amacıyla tepe püsküllerinin zamanında tespit edilememesi, genetik saflığın bozulmasına ve ciddi ekonomik kayıplara yol açabilmektedir.

Çizelge 1. Tarımda YZ uygulama alanları, amaçları ve kullanılan teknolojiler

Table 1. Application areas, objectives, and technologies used for AI in agriculture

Kullanım Alanı	Amacı	Kullanılan Teknolojiler
Bitki Sınıflandırması	Bitki türlerinin otomatik olarak tanımlanması	Görüntü işleme, derin öğrenme, bilgisayarlı görü
Zararlı Tespiti	Bitkilere zarar veren böcek ve organizmaların erken tespiti	Görüntü işleme, derin öğrenme (CNN), dron ve kamera sistemleri
Hastalık Tespiti	Bitki hastalıklarının erken aşamada teşhis edilmesi	YZ destekli görüntü analizi, makine öğrenmesi, sensörler
Gübre Seçimi	Toprak yapısına ve bitki ihtiyacına uygun gübrenin belirlenmesi	Toprak sensörleri, veri analitiği, makine öğrenmesi
Sulama Yönetimi	Su kaynaklarının verimli kullanılması ve bitkinin ihtiyacına göre sulama	IoT sensörleri, YZ algoritmaları, hava durumu tahmin sistemleri
Üretim Planlaması	Ekim zamanı ve ürün deseninin optimize edilmesi	Büyük veri analizi, tahminleme modelleri, karar destek sistemleri
İzleme ve Denetim	Tarım alanlarının, bitki gelişiminin ve çevresel koşulların sürekli izlenmesi; anomali ve risklerin erken tespiti	IoT sensörleri, uydu, insansız hava aracı, dron görüntüleri, YZ zekâ tabanlı veri analizi, gerçek zamanlı izleme sistemleri
Verim Tahmini	Çevresel ve üretim verilerine dayalı olarak ürün veriminin tahmin edilmesi	Makine öğrenmesi, derin öğrenme, uydu/dron görüntüleri, sensör verileri

Bu tür kayıpların önlenmesinde uydu tabanlı uzaktan algılama sistemleri geniş alanları kapsama avantajı sunsa da mekânsal çözünürlük, bulutluluk ve veri tekrar sıklığı gibi sınırlamalar parsel düzeyinde hassas uygulamaları zorlaştırmaktadır (Mulla, 2013). Bu bağlamda dron türü insansız hava araçları (İHA), tarımsal uygulamalarda giderek daha yaygın biçimde kullanılmaktadır. Bu araçlar düşük irtifada yüksek çözünürlüklü görüntü elde edebilme, esnek operasyon kabiliyeti ve zamansal süreklilik avantajları sayesinde hassas tarım uygulamalarında önemli bir araç hâline gelmiştir (Tsouros ve ark., 2019). Yüksek çözünürlüklü, hızlı ve ekonomik veri sağlayabilmeleri sayesinde bitkilerin durumunu izleme, kontrol, hastalık, stres tespiti, verimlilik tahmini ve yabancı ot belirleme gibi birçok tarımsal uygulamada geleneksel yöntemlerin yerini almaya başlamıştır (Akkamış & Çalışkan, 2020). Bu araçların tarımsal izleme, bitki gelişim takibi ve saha denetim süreçlerinde zaman ve iş gücü açısından sağladığı avantajların önemi her geçen gün artmaktadır. Bu araçlardan elde edilen verilerin anlamlı bilgiye dönüştürülmesinde spektral indeksler ve görüntü analizi yöntemleri yaygın olarak kullanılmaktadır. Bununla birlikte, dron görüntülerinin hassas ve güvenilir biçimde analiz edilebilmesi için nesne tabanlı görüntü analizi ve YZ yaklaşımlarına ihtiyaç duyulmaktadır. YZ, makine öğrenimi ve özellikle derin öğrenme tabanlı yöntemler, tarımsal görüntülerden karmaşık örüntüleri manuel özellik çıkarımına ihtiyaç duymadan öğrenebilmekte ve geleneksel yöntemlere kıyasla daha yüksek doğruluk ve tutarlılık sağlamaktadır (LeCun ve ark., 2015; Kamilaris & Prenafeta-Boldú, 2018). Nitekim bitki sayımı ve çıkış analizi gibi karmaşık görevlerde LiDAR ve YZ destekli İHA sistemleri %97'ye varan doğruluk oranlarına ulaşabilmektedir (Nevavuori ve ark., 2020; Su ve ark., 2023). Benzer şekilde, mısır ve şeker kamışı gibi ürünlerde gerçekleştirilen verim tahmin çalışmalarında da yüksek başarılar elde edilmiştir (Amarasingam ve ark., 2022; Bouguettaya ve ark., 2022; Kakarla ve ark., 2022). Günümüzde yeni nesil dronlar, YZ ve uçtan uca veri işleme teknolojileri sayesinde sahadan elde edilen verileri anlık olarak analiz edebilmekte ve tarımsal izleme ile denetim süreçlerinde önemli bir dönüşüm sağlamaktadır (Severoğlu, 2025).

Tarımda mevcut ve gelecekte artması beklenen zorluklarla başa çıkmak için verimliliği artıracak bilimsel ve teknolojik ilerlemelere daha fazla ihtiyaç duyulmaktadır (Çakmakçı & Çakmakçı, 2023). Tohumluk üretiminde kalite kontrol süreçleri de dâhil olmak üzere tarımın dijital sistemlerle desteklenmesi gerekliliği birçok çalışmada vurgulanmış (Bağcı, 2025; Dayıoğlu & Turker, 2021; Pakdemirli ve ark., 2021; Severoğlu, 2025; Ceylan, 2023) olmasına rağmen, bu sistemlerin saha uygulamalarına yönelik yöntemler ve uygulamalı çalışmalara ilişkin literatürde sınırlı sayıda çalışmaya rastlanmıştır. Li ve ark. (2023), RGB İHA görüntülerini kullanarak kolza çiçek salkımlarının otomatik sayımı amacıyla İHA tabanlı RGB görüntüler üzerinde CBAM modülü entegre edilmiş YOLOv5 modeli kullanmıştır. Benzer şekilde, Feng ve ark. (2023) Sincan'da İHA tabanlı çok spektrumlu görüntülerle pamuk fideleri için YOLOv5, YOLOv7 ve CenterNet kullanılmıştır. Chen ve ark. (2024) ise İHA görüntülerinden mısır püsküllerini tespit etmek için derin öğrenme tabanlı YOLOv8n modelini geliştirmiştir. Jing ve ark. (2024) RGB İHA görüntülerinden ayçiçeği çiçek

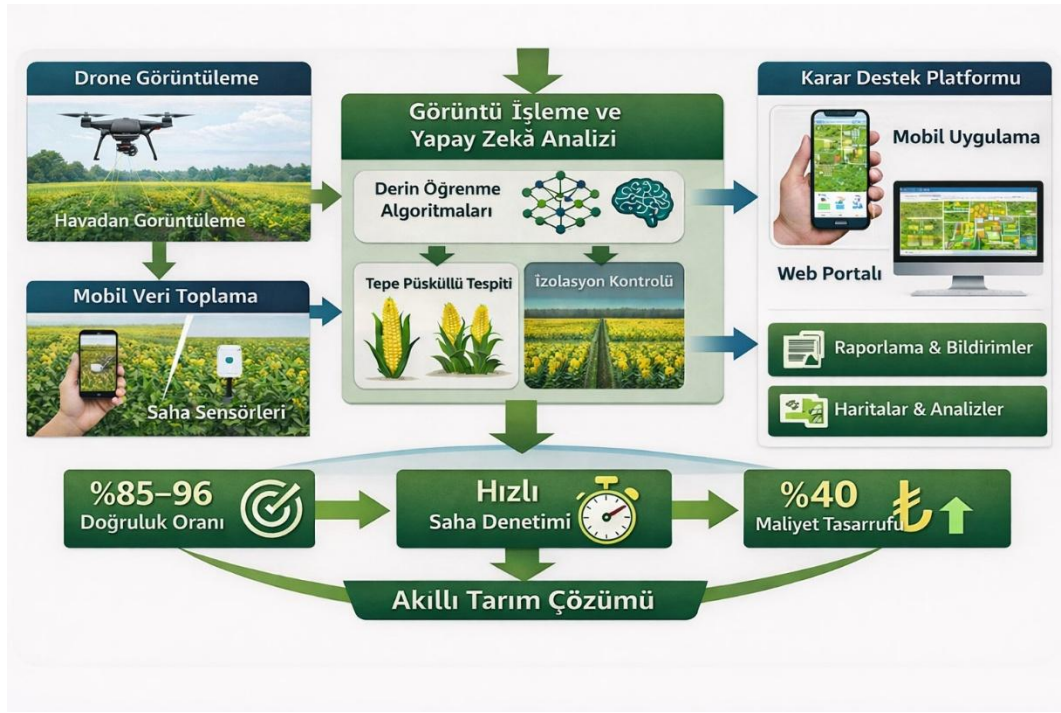
başlarını tanımlamak amacıyla ayçiçeği-YOLO modelini tanıtmıştır. Yıldırım ve ark. (2024) çok zamanlı RGB İHA ortomoziklerini kullanarak çeşitli fenolojik aşamalardaki ayçiçeklerini tespit etmek için U-Net ve DeepLab V3 derin semantik segmentasyon modellerini değerlendirmiştir. Takip eden bir çalışmada, Yıldırım ve ark. (2025) üreme dönemlerindeki ayçiçeklerini tanımlamak için çok zamanlı İHA ortomozikleri üzerinde DETR tabanlı nesne algılama modelinin performansını incelemişlerdir. Baidalin ve ark. (2025) tarafından Kazakistan'da gerçekleştirilen bir çalışmada, İHA tabanlı çok spektrumlu veriler ve ResNet modeli kullanılarak yem bitkilerinin olgunluğu yüksek doğrulukla tahmin edilmiştir. Zhang ve ark. (2025) yapılan çalışmada, İHA tabanlı çok spektrumlu uzaktan algılamanın hassas tarımdaki uygulamalarını kapsamlı biçimde inceleyen bir derleme çalışmada, ürün gelişiminin izlenmesi, hastalık ve zararlı tespiti, besin durumu değerlendirmesi ve verim tahmini gibi temel alanlarda mevcut yaklaşımlar değerlendirilmiştir. Bu inceleme çalışmasında YZ yöntemleriyle entegrasyonunun izleme doğruluğunu artırma potansiyeli taşıdığı vurgulanmıştır.

Bu çalışmanın amacı, tarımsal üretim alanlarının izlenmesine yönelik olarak YZ destekli dron ve mobil sistemlerin entegre edildiği bir dijital izleme modeli geliştirmek ve bu modelin saha uygulamalarındaki performansını değerlendirmektir. Çalışma kapsamında, tohumluk ayçiçeği üretiminde izolasyon denetimi ve tohumluk mısır üretiminde tepe püskülü tespiti temel uygulama senaryoları olarak ele alınmıştır. Elde edilen bulgular, önerilen yaklaşımın yüksek doğruluk sağladığını, operasyonel süreçleri hızlandırdığını ve karar verme süreçlerini etkin biçimde desteklediğini göstermektedir. Bu yönüyle çalışma hem uluslararası literatüre hem de Türkiye'de dijital tarım ve hassas tarım uygulamalarına yönelik çalışmalara bütüncül bir katkı sunma potansiyeline sahiptir.

## Materyal ve Yöntem

Bu çalışmada, tarım alanlarının takip edilmesi amacıyla YZ destekli dronlar ile mobil sistemlerin bir araya getirildiği bir dijital izleme ve karar verme modeli geliştirilmiştir. Bu model, tohum üretimi alanında güney Marmara bölgesinde faaliyet yürüten bir işletmenin saha şartlarında Nisan-Haziran ayları arasında test edilmiştir. Modelin veri toplama, analiz etme ve karar verme aşamalarına dair yöntemsel yapısı, çalışmanın amacına uygun olarak oluşturulmuştur. Önerilen sisteme ait model Şekil 1'de sunulmaktadır. Bu şekil, geliştirilen modelin kavramsal ve yöntemsel yapısını görselleştirmek amacıyla, araştırmacı tarafından tanımlanan bileşenler esas alınarak üretken YZ aracı (ChatGPT) tarafından üretilmiştir ve sadece modeli açıklayıcı bir amaç taşımaktadır.

Şekil 1'de gösterilen dijital izleme sistemi dron platformu, YZ destekli görüntü analiz modülü, mobil ve internet uygulamaları ile veri saklama ve internet sunucu altyapısını kapsayan bütünlümlü bir yapıdır. Bu model dahilinde, tarım alanlarından elde edilen yüksek çözünürlüklü görüntüler dron/İHA aracılığıyla toplanmakta ve kablosuz iletişim altyapısı vasıtasıyla merkezi sunucuya iletilmektedir. Elde edilen veriler, YZ ve derin öğrenme tabanlı algoritmalar kullanılarak işlenmektedir.



Şekil 1. YZ Destekli Dijital İzleme ve Karar Destek Modeli  
Figure 1. AI-Powered Digital Monitoring and Decision Support Model

Bitki durumu, gelişim farklılıkları ve istenen fenolojik özellikler otomasyonla belirlenmektedir. Analiz sonuçları, mobil ve internet tabanlı kullanıcı arayüzleri aracılığıyla anlık ya da gerçek zamana yakın şekilde sahadaki kullanıcılara sunulmakta ve bu sayede izleme, gözetleme ve karar verme süreçleri etkin olarak desteklenmektedir.

Araştırma yöntemi olarak deney tasarımı, veri toplama, veri ön işleme, YZ modeli geliştirme, sistem entegrasyonu ve istatistiksel değerlendirme olmak üzere altı ana aşamadan oluşmaktadır.

#### Deney Tasarımı

Araştırma, tohumluk ayçiçeği ve tohumluk mısır üretilen tarım arazilerinde uygulanmıştır. Bu araziler, genetik saflığın korunmasının önemli olduğu ve düzenli olarak denetlenmesi gereken üretim bölgeleri niteliğindedir. Deneysel düzende, gözlemsel ve uygulamalı saha çalışmaları temel alınarak oluşturulmuştur. Ayçiçeği üretim alanlarında izolasyon mesafelerinin kontrol edilmesi, mısır üretim bölgelerinde ise yabancı tozlaşmanın engellenmesi amacıyla tepe püskülü tespitinin ana uygulama yöntemleri arasında olduğu görülmüştür. Her iki ürün grubuna yönelik veri toplama aşaması, bitkilerin fenolojik evreleri göz önünde bulundurularak planlanmıştır. Bu sayede hem model eğitime hem de saha performansında yüksek temsil yeteneğine sahip veri setleri oluşturulmuştur.

#### Veri Toplama ve Donanım Altyapısı

Çalışma kapsamında, işletmeye ait 500 dekarlık mısır ve ayçiçeği üretim alanlarından bitkilerin çiçeklenme dönemlerinde veri toplanmıştır. Çalışma sahası, üretim yoğunluğu ve ürün çeşitliliğini temsil edecek biçimde amaçlı (*purposeful*) örnekleme yöntemiyle seçilmiştir. Bu yaklaşım, genetik saflık açısından kritik öneme sahip alanların veri setine dahil edilmesini sağlamıştır. YZ modellerinin geliştirilmesi sürecinde öncelikle veri

toplama, ön inceleme ve temizleme aşamaları yürütülmüştür. Ardından veri seti düzenlenmiş, eğitim-doğrulama-test alt kümelerine ayrılmış ve uzman denetiminde etiketleme işlemleri gerçekleştirilmiştir.

Saha çalışmalarında toplanan veriler doğrultusunda, mısır tepe püskülüne ilişkin 2-10 dakika arasında süren 115 video ve ayçiçeği izolasyonu için 3-12 dakika aralığında bulunan 46 video veri setine eklenmiştir. Söz konusu videolar, alan uzmanlarının değerlendirmeleri doğrultusunda işlenerek YZ eğitime uygun hâle getirilmiştir. Ayrıca mobil ve web uygulamaları aracılığıyla bulut tabanlı altyapı üzerinden toplanan ve uzmanlar tarafından etiketlenen görüntüler de veri setine dâhil edilmiştir.

Görüntüler, yüksek çözünürlüklü RGB kamera ve multispektral sensörlere sahip insansız hava araçları kullanılarak toplanmıştır. Uçuşlar, 10-40 metre irtifa aralığında gerçekleştirilmiş ve farklı ışık koşullarını temsil edecek şekilde sabah ve öğle saatlerinde tekrar edilmiştir. Konumsal doğruluğu artırmak amacıyla gerçek zamanlı kinematik konumlandırma sistemi kullanılmış ve görüntüler santimetre seviyesinde hassasiyetle haritalanmıştır. Veriler bitki yoğunluğu, çevresel şartlar ve ürün çeşitliliğini dikkate alacak şekilde bakımından farklı alanlardan toplanmıştır. Bu yöntemle modelin geçerliliğinin geniş alanlarda artırılması hedeflenmiştir.

#### Veri Ön İşleme ve Etiketleme Süreci

Ham görüntüler, analiz öncesi veri ön işleme sürecinden geçmiştir. Bu süreçte; düşük çözünürlüklü, bulanık veya aşırı ışık koşullarında çekilmiş görüntüler veri kümesinden çıkarılmıştır. Modelin aşırı uyum sağlamasını engellemek için döndürme, ölçekleme ve parlaklık ayarları gibi veri artırma yöntemleri kullanılmıştır.

Etiketleme işlemi, uzman ziraat mühendislerinin denetimi altında yapılmıştır. Ayçiçeği yetiştirme

alanlarındaki izolasyon ihlalleri ile ilgili bölgeler, mısır yetiştirme alanlarında ise tepe püsküllerine ait görüntüler üzerinde sınır kutuları ile manuel olarak işaretlenmiştir. Etiketleme aşamasında, tutarlılığın sağlanması için aynı görüntüler birden fazla uzman tarafından incelenmiştir.

### Yapay Zekâ Modeli

Nesne tanıma, model geliştirme ve görüntü analizi süreçlerinde derin öğrenme temelli yapay sinir ağı mimarileri tercih edilmiş olup, analizler YOLOv5 modeli kullanılarak gerçekleştirilmiştir. Model geliştirme süreci Python tabanlı PyTorch/TensorFlow ortamında gerçekleştirilmiştir. Alan çalışmalarından toplanan ham veriler işlenerek, mısır tepe püskülü modeli için 2. 800 eğitim, 800 doğrulama ve 250 test verisi; ayçiçeği izolasyonu modeli için ise 2. 100 eğitim, 600 doğrulama ve 200 test verisi hazırlanmıştır. Modelin başarısı, doğruluk, kesinlik, duyarlılık ve F1 skoru gibi bilinen ölçütler aracılığıyla değerlendirilmiştir. Özellikle tohumluk üretiminde önemli olan yanlış negatif sonuçların azaltılması amaçlanmıştır. Eğitim süreci süresince aşırı öğrenmeyi engellemek için erken durdurma ve çapraz doğrulama yöntemleri kullanılmıştır.

### Mobil ve Web Tabanlı Sistem Entegrasyonu

Geliştirilen YZ modelleri, saha koşullarında kullanılabilmesi amacıyla mobil ve web tabanlı platformlara entegre edilmiştir. Mobil uygulamalar, internet bağlantısının sınırlı olduğu alanlarda da çalışabilecek şekilde çevrimdışı analiz yeteneğiyle tasarlanmıştır. Web tabanlı platform ise merkezi veri yönetimi, raporlama ve görselleştirme işlevlerini yerine getirmektedir.

Bu bütünlük yapı sayesinde, dron/İHA ile elde edilen görüntüler sahada anlık olarak analiz edilebilmekte ve sonuçlar karar vericilere hızlı biçimde sunulabilmektedir.

### Performans Ölçütleri ve İstatistiksel Yöntem

Geliştirilen YZ modellerinin performansı, sınıflandırma ve nesne tanıma ile ilgili literatürde yaygın olarak başvuru ölçütleri aracılığıyla incelenmiştir. İstatistiksel analizlerde doğruluk, hata oranları ve güven aralıkları belirlenmiştir. Karşılaştırmalı analizlerde %95 güven aralığı kullanılmış ve  $p < 0.05$  anlamlılık düzeyi esas alınmıştır. Gerekli olması durumunda, iki yöntem arasındaki farklılıkların anlamlılığı, karşılaştırmalı istatistiksel testler ile ele alındı. İstatistiksel analizlerde doğruluk, hata oranları ve güven aralıklarının hesaplanmasında aşağıda belirtilen bilinen yöntemler kullanılmıştır.

**Doğruluk (Accuracy):** Modelde doğru şekilde sınıflandırılan örnek sayısının toplam örnek sayısına oranını gösteren bir performans ölçütüdür ve modelin genel sınıflandırma başarısını göstermektedir. Hesaplaması Denklem (1)'de gösterilmektedir.

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

Formülde kullanılan kısaltmalar; TP: Gerçek Pozitif, TN: Gerçek Negatif, FP: Yanlış Pozitif, FN: Yanlış Negatif anlamına gelir (Powers, 2011).

**Kesinlik (Precision):** Model tarafından pozitif olarak sınıflandırılan örnekler arasından gerçekten pozitif olanların oranını ifade eden performans ölçütüdür. Bu metrik, özellikle yanlış pozitif sonuçların maliyetinin yüksek olduğu durumlarda modelin ayırt edicilik başarısını değerlendirmek amacıyla kullanılmaktadır. Kesinlik değeri, doğru pozitiflerin (TP) sayısının, doğru pozitifler (TP) ile yanlış pozitiflerin (FP) toplamına oranı olarak hesaplanmakta olup Denklem (2)'de gösterilmektedir.

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Duyarlılık, kaçırılan olumlu durumları azaltılması gereken uygulamalarda önemli bir işlev üstlenir (Sokolova & Lapalme, 2009).

**Duyarlılık (Recall):** Veri kümesinde yer alan gerçek pozitif örneklerin model tarafından doğru şekilde tespit edilme oranını ifade eden bir performans ölçütüdür. Bu metrik, özellikle yanlış negatif sonuçların kritik olduğu uygulamalarda modelin kapsayıcılık düzeyini değerlendirmek amacıyla kullanılmaktadır. İlgili değerler hesaplanması Denklem (3)'te gösterilmektedir.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

Duyarlılık, yanlış negatif sayısını azaltmanın hayati olduğu durumlarda modelin etkinliğini ölçmede önemli bir kriter olarak dikkat çekmektedir. (Davis & Goadrich, 2006).

**F1-Skoru:** F1-skoru, kesinlik (precision) ve duyarlılık (recall) metriklerinin harmonik ortalamasını ifade eden bir performans ölçütüdür. Bu metrik özellikle veri setlerinde sınıf dağılımının dengesiz olduğu durumlarda model performansının daha dengeli ve bütüncül olarak değerlendirilmesini sağlar. F1-skoru hesaplanması Denklem (4)'de gösterilmektedir.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

F1-Skoru, özellikle dengesiz veri setlerinde model performansının genel bir göstergesidir (Borandağ, 2024). Elde edilen F-skoru, hassasiyet ve duyarlılığın harmonik ortalaması olup 0 ile 1 arasında değer alır. Bu değer 1'e yaklaşması model başarısının arttığını gösterir ve dengesiz veri kümelerinde güvenilir bir performans ölçütü sunar (Yucalar, 2023).

### Performans Analizi

Ayçiçeği izolasyonunun kontrolü ve mısır tepe püskülünün tespiti için özgü performans analizi gerçekleştirilmiştir. Manuel olarak yapılan saha gözlemleri ile kıyaslanarak kantitatif doğruluk açısından incelenmiştir. Ayrıca, modelin alan uygulamalarındaki başarısını ölçmede Delphi yöntemi kullanılarak uzman görüşlerine dayalı nitel bir değerlendirme yapılmıştır. Bu yöntemde geleceğe yönelik yapılacak bir tahmin için o alanın saha uzmanlarından yararlanılır ve uzlaşma ile bir karara ulaşılmaya çalışılır (Rowe & Wright, 1999; Günerkan ve ark., 2022). Delphi sürecinde, tarım teknolojileri ve hassas tarım alanlarında uzmanlık sahibi profesyonellerden meydana gelen bir ekip aracılığıyla

denetim süresi, çalışan gereksinimi, hata olasılığı, tekrarlanabilirliği ve ölçeklendirilebilirliğine dair kriterler incelendi. Bu yaklaşımla modelin yalnızca teknik becerileri değil, ayrıca pratikteki uygulanabilir olup olmadığı ve operasyonel olarak avantajlarının olup olmadığını da ortaya çıkarmak hedeflemiştir.

### İstatistiksel Karşılaştırma Yaklaşımı

Dijital model ile manuel yöntem arasındaki performans farklarının anlamlılığı, karşılaştırmalı istatistiksel analizlerle değerlendirildi. İki yöntem arasındaki ortalama doğruluk farkının hesaplanmasına ait Denklem (5)'te sunulmaktadır.

$$\Delta Accuracy = Accuracy_{dijital} - Accuracy_{manuel} \quad (5)$$

Edinilen bulguların güvenilirliğini incelemede %95 güven aralığı hesaplandı ve ihtiyaç duyulduğunda parametrik olmayan karşılaştırma testleri kullanıldı.

### Güvenilirlik ve Tekrarlanabilirlik

Modelin güvenilirliğini tespit etmede farklı günlerde ve çeşitli aydınlatma koşullarında toplanan veriler kullanıldı. Aynı alanda tekrarlanan uçuşların sonuçlarının uyumluluğu kontrol edildi ve varyans oranları hesaplandı. Bu yöntemle geliştirilen yöntemin yalnızca belirli koşullara bağlı olmadığını, saha uygulamaları sırasında tutarlı ve tekrarlanabilir sonuçlar elde edilebildiğini görebilmek için uygulanmıştır.

### Yöntemsel Sınırlılıklar

Çalışma kapsamında geliştirilen yöntem, çevresel koşullar ve görüntü kalitesi gibi faktörlerden etkilenebilmektedir. Veri setinin tek üretim sezonuna ait olması ve sınırlı coğrafi bölgede toplanmış olması, modelin farklı iklim koşullarındaki performansını değerlendirmeyi sınırlamaktadır. Modelin daha uzun dönemli, farklı ürün türleri ve coğrafi bölgelerde yeniden eğitilmesi gerekebilecektir. Bu sınırlılıklar, gelecekteki çalışmalar için yeni araştırma alanları sunmaktadır.

### Bulgular ve Tartışma

Bu bölümde, geliştirilen YZ destekli dron ve mobil sistemlerle bütünleşmiş dijital izleme modelinin saha uygulamalarından elde edilen sonuçlar sunulmaktadır. Bulgular; model performansı, operasyonel kazanımlar ve istatistiksel karşılaştırmalar başlıkları altında ele alınmıştır.

### Model Performans Sonuçları

Geliştirilen YZ tabanlı nesne algılama modellerinin performansı farklı senaryolar altında değerlendirilmiştir.

Ayçiçeği izolasyon denetimi ve mısır tepe püskülü tespiti senaryoları için modeller, hem kontrollü ortamda gerçekleştirilen kavram kanıtı (Proof of Concept – PoC) aşamasında hem de gerçek saha koşullarında test edilmiştir. Performans değerlendirmesi, test veri setleri üzerinden doğruluk, kesinlik, duyarlılık ve F1-skoru ölçütleri kullanılarak gerçekleştirildi. Elde edilen bulgular Çizelge 2'de sunulmaktadır.

Çizelgedeki performans verileri gözden geçirildiğinde, oluşturulan modellerin PoC aşamasında iki senaryoya da yüksek doğruluk ve F1-skora ulaştığı görülmektedir. Ayçiçeği ve mısır senaryolarında PoC ortamında doğruluk oranlarının yaklaşık %96-97 oranında gerçekleşmesi, modelin kontrollü koşullarda yüksek bir tespit başarısı sergilediğini ortaya koymaktadır. Saha uygulamalarında ise çevresel koşullar, görüntü kalitesi ve operasyonel değişkenlere bağlı olarak sınırlı bir performans düşüşü gözlemlendi. Bütün bunlara rağmen, doğruluk, duyarlılık ve F1-skoru oranlarının yüksek güvenilirlik seviyelerini sürdürdüğü gözlemlendi. YZ modeli, saha koşullarında manuel incelemelere benzer güvenilirlik düzeyine ulaşmıştır.

### Yanlış Negatif Analizi

Tohum üretiminde kayda değer bir rol oynayan yanlış negatif bulgular ele alınmıştır. Yanlış negatif durumları, genellikle izolasyon kurallarının ihlal edilmesi veya tepe püsküllerinin yeterince belirlenememesi gibi genetik saflığı etkileyebilecek olayları içermektedir. Bu tür hatalar, tohum üretiminde kalite kaybına yol açabileceği gibi, uzun vadede de ekonomik kayıplara neden olabilir. Bu nedenle, geliştirilen dijital izleme sisteminin bu hataları azaltma yeteneği dikkate değer bir performans göstergesi olarak değerlendirildi.

Modelin saha şartlarındaki etkinliği görebilmek için yanlış negatif oranları, Yanlış Negatif Oranı = FN / (TP + FN) tanımına uygun bir şekilde hesaplanmıştır. Ayçiçeği tarım senaryosunda yanlış negatif oranı %17.2 olarak belirlenirken, mısır tarım senaryosunda bu oran %7.5 seviyesinde ortaya çıkmıştır. Bu verilere bakıldığında, hazırlanan dijital izleme modelinin yanlış negatif oranlarının kabul edilebilir ve düşük düzeylerde tutulduğu anlaşılmaktadır. Özellikle mısır üretim alanlarında elde edilen düşük yanlış negatif oranı, modelin tarla koşullarında önemli izolasyon ihlallerini ve tepe püskülü oluşumlarını yüksek bir doğrulukla tespit edilmiştir. Oluşturulan bu takip yönteminin tohum üretiminde genetik saflığın korunması açısından güvenli ve kullanışlı bir destek sistemi sağladığını ortaya koymaktadır. Yanlış negatif oranlarının sınırlı kalması, modelin sahada kalite kontrol süreçlerine katkıda bulunabileceğini ve geleneksel manuel denetim yöntemleriyle kıyaslandığında daha tutarlı sonuçlar elde edebileceğini ortaya koymaktadır.

Çizelge 2. YZ Modellerinin Performans Sonuçları

Table 2. Performance Results of AI Models

Senaryo	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-Skoru
Ayçiçeği (PoC)	96.0	94.5	93.8	0.94
Ayçiçeği (Saha)	85.4	84.0	82.8	0.83
Mısır (PoC)	97.1	96.3	95.9	0.96
Mısır (Saha)	94.5	93.5	92.5	0.93

Çizelge 3. Operasyonel Verimlilik Karşılaştırması

Table 3. Operational Efficiency Comparison

Kriter	Manuel Yöntem	Dijital Model
Alan büyüklüğü	500 dekar	500 dekar
Kontrol süresi	5–8 kişi/gün	10–15 dakika
Personel ihtiyacı	5–8 kişi	1 operatör
Tekrar kontrol	Zor	Kolay

Çizelge 4. Operasyonel Maliyet Karşılaştırması

Table 4. Operational Cost Comparison

Kriter	Manuel Yöntem	Dijital Model
İş gücü maliyeti	Yüksek	Düşük
Zaman maliyeti	Yüksek	Çok düşük
Yakıt/lojistik	Yüksek	Düşük
Toplam maliyet	100 (referans)	60

Çizelge 5. Dijital Model ve Manuel Yöntem Performans Karşılaştırılması

Table 5. Comparison of Digital Model and Manual Method Performance

Kriter	Manuel Yöntem	Dijital Model
Kontrol süresi	Saatler–günler	Dakikalar
İş gücü ihtiyacı	Yüksek	Düşük
Hata riski	Orta–yüksek	Düşük
Tekrarlanabilirlik	Düşük	Yüksek
Ölçeklenebilirlik	Sınırlı	Yüksek

### Operasyonel Verimlilik Analizi

İşletmenin operasyonel verimliliğini belirlemede dijital takip sistemi kullanımı ile insan emek gücüne dayalı manuel olarak gerçekleştirilen saha denetim yaklaşımları karşılaştırmalı olarak incelendi. Alan büyüklüğü sabit tutularak kontrol süresi, personel ihtiyacı ve tekrar kontrol edilebilirlik kriterleri değerlendirilmeye alındı. Uygulama sahası, test ve uzman ekibin deneyimine dayalı olarak elde edilen bulgular Çizelge 3'te sunulmaktadır.

Çizelge 3'te yer alan karşılaştırmalı sonuçlar, önerilen modelinin operasyonel süreçlerde belirgin bir verimlilik artışı sağladığı görülmektedir. Aynı büyüklükteki (500 dekar) alan için manuel yöntemle gerçekleştirilen kontrollerin 5-8 kişilik ekiplerle günler sürebildiği, buna karşılık dijital model ile kontrollerin tek bir operatör tarafından 10-15 dakika da tamamlanabildiği gözlemlenmiştir. Bilinen insana dayalı manuel yöntemlerde gözden geçirme süreçlerinin zorluklar barındırdığı, dijital modelde daha hızlı ve daha pratik bir şekilde tekrarlanabildiği, insan gücü ihtiyacını önemli ölçüde azalttığını ve saha yönetiminde verimliliği artırdığını göstermiştir.

### Ekonomik Etki ve Maliyet Analizi

Önerilen modelin ekonomik olarak etkisi, manuel saha kontrol yöntemleri ile karşılaştırmalı olarak ele alınmıştır. Analiz kapsamında iş gücü maliyeti, zaman maliyeti ile yakıt ve lojistik giderleri temel değerlendirme kriterleri olarak belirlenmiştir. Söz konusu kriterlere ilişkin tahmini operasyonel maliyetler, Delphi yöntemi kullanılarak uzman ekiplerin değerlendirmeleri doğrultusunda belirlendi. Bu bulgular Çizelge 4'te sunulmaktadır.

Çizelge 4'te yer alan bulgular incelendiğinde, dijital modelin manuel yönetime kıyasla tüm maliyet kalemlerinde belirgin bir avantaj sağladığı görülmektedir. Özellikle iş gücü ve zamandaki maliyetlerin azalması, dijital modelin otomasyonu ve uzaktan izleme özellikleri

sayesinde operasyonel etkinliğin arttığını ortaya koymaktadır. Yakıt ve lojistik harcamalarındaki düşüş, saha ziyaretlerinin azaltılmasıyla bağlantılıdır. Toplam maliyetler açısından bakıldığında, manuel yöntem 100 birim olarak temel alırsa, dijital modelin yaklaşık 60 birimlik bir maliyetle hayata geçirilebileceği ve bunun da operasyonel maliyetlerde yaklaşık %40'lık bir tasarrufa yol açtığı sonucuna varılmıştır.

### Karşılaştırmalı Performans Analizi

Bu bölümde, araştırmada sunulan dijital model ile klasik manuel saha kontrol tekniklerinin etkinlikleri karşılaştırmalı olarak incelenmiştir. Bu karşılaştırma esnasında denetim süresi, iş gücü gereksinimi, hata olasılığı, tekrarlanabilirliğe ve ölçeklenebilirliğe dair faktörler göz önünde bulundurulmuştur. Edinilen bulgular, Delphi yöntemi kullanılarak oluşturulan uzman görüşleri doğrultusunda değerlendirilmiş ve sonuçlar Çizelge 5'te sunulmaktadır.

Çizelge 5'te sunulan karşılaştırmalı analiz sonuçları incelendiğinde, dijital modelin manuel yönetime kıyasla önemli performans avantajları sağladığı görülmektedir. Kontrol süresi bakımından incelendiğinde, elle yapılan yöntemin saatler veya günler sürebilen bir süreç gerektirdiği, buna karşılık dijital modelin sadece dakikalar içinde sonuç verebildiği tespit edildi. Özellikle zaman kritik süreçlerde dijital yaklaşımın etkinliğini ortaya koymaktadır.

İş gücü ihtiyacı bakımından manuel yöntemin yüksek düzeyde insan kaynağı gerektirdiği, dijital modelde ise otomasyon ve sistematik veri işleme sayesinde bu ihtiyacın önemli ölçüde azaldığı belirlenmiştir. Benzer şekilde, manuel süreçlerde insan faktörüne bağlı olarak hata riskinin orta-yüksek seviyelerde seyrettiği, dijital modelde ise standartlaştırılmış süreçler sayesinde hata riskinin düşük düzeye indirildiği görülmektedir.

Elde edilen bulgular, dijital modelin tekrar kullanılabilirlik ve genişletilebilirlik açısından geleneksel yöntemlerle karşılaştırıldığında belirgin bir avantaj sunduğunu, çeşitli ölçeklerde ve saha koşullarında tutarlı sonuçlar ortaya koyduğunu ve operasyonel etkinlik, doğruluk ve sürdürülebilirlik açısından daha verimli bir çözüm sağladığını ortaya koymaktadır.

### **İstatistiksel Karşılaştırma Sonuçları**

Ayçiçeği ve mısır senaryolarında hesaplanan farkların pozitif olması, dijital modelin elle yapılan yöntemlere göre daha güvenilir sonuçlar verdiğini göstermektedir. Elde edilen bulgular, %95 güven düzeyinde dijital modelin performansının istatistiksel olarak kayda değer olduğunu göstermektedir.

### **Tartışma**

Elde edilen bulgular, YZ destekli dijital izleme modelinin sahada başarılı ve güvenilir bir şekilde çalıştığını ortaya koymaktadır. Modelin farklı ürün ve uygulama senaryolarında %85-96 aralığında doğruluk değerlerine ulaşması, gerçek saha koşullarında karşılaşılan çevresel değişkenlere rağmen teknik yeterliliğin büyük ölçüde korunduğunu göstermektedir. Ayçiçeği senaryosunda mısır senaryosuna kıyasla daha düşük saha doğruluğu elde edilmesi, çiçek tablasının geniş yüzey yapısı ve rüzgâra duyarlılığı ile ilişkilendirilebilir. Değişken ışık koşulları, rüzgâr etkisiyle bitkilerin hareketi ve uçuş yükseklik ve açısındaki farklılıklar, nesnenin spektral dağılımı etkili olmuştur. Performansta gözlenen bu düşüşün, modelin yapısal yetersizliğinden ziyade gerçek saha koşullarındaki çevresel ve operasyonel değişkenlikten kaynaklanmaktadır. Diğer taraftan PoC aşamasında gözlenen yüksek performansın saha uygulamalarında sınırlı bir düşüşle devam etmesi, geliştirilen yaklaşımın yalnızca kontrollü ortamlara özgü değil, gerçek üretim koşullarına uyarlanabilir olduğunu da ortaya koymaktadır. Mısır tepe püskülü tespitinde ise rüzgârlı hava koşullarının püskül yapısında oluşturduğu şekilsel değişkenlik nedeniyle mısır püskülünde farklı görüntü varyantlarının ortaya çıkmasına neden olmaktadır. Bu nedenle tohumluk üretim alanlarında yetişen mısır ve ayçiçeği bitkilerinin homojen görsel özellikler sergilememesi, yalnızca renk odaklı yaklaşımların saha uygulamalarında yetersiz kalabileceğini göstermektedir. İncelenen araştırmalar, tarımsal görsel analizde kalıp tanıma yönelik YZ sistemlerinin akıllı tarım uygulamaları için günümüzde zorunlu hale geldiğini göstermektedir. Model, renk odaklı yöntemleri aşarak mekânsal, yapısal ve durumsal öznitelikleri bir arada incelemekte ve böylece farklı alan koşullarında uyumlu sonuçlar elde etmektedir. Bu açıdan elde edilen sonuçlar, YZ destekli akıllı tarım izleme sistemleri için pratikte başarılı bir şekilde uygulanmış olması literatürde yer verilen benzer çalışmalara ait bulgularla da büyük oranda örtüşmektedir. Ayrıca yanlış negatif oranlarının düşük seviyelerde tutulabilmesi, modelin genetik saflığın korunması açısından kritik riskleri etkin biçimde yönetebildiğini göstermektedir. Özellikle izolasyon ihlalleri ve tepe püskülü oluşumlarının gözden kaçırılması, tohumluk üretimde telafisi zor sonuçlar doğurabileceğinden, bu başarımlı düzeyi modelin operasyonel güvenilirliğini önemli ölçüde artırmaktadır.

Bu yönüyle geliştirilen dijital izleme yaklaşımı, yalnızca verimlilik odaklı bir otomasyon aracı değil, aynı zamanda kalite güvencesi ve risk azaltma mekanizması olarak da değerlendirilebilir. Bulgular, manuel kontrollerde insan faktörüne bağlı olarak ortaya çıkabilen hata risklerinin dijital sistemler aracılığıyla minimize edilebileceğini göstermektedir. Aynı zamanda operasyonel ve ekonomik değerlendirmeler birlikte ele alındığında, dijital modelin saha yönetim süreçlerinde anlamlı bir dönüşüm potansiyeline sahip olduğu da görülmektedir. Manuel yöntemlerle yapılan kontrol işlemlerinin saatler veya günler sürebilmesi, bu süreçlerin dakikalar içinde tamamlanmasını sağlamakta, böylece iş gücü ihtiyacını azaltmakta ve süreçlerin tekrarlanabilirliğini artırmaktadır. İş gücü, zaman ve lojistik maliyetlerindeki iyileşmeler ile operasyonel harcamalarda yaklaşık %40 oranında tasarruf sağlanmıştır. Elde edilen veriler, geliştirilen dijital izleme modelinin ekonomik sürdürülebilirlik açısından uygulanabilirliğini göstermekte ve yüksek katma değerli tarımsal üretim alanlarında stratejik bir yatırım aracı olarak değerlendirilebileceğini ortaya koymaktadır. Bu açıdan inceleme, akıllı tarım ve dijital dönüşüm uygulamalarına somut ve kapsamlı bir katkı sağlamaktadır.

### **Sonuç**

Bu çalışmada, tarımsal üretim alanlarının izlenmesine yönelik olarak YZ destekli dron ve mobil sistemlerin bütünleşmiş bir dijital izleme ve kontrol modeli geliştirildi. Bu modelin saha koşullarında uygulanabilir olup olmadığı ayrıntılı olarak değerlendirildi. Özellikle tohumluk ayçiçeği üretiminde izolasyon denetimi ve tohumluk mısır üretiminde yabancı tozlaşmanın önlenmesine yönelik tepe püskülü tespiti gibi genetik saflık açısından kritik öneme sahip süreçler, önerilen dijital model kapsamında otomatik ve veri temelli bir yaklaşımla ele alınmıştır.

Bulgular, geliştirilen modelin farklı ürün ve uygulama senaryolarında saha koşullarında %85-96 doğruluk aralığında çalışabildiğini ve manuel denetim yöntemleriyle karşılaştırıldığında yüksek bir performans sergilemiştir. Nesne algılama tabanlı YZ modellerinin, çevresel değişkenlere ve saha koşullarına rağmen kabul edilebilir performans seviyelerini koruduğu; özellikle yanlış negatif oranlarının düşük seviyelerde tutulabilmesinin, tohumluk üretimde genetik saflığın korunması açısından önemli bir kalite güvencesi sağladığı belirlenmiştir. Bu sonuçlar, dijital izleme ve karar destek yaklaşımının yalnızca teknik açıdan değil, operasyonel verimlilik ve sürdürülebilirlik bakımından da uygulanabilir bir çözüm sunduğunu ortaya koymaktadır.

Çalışmanın önemli katkılarından biri, operasyonel süreçlerde sağlanan belirgin zaman ve iş gücü tasarrufudur. Geleneksel yöntemlerle saatler veya günler sürebilen saha kontrollerinin dijital model sayesinde dakikalar içerisinde tamamlanabilmesi, tekrarlanabilirlik ve ölçeklenebilirlik yönünden büyük bir avantaj sağlamaktadır. Bununla birlikte, iş gücü, zaman ve lojistik maliyetlerindeki gelişmeler sayesinde operasyonel harcamalarda yaklaşık %40 oranında tasarruf sağlanmıştır. Elde edilen veriler, geliştirilen sistemin ekonomik sürdürülebilirlik açısından geçerli olduğunu ve yüksek katma değerli tarımsal üretim alanlarında stratejik bir yatırım aracı olarak görülmesinin mümkün olduğunu göstermektedir.

Akademik açıdan bu araştırma, insansız hava araçları, YZ tabanlı görüntü analizi ve karar destek sistemlerini bütüncül bir yapıda birleştirerek mevcut literatüre yenilikçi bir katkıda bulunmaktadır. Özellikle genetik saflığın büyük bir önem taşıdığı tohum üretimi süreçlerinde, tamamen dijital bir izleme yönteminin gerçek dünya verileriyle desteklenerek sunulması, araştırmanın literatürdeki yerini pekiştirmektedir. Bu açıdan çalışma, dijital tarım ve akıllı tarım uygulamaları için uygulanabilir ve genişletilebilir bir model önermektedir.

Ancak, çalışmanın bazı kısıtlamaları mevcuttur. Modelin performansı, hava durumu, toprak yapısı gibi çevresel etkenler ve kullanılan teknolojik cihazların özelliklerine bağlı olarak görüntü kalitesini ve veri çeşitliliğini etkileyebilmektedir. Ayrıca, farklı ürün çeşitleri, iklim şartları ve coğrafi bölgeler için modelin yeniden eğitilmesi gerekebilir. Gelecek araştırmalarda, daha geniş ve çeşitli coğrafi alanları kapsayan veri setleri kullanılarak modelin genellenabilirliğinin artırılması amaçlanmaktadır. Bilgi teknolojilerindeki ilerlemelere bağlı olarak, gerçek zamanlı analiz kapasitesinin sisteme dahil edilmesiyle işlem sürelerinin daha da kısalması sağlanabilir. Ayrıca, otomatik eylem önerileri sunan daha gelişmiş ve akıllı karar destek modüllerinin sisteme entegre edilmesi, modelin operasyonel karar alma süreçlerine doğrudan katkı sunabilecek önemli bir iyileştirme alanı olarak görülmektedir.

Sonuç olarak, bu araştırma, tarımsal üretim alanlarının takibinde YZ ile desteklenen dronlar ve mobil sistemlerin bütüncül bir biçimde etkin bir şekilde kullanılabilirliğini ortaya koymaktadır. Geliştirilen yöntem, veriye dayalı, operasyonel maliyetleri azaltan, sürdürülebilir ve uygulanabilir akıllı tarım uygulamaları için YZ destekli bir dijital izleme ve karar destek sistemi sunmaktadır.

## Beyanlar

### **Etik Kurul Onay Belgesi**

Etik kurul onayına gerek yoktur.

### **Finansal Destek**

Çalışmada herhangi bir finansal destek alınmamıştır.

### **Çıkar Çatışması Beyanı**

Herhangi bir çıkar çatışması yoktur.

### **Teşekkür**

Bu çalışmanın uygulama, teknik altyapı ve saha süreçlerinde sağladıkları destekler için Murat Yonar'a ve uzman ekibine teşekkür ederiz.

## Kaynaklar

- Akkamış, M., & Çalışkan, S. (2020). İnsansız hava araçları ve tarımsal uygulamalarda kullanımı. *Türkiye İnsansız Hava Araçları Dergisi*, 2(1), 8-16.
- Amarasingam, N., Salgadoe, A.S.A., Powell, K., Gonzalez, L.F., Natarajan, S. (2022). A review of UAV platforms, sensors, and applications for monitoring of sugarcane crops. *Remote Sensing Applications: Society and Environment*, 26: 100712. <https://doi.org/10.1016/j.rsase.2022.100712>
- Bağcı, A. (2025). Tarımda dijital dönüşüm ve sürdürülebilirlik: Türkiye örneği üzerinden çok boyutlu bir değerlendirme. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 14(5), 2313-2333. <https://doi.org/10.15869/itobiad.1744124>

- Baidalin, M., Rakhimzhanova, T., Akhet, A., Baidalina, S., Myrzakhanov, A., Bogapov, I., Salikova, Z., & Varol, H. A. (2025). AI-powered aerial multispectral imaging for forage crop maturity assessment: A case study in Northern Kazakhstan. *Agronomy*, 15(12), 2807. <https://doi.org/10.3390/agronomy15122807>
- Borandağ, E. (2024). LSRM: A New Method for Turkish text classification. *Appl. Sci.* 14, 11143. <https://doi.org/10.3390/app142311143>
- 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. <https://doi.org/10.1007/s00521-022-07104-9>
- Ceyhan, V. (2023). Türkiye'de Tarım Piyasaları İzleme, Değerlendirme ve Erken Uyarı: Mevcut Durum ve Yeni Yönelimler. *Tarım Ekonomisi Araştırmaları Dergisi*, 9(EKS 1), 26-39. <https://doi.org/10.61513/tead.1361021>
- Chen, J., Fu, Y., Guo, Y., Xu, Y., Zhang, X., Hao, F., (2024). An improved deep learning approach for detection of maize tassels using UAV-based RGB images. *International Journal of Applied Earth Observation and Geoinformation*, 130, 103922. <https://doi.org/10.1016/j.jag.2024.103922>
- Çakmakçı, M. F., & Çakmakçı, R. (2023). Uzaktan algılama, yapay zekâ ve geleceğin akıllı tarım teknolojisi trendleri. *Avrupa Bilim ve Teknoloji Dergisi* (52), 234-246
- Davis, J., & Goadrich, M. (2006). The relationship between precision-recall and ROC curves. *Proceedings of the 23rd International Conference on Machine Learning*, 233-240. <https://doi.org/10.1145/1143844.1143874>
- Dayıoğlu, M. A., & Turker, U. (2021). Digital transformation for sustainable future -agriculture 4.0: A review. *Journal of Agricultural Sciences*, 27(4), 373-399. <https://doi.org/10.15832/ankutbd.986431>
- Feng, Y., Chen, W., Ma, Y., Zhang, Z., Gao, P., & Lv, X. (2023). Cotton seedling detection and counting based on UAV multispectral images and deep learning methods. *Remote Sensing*, 15(10), 2680. <https://doi.org/10.3390/rs15102680>
- Günerkan, M., Şahinaslan, E., & Şahinaslan, Ö. (2022). Gümrük beyannamesi sürecinde öğrenmeye dayalı algoritmaların etkinliğinin incelenmesi. *Acta Infologica*, 6(2), 175-188. <https://doi.org/10.26650/acin.1057060>
- Jiang (Eds.), *Unmanned Aerial Systems in Precision Agriculture*, Smart Agriculture, Springer, Singapore, pp. 1-19
- 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, 127332. <https://doi.org/10.1016/j.eja.2024.127332>
- Kakarla, S.C., Costa, L., Ampatzidis, Y., Zhang, Z. (2022). Applications of UAVs and machine learning in agriculture. In: *Unmanned aerial systems in precision agriculture: technological progresses and applications*. Singapore: Springer *Nature Singapore*; p. 1-19. [https://doi.org/10.1007/978-981-19-2027-1\\_1](https://doi.org/10.1007/978-981-19-2027-1_1)
- 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>
- Kenney, M., Serhan, H. & Trystram, G. (2020). Digitalization and platforms in agriculture: organizations, power asymmetry, and collective action solutions, *ETLA Working Papers*, (No. 78). The Research Institute of the Finnish Economy (ETLA), Helsinki
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://www.nature.com/articles/nature14539>
- 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. *Front Plant Sci.* 14:1101143. <https://doi.org/10.3389/fpls.2023.1101143>

- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, 114(4), 358–371. <https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- Nevavuori, P., Narra, N., Linna, P., Lipping, T. (2020). Crop yield prediction using multitemporal UAV data and spatio-temporal deep learning models. *Remote Sensing*, 12(23): 4000. <https://doi.org/10.3390/rs12234000>
- Pakdemirli B., Birişik N., Aslan İ., Sönmez B., Gezici M. (2021). Türk tarımında dijital teknolojilerin kullanımı ve tarım-gıda zincirinde tarım 4.0. *Toprak Su Dergisi*, 10(1), pp.78-87. doi:10.21657/topraksu.898774
- Powers, D. M. W. (2011). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63. <https://doi.org/10.48550/arXiv.2010.16061>
- Purnama, S., & Sejati, W. (2023). Internet of things, big data, and artificial intelligence in the food and agriculture sector. *International Transactions on Artificial Intelligence*, 1(2), pp.156-174.
- Rowe, G., & Wright, G. (1999). The Delphi technique as a forecasting tool: issues and analysis. *International Journal of Forecasting*, 15(4), 353-375. [https://doi.org/10.1016/S0169-2070\(99\)00018-7](https://doi.org/10.1016/S0169-2070(99)00018-7)
- Saiz-Rubio, V. & Rovira-Más, F. (2020). From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management. *Agronomy*, 10(2), 207. <https://doi.org/10.3390/agronomy10020207>
- Severoğlu, S. (2025). Tarla bitkilerinde kullanılan akıllı tarım teknolojileri. *Türkiye Tarımsal Araştırmalar Dergisi*, 12(3), 348-364. <https://doi.org/10.19159/tutad.1730333>
- Sokolova, M. & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Su, J., Zhu, X., Li, S., Chen, W.H. (2023). AI meets UAVs: A survey on AI empowered UAV perception systems for precision agriculture. *Neurocomputing*, 518: 242-270. <https://doi.org/10.1016/j.neucom.2022.11.020>
- Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A Review on UAV-based applications for precision agriculture. *Information*, 10(11), 349. <https://doi.org/10.3390/info10110349>
- United Nations, Department of economic and social affairs, population division. (2019). *World population prospects 2019: Highlights*. [https://population.un.org/wpp/assets/Files/WPP2019\\_Highlights.pdf](https://population.un.org/wpp/assets/Files/WPP2019_Highlights.pdf)
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. J. (2017). Big data in smart farming. *Agricultural Systems*, 153, 69–80. <https://doi.org/10.1016/j.agsy.2017.01.023>
- Yılmazer, E. B., & Tunalıoğlu, R. (2024). Akıllı tarım uygulamalarında akademi ve özel sektörün rolü. *Tarım Ekonomisi Dergisi*, 30(2), 111-120. <https://doi.org/10.24181/tarekoder.1511288>
- Yildirim, E., Colkesen, I., & Sefercik, U. G. (2025). Transformer-based sunflower recognition from multi-temporal UAV orthomosaics. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVIII-M-6-2025, 309–315. <https://doi.org/10.5194/isprs-archives-XLVIII-M-6-2025-309-2025>
- Yildirim, E., Colkesen, I., Sefercik, U.G. (2024). Identification of sunflowers (*Helianthus annuus* L.) from multi-temporal UAV orthomosaics using deep learning models. 9th Advanced Engineering Days, Tabriz, Iran, 782-785.
- Yucalar, F. (2023). Developing an advanced software requirements classification model using BERT: An empirical evaluation study on newly generated Turkish data. *Applied Sciences*, 13(20), 11127. <https://doi.org/10.3390/app132011127>
- Zhang, S., Wang, X., Lin, H., Dong, Y., Qiang, Z. (2025). A review of the application of UAV multispectral remote sensing technology in precision agriculture, *Smart Agricultural Technology*, 12, 101406, ISSN 2772-3755, <https://doi.org/10.1016/j.atech.2025.101406>.