

Entegre Zararlı Yönetimi Çalışmalarında Akıllı Tarım Sistemlerinin Kullanım Olanakları

Ceyda GÜLER¹  Bahadır ŞİN²  Salih KARABÖRKLÜ^{2*} 

¹Bitki Koruma Anabilim Dalı, Lisansüstü Eğitim Enstitüsü, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye.

²Bitki Koruma Bölümü, Ziraat Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye.

ÖZ

Entegre zararlı yönetimi (EZY), tarımsal üretimdeki zararlı popülasyonlarını ekonomik ve ekolojik açıdan makul seviyelerde tutmayı amaçlayan bir yaklaşımdır. EZY, yalnızca zararlılarla mücadele etmeyi değil; çevre ve insan sağlığını korumayı, doğal düşmanları desteklemeyi ve ekonomik kayıpları minimize etmeyi hedeflemektedir. Günümüzde dijital teknolojilerin hızla gelişimi tarımsal alanlarda zararlı böceklerin hızlı ve doğru şekilde tespit edilmesine olanak tanımıştır. Tarım alanlarında zararlıların erken dönemde tespit edilmesi, popülasyon yoğunluğu artmadan gerekli önlemlerin alınması, uygun mücadele yönteminin belirlenmesi, verim ve kalite kayıplarının önlenmesi açısından büyük önem taşımaktadır. Nesnelerin interneti (IoT), sensörler, dronlar, görüntü işleme teknikleri, yapay zekâ destekli karar destek sistemleri ve otomasyon uygulamaları sayesinde zararlıların erken tespiti, popülasyon dinamiklerinin izlenmesi ve hedefe yönelik mücadeleyi mümkün hale getirmektedir. Bu teknolojiler, makine öğrenmesi ve derin öğrenme algoritmalarıyla birleştirildiğinde, zararlı popülasyonlarının izlenmesi, stres belirtilerinin tanımlanması ve mücadele stratejilerinin optimize edilmesi açısından önemli kazanımlar sağlamaktadır. Görüntü işleme ve sensör tabanlı sistemlerle yapılan çalışmalar, bitkilerde zararlı kaynaklı stresin spektral, termal veya akustik değişimlerle belirlenebildiğini ortaya koymaktadır. Özellikle dron tabanlı görüntüleme sistemleri ve otonom robotlar, geniş tarım alanlarında hızlı veri toplama ve yerinde değerlendirme olanağı sunarak klasik gözlem yöntemlerinin ötesine geçmektedir. Bu yaklaşım, yalnızca zararlı kontrolünde değil; aynı zamanda iklim değişikliğine uyum, kaynak verimliliği ve sürdürülebilir tarım hedeflerinin gerçekleştirilmesinde de stratejik bir öneme sahiptir. Bu durum hem pestisit kullanımının azaltılması hem de çevre dostu ve ekonomik bir üretim sürecinin desteklenmesine katkı sağlayacaktır. Bu çalışma kapsamında, entegre zararlı yönetiminde akıllı tarım sistemlerinin kullanım olanakları ele alınmış ve zararlı böceklerle yönelik yapılan araştırmalar derlenmiştir.

Anahtar Kelimeler: Akıllı tarım sistemleri, Entegre zararlı yönetimi, Zararlı böcekler, Tespit, Yapay zekâ.

*Sorumlu Yazarın e-postası: salihkaraborklu@subu.edu.tr

Cite as: Güler, C., Şin, B. & Karabörklü, S. (2025). Entegre Zararlı Yönetimi Çalışmalarında Akıllı Tarım Sistemlerinin Kullanım Olanakları, *Journal of Agricultural Biotechnology*, 6(2), 81-97. <https://doi.org/10.58728/joinabt.1831254>

Possibilities of Using Smart Agricultural Systems in Integrated Pest Management Studies

ABSTRACT

Integrated pest management (IPM) is a strategy that focuses on sustaining pest populations in agricultural systems at economically and ecologically viable levels. IPM prioritizes pest management while protecting environmental and human health, promoting natural predators, and reducing economic losses. Recent advancements in digital technologies have facilitated swifter and more precise identification of pests and pathogens in agricultural settings. Timely identification is crucial for enacting suitable management strategies prior to the escalation of pest populations and for averting losses in productivity and quality. Technologies including the Internet of Things (IoT), sensors, drones, image processing techniques, artificial intelligence-driven decision support systems, and automation tools enable early pest identification, ongoing monitoring of population dynamics, and precise control strategies. These technologies greatly enhance pest population monitoring, stress symptom recognition, and control choice optimization when paired with machine learning and deep learning algorithms. Studies utilizing image processing and sensor-based systems indicate that pest-induced stress in plants can be determined through spectral, thermal, or sensory alterations. Drone imaging systems and autonomous robots provide swift data collection and on-site evaluation across extensive agricultural fields, exceeding the efficacy of conventional scouting techniques. These strategies are crucial for effective pest management as well as for attaining climate change adaptation, resource efficiency, and long-term agricultural sustainability. These technologies provide targeted interventions, thereby diminishing pesticide application and fostering environmentally sustainable and economically viable farming methods. This study assesses the prospective advantages of smart agricultural technology in IPM and consolidates existing research on the identification and surveillance of insect pests. This study demonstrates that the integration of smart agricultural technologies into IPM offers a promising pathway toward data-driven, environmentally responsible, and economically viable pest management.

Keywords: Smart agriculture systems, Integrated pest management, Insect pests, Detection, Artificial intelligence.

1. Giriş

Dünya nüfusundaki hızlı artış, gıda talebini sürekli olarak yükseltmekte ve mevcut tarımsal üretim kapasitesi üzerinde ciddi bir baskı oluşturmaktadır. Artan talebi karşılamak için tarımsal üretimde verimliliğin artırılması büyük önem taşımaktadır. Ancak, üretim sürecinde karşılaşılan en kritik sorunlardan biri, çeşitli zararlı organizmaların neden olduğu ürün kayıplarıdır. FAO'nun 2023 [1] verilerine göre, tarımsal zararlılar her yıl dünya genelinde %20 ile %40 arasında ürün kaybına neden olmaktadır. Bu oran, iklim koşulları, yetiştirilen ürünün türü, bölgesel üretim sistemleri ve uygulanan mücadele yöntemlerine bağlı olarak değişiklik göstermektedir. Özellikle gelişmekte olan ülkelerde, yetersiz bitki koruma uygulamaları, sınırlı teknolojik imkânlar ve uygun olmayan mücadele stratejileri nedeniyle bu kayıp oranlarının daha da yüksek seviyelere ulaştığı bildirilmektedir [2, 3].

Tarımsal üretimde zararlı organizmaların yol açtığı ürün kayıpları yalnızca üreticinin ekonomik gelirini azaltmakla kalmamakta, aynı zamanda gıda güvenliğini de tehdit etmektedir. Zararlıların kontrolsüz şekilde çoğalması, üreticilerin daha fazla pestisit, iş gücü ve enerji harcamasına neden olarak sürdürülebilir tarım hedeflerini de ciddi şekilde tehdit etmektedir [2]. Bu sorunların önlenmesi için zararlıların erken dönemde ve doğru yöntemlerle tespit edilmesi büyük önem taşımaktadır.

Geleneksel zararlı mücadele yöntemlerinde yaygın olarak kullanılan pestisitler, uygulandıkları dönemde zararlı popülasyonlarını hızla baskı altına alarak kısa vadede yüksek etkinlik göstermektedir. Ancak bu yöntem uzun vadede bazı ciddi sorunlara yol açmaktadır [4]. Sürekli ve yoğun pestisit kullanımı, zararlı

türlerin belirli etken maddelere karşı direnç geliştirmesine neden olmakta, bu da aynı dozların zamanla etkisiz hale gelmesine yol açmaktadır. Bunun yanı sıra pestisitler yalnızca hedef zararlıları değil, ekosistem dengesinin korunmasında önemli rol oynayan faydalı böcekleri, toprak mikroorganizmalarını ve tozlayıcıları da olumsuz etkileyebilmektedir. Ayrıca yanlış veya aşırı uygulamalar sonucunda ürünlerde kalıntı birikimi meydana gelmekte, bu durum hem insan sağlığı açısından risk oluşturmakta hem de gıda güvenliği ve ihracat açısından önemli sorunlara neden olmaktadır. Pestisitlerin çevrede uzun süre kalabilmeleri, toprak ve su kirliliği gibi ekosistem sağlığı üzerinde geri dönüşmesi güç olumsuz etkiler doğurabilmektedir [5]. Olumsuz etkileri nedeniyle pestisitlerin tek başına kullanımı yeterli bir çözüm olarak görülmemektedir ve kimyasal uygulamaların azaltılarak, daha sürdürülebilir yaklaşımların benimsenmesi gerekmektedir.

Bu sorunlar, entegre zararlı yönetimi yaklaşımının tarımsal üretimdeki önemini artırmıştır. Entegre zararlı yönetimi, biyolojik, kültürel, fiziksel, mekanik ve kimyasal mücadele yöntemlerini bir arada ve uyumlu şekilde kullanarak zararlı popülasyonlarını ekonomik zarar eşiği altında tutmayı amaçlayan sürdürülebilir bir stratejidir [6]. Ancak, iklim değişikliği, sıcaklık ve nem değişimleri ile zararlıların üreme hızını ve dağılım alanlarını etkilerken, yeni zararlı türlerin ortaya çıkması ve yayılması mevcut entegre zararlı yönetim stratejilerinin güncellenmesini gerekli kılmaktadır. Ayrıca, artan üretim yoğunluğu ve büyük ölçekli tarım alanları, manuel gözlem ve geleneksel yöntemlerinin yetersiz kalmasına neden olmaktadır. Zararlıların erken tespiti ve hızlı müdahalesi için daha hassas, güvenilir tahmin ve izleme sistemlerine ihtiyaç duyulmaktadır.

Dijital teknolojilerin hızla gelişmesi, özellikle nesnelerin interneti (IoT), sensörler, dronlar, görüntü işleme, yapay zekâ ve otomasyon uygulamaları sayesinde, günümüzde tarımsal alanlarda ciddi verim ve kalite kaybına neden olan zararlı böceklerin hızlı, doğru ve erken dönemlerde tespitini mümkün hale getirmiştir. Bu sistemler, popülasyon dinamiklerini izleyerek hedef odaklı mücadeleyi desteklemektedir. Böylece hem pestisit kullanımının azaltılması hem de çevre dostu ve ekonomik bir üretim sürecinin desteklenmesi sağlanmaktadır.

Bu derlemede, entegre zararlı yönetimi kapsamında akıllı tarım sistemlerinin kullanım olanakları ele alınmış ve mevcut uygulamalar tartışılmıştır.

2. Entegre Zararlı Yönetimi (EZY)


Entegre zararlı yönetimi (EZY), tarımsal üretim sürecinde ekonomik zarara neden olan zararlıların popülasyon yoğunluğunu ekonomik zarar eşiğinin altına çekerek zararlı popülasyonunu kabul edilebilir seviyelerde tutmayı amaçlayan bütüncül bir yaklaşımdır. EZY, yalnızca zararlılarla mücadele etmeyi değil; çevre ve insan sağlığını korumayı, doğal düşmanları desteklemeyi ve ekonomik kayıpları minimize etmeyi hedeflemektedir [6].

Entegre mücadele kavramı ilk kez Kaliforniya Üniversitesi entomologları [7] tarafından ortaya atılmıştır. Tanımda, araştırmacılar biyolojik ve kimyasal mücadele yöntemlerinin birlikte ve dengeli kullanımı vurgulamışlardır. Ancak uygulamalarda geniş spektrumlu insektisitlerin aşırı ve bilinçsiz kullanımı, doğal düşman popülasyonlarının zarar görmesine neden olmuş, bu da zararlı böcek türlerinde popülasyon patlamalarına yol açmıştır. Bu durum üzerine, EZY kavramını yeniden tanımlamış ve zararlılarla mücadelede; zararlı popülasyonları baskılamak ve ekonomik zarar eşiği altında tutmak için bütün mücadele yöntemlerinin uyumlu bir şekilde kullanılması gerektiğini belirtmişlerdir [8].

Entegre zararlı yönetimi kapsamında, kültürel mücadele zararlı popülasyonlarını baskı altına almak için kullanılan temel ve önleyici bir yöntemdir. Toprak işleme, besin ve sulama yönetimi, dayanıklı çeşit kullanımı, ekim nöbeti ve doğru ekim zamanı gibi uygulamalar ile zararlı popülasyonlarının gelişimi engellenmeye çalışılmaktadır. Biyolojik mücadele yönteminde zararlı organizmaların doğal düşmanları

(predatörler, parazit ve parazitoitler) ve faydalı mikroorganizmalar (entomopatojen virüs, bakteri, fungus, microsporidia, bir hücreli ve nematodlar) kullanılarak zararlılarla mücadele edilmektedir. Fiziksel ve mekanik mücadele, zararlıları doğrudan ortadan kaldırmak veya bitkilerin zararlılardan korunmasını sağlamak için uygulanan yöntemlerdir. Feromon, tuzaklar, el ile veya makine ile toplama, sıcaklık uygulamaları gibi yöntemler kullanılmaktadır. Bu yöntemler yetersiz kaldığında kimyasal mücadele tercih edilmektedir.

Tarımsal üretimde sorun oluşturan zararlıların erken dönemde tespit edilmesi kritik bir öneme sahiptir. Zararlıların erken dönemde tespiti; doğru bir stratejinin belirlenmesine, popülasyon yoğunluğunun ekonomik zarar eşiğine ulaşmasını önlemeye yönelik tedbirlerin alınmasına, üretimde verim ve kalite kayıplarının önüne geçilmesine olanak sağlayacaktır. Ancak, geniş ölçekli tarım alanlarında zararlıların uzmanlar veya üreticiler tarafından manuel olarak izlenmesi ve tespiti zaman alıcı ve yoğun emek isteyen bir süreçtir [9]. Günümüzde gelişen teknolojinin tarım alanlarında kullanılması zararlıların tespitinin sensör ve kameralar ile yapılabilmesine olanak sağlamıştır. Akıllı tarım sistemleri sayesinde zararlılar daha kolay, hızlı ve hassas bir şekilde izlenebilmektedir (Şekil 1).



Şekil 1. Entegre zararlı yönetimde kullanılan dijital teknolojiler; Nesnelerin interneti (IoT), uzaktan algılama, görüntü işleme, dronlar ve otonom robotlar

Geçmişten günümüze teknolojik gelişmelerin etkisiyle tarım sektöründe büyük değişimler yaşanmıştır. Bu değişimler neticesinde gerçekleştirilen teknolojik uygulamalar, tarım sektörünün geleceğini şekillendirmiştir [10]. Tarım sektöründe geçmişten günümüze kadar meydana gelen teknolojik gelişim aşamalarını incelediğimizde; hayvan gücü ve insan gücüne dayanan tarım (Tarım 1.0), tarımda motorlar ve traktör kullanımının başlaması (Tarım 2.0), yönlendirme sistemleri ve hassas tarım uygulamaları (Tarım 3.0) ve akıllı ve sürdürülebilir tarım uygulamaları (Tarım 4.0) ön plana çıkmaktadır (Şekil 2).



Şekil 2. Tarım devrimleri; Tarımın evrimi: Tarım 1.0'da manuel uygulamalar, Tarım 2.0'da mekanizasyon, Tarım 3.0'da GPS destekli hassas tarım ve Tarım 4.0'da dijital ve akıllı tarım teknolojilerine geçiş [11]

İlk tarım devriminde üretimin az olduğu, emeğin baskın olduğu üretim şekli hâkim olmuştur. İşlerin yoğun emek ile yürütüldüğü bu dönemde çapa, kürek, orak gibi basit aletler kullanılmıştır [12]. İkinci tarım devriminde ekilebilir arazilerin büyük çiftliklerde birleştirilmesi ve makineleşmeyle beraber elektrik, seri üretime geçiş, toplu üretim, kimyasal gübre, zararlılarla mücadelede zirai ilaçlar kullanılmaya başlanmıştır. Bu devrim yeşil devrim olarak da adlandırılmıştır. Askeri GPS sinyallerinin kamu kullanımı için erişilebilir hale getirilmesi ile beraber hassas tarım da denilen üçüncü tarım devrimine geçilmiştir. GPS teknolojisi ile birlikte, manuel yönlendirme uygulamaları, ilaçlama makinelerinde verim kontrolü, biçerdöverlere uygulanan VRA (Variable Rate Application) sistemleriyle gübreleme işlemlerinin takibinin yapılması ve veri işlemeyi sağlayacak bilgisayar programlarının geliştirilmesi bu dönemde uygulanmış teknoloji sistemlerindendir [13]. Bu sistemlerin temelinde veri odaklı karar verme uygulamaları yatmaktadır. Bu yaklaşım, modern EZY stratejileri için mükemmel bir araç seti ve teknolojik altyapı sağlamaktadır. Endüstri 4.0 devriminin sanayide oluşturduğu dönüşüm, 2011 yılına gelindiğinde tarım sektöründe de benzer bir şekilde kendini göstermeye başlamıştır [10]. Artan nüfusun taleplerini karşılamada geleneksel tarımın yetersiz kalması, tarımsal üretimin çevre kirliliğini artırması, tarımsal sürdürülebilirliği sağlamak ve güvenli gıdaya ulaşma zorluğu gibi nedenler tarımsal üretimde yeni yaklaşımların benimsenmesini zorunlu hale getirmiştir. Akıllı teknolojilerin tarımsal üretimde kullanılmaya başlanması ile beraber, Tarım 4.0'a (bir diğer adıyla akıllı tarıma) geçilmiştir (Şekil 2).

Akıllı tarım sistemlerinin kullanılmaya başlanması yoğun işgücü kullanımı ve daha uzun süren üretim süreçleri artık daha hızlı ve yüksek oranda bir üretimin yapılabilme imkânı sağlamaktadır [14].

3. Akıllı Tarım Sistemlerinin Ana Unsurları

Akıllı tarım sistemleri nesnelerin interneti, görüntü işleme, uzaktan algılama, insansız hava araçları, otonom araçlar ve sensörler gibi teknolojileri içermektedir. Bu sistemin amacı, tarımsal üretimin her aşamasında doğru girdinin doğru zamanda, doğru yere, doğru şekilde ve doğru miktarda uygulanmasını sağlayarak maliyetleri düşürmek, verimi artırmak ve tarımsal sürdürülebilirliğe fayda sağlamaktır [15].

3.1. Nesnelerin İnterneti (IoT)

İnternete bağlı olan nesnelerin birbirleriyle ya da daha büyük sistemlerle veri alışverişi yapabildiği iletişim ağına nesnelerin interneti (IoT) denir. Bu nesneler; sensörler, cihazlar, makineler, robotlar ve dronlar olabilir (Şekil 3). IoT teknolojisinde kullanılan akıllı cihazlar; çevreden veri toplama, toplanan verileri depolama, depolanan verileri analiz etme, ağ kurabilme, kendini tanıtmaya ve bulut servisine veri aktarma özelliğine sahiptir [16, 17].

IoT teknolojisi ulaşım, haberleşme, lojistik, endüstri, sağlık, tarım gibi birçok alanda kullanılmaktadır [18, 19]. Akıllı tarım uygulamalarını geliştirebilmek için sistemin temelini inşa eden IoT teknolojisi tarım ortamında verimliliği ve üretimi artırmak amacıyla kullanılan teknolojik bir gelişmedir [20].

Nesnelerin interneti teknolojisi akıllı tarım uygulamalarında; tarım arazisine hangi tohumun ekileceğine karar vermede, sensörler sayesinde nem, bitki örtüsü, sıcaklık, buhar ve hava koşullarını ölçmede, bitkiye gerekli optimum besin ihtiyacını tahmin etmede, stres koşulları, kuraklık, toprak ve bitki koşulları izlemeye, görüntü işleme ve erken teşhisle hastalık ve zararlıların kontrolünde [14], kaynak optimizasyonunda, hasat zamanının planlanmasında [21] başarıyla kullanılabilmektedir. Bu teknoloji, tarımsal işlemlerde uygun kararı vermek için tüm tarımsal cihaz ve ekipmanların birbirine entegre şekilde çalışmasını sağlamaktadır [22].

IoT sisteminin mimarisi şu şekilde tanımlanmaktadır;

- a. *Verilerin toplanması:* Nesneler aracılığı ile ilk olarak çevresel veriler toplanır.

- b. *İletim*: Toplanan veriler kablosuz ağlar veya kablolu bağlantılar aracılığıyla buluttaki sunucuya gönderilir.
- c. *İşleme ve analiz*: Verilerin analiz ve raporlamasını yapabilmek için büyük veri teknolojisi kullanılır. Büyük veri teknolojisi verilerden anlamlı sonuçlar çıkarmamızı sağlar.
- d. *Karar ve aksiyon*: Analiz sonuçlarına göre otomatik bir aksiyon alınması veya kullanıcıya bilgi verilmesi şeklindedir.



Şekil 3. Gerçek zamanlı ürün izleme ve veri odaklı zararlı yönetimi için dronlar, sensörler ve kablosuz iletişim ağına sahip akıllı tarım sistemleri

3.2. Sensörler

Zararlıların tespitinde kullanılan sensörlerden, saha sensörleri çevresel değişkenlerin (sıcaklık, yaprak ıslaklığı, toprak nemi) gerçek zamanlı olarak elde edilmesine olanak tanımaktadır [23, 24]. Zararlıların popülasyon gelişimini tahmin etmek için mikroiklim koşullarının izlemesi riskli dönemleri öngörmeye yardımcı olmaktadır. 2023 [25] yılında yapılan bir çalışmada sıcaklık, bağıl nem ve yağış ölçümü yapan sensörlerle donatılmış sistem geliştirilmiştir. Sensörler her 30 dk'da bir ölçerek kaydetmektedir. Ölçülen değerler sonucunda makine öğrenmesi algoritması ile zararlıların risk durumu belirlenmekte ve risk durumunun tespitinde sistem anlık olarak kullanıcıya bildirim göndermektedir. Yazarlar sistemi gerçek tarla koşullarında test ettiklerinde sistemin etkili bir şekilde çalıştığını doğrulamışlardır. Sistem sıcaklık, nem ve yağış ölçümlerine dayandığından zararlıları doğrudan görüntüsel izleme yapamamaktadır.

Akustik sensörler, böceklerin kanat çırpma, konma, bitki üzerindeki hareketlerini ve larvaların kemirme seslerini algılamayı sağlayan sensörlerdir. Sharan ve Moir [26] farklı böcek türleri tarafından üretilen sesleri ve türlerin farklı davranışsal aktivitelerini birbirinden ayırt etmek için uyarlanmış farklı yöntemleri listelemişlerdir. Vick ve ark. [27] depolanan tahılların içinde beslenen böcek larvaların akustik olarak tespiti için bir sistem geliştirmiştir. Bu sistem sayesinde Ekin kambur biti, *Rhyzopertha dominica* (F.) (Coleoptera: Bostrichidae), Pirinç böceği, *Sitophilus oryzae* (L.) (Coleoptera: Curculionidae) ve Arpa güvesi, *Sitotroga cerealella* (Olivier) (Lepidoptera: Gelechiidae)'nin depo ortamında yumurtlamadan 13-19 gün sonra tespit edilebileceğini açıklamışlardır. Buğday tarlalarında Süne, *Eurygaster integriceps* (Puton) (Heteroptera: Scutelleridae)'nin varlığının tespiti için, akustik ve ultrasonik ses seviyelerinde çalışan bir sensör sistemi kullanılarak kanat çırpma seslerinden tespiti yapılmıştır [28]. Latha ve Manoranjini [29] yaptıkları çalışmada akustik ve görüntü tabanlı sensörlerin birleşimi ile çalışan bir ağ geliştirmiştir. Topladıkları zararlı görüntü ve seslerinden ayırt edici özellikleri

çıkarmışlardır ve zararlıların ses seviyesinde belirli bir eşik değere ulaştığında uyarı veren sistemi tanıtmışlardır.

Guarnieri ve ark. [30] feromon tuzaklarına gelen zararlıların optik sensörler ile otomatik sayıldığı sistemi kullanmışlardır. Tuzak içine yerleştirilmiş sensör, böcek tuzağa girdiğinde ışık bariyerini kesmesi sonucu sinyal üretmekte ve otomatik sayım yapmaktadır. Farklı çalışmalarda da [31-37] optik sensörler denenmiş ve yüksek doğrulukta sonuçlar elde edilmiştir.

Spektral ve multispektral sensörler ile zararlıların bitkide oluşturduğu stresin dalga boylarındaki değişimine bakılarak zararlı tespiti yapılmaktadır. Entomologlar [38], elma yapraklarında zararlı kaynaklı biyotik stresin hiperspektral indekslerle nasıl teşhis edilebileceğini araştırmışlardır. Beyazsinek istilasını belirlemek için [39] istilanın biyotik stresle ilişkisini sensör kullanarak tespit etmişlerdir. 350-2500 nm spektral bölgesinde 1 nm'de farklı örnekleme aralıklarına sahip bir spektoradyometre kullanmışlardır. Beyazsinek istilasına hasarının şiddeti ile klorofil konsantrasyonu arasındaki ilişkiyi belirlemek için klorofil konsantrasyonunu ölçmüşlerdir. Beyazsinek istilasına uğramış bir pamuk mahsulü, 350-1335 nm ile 1526-1769 nm arasında düşük bir yansıma değeri göstermiştir. Beyazsinek istilasına uğramış yaprak dokusu yakın kızılötesi (NIR) yansıma da sağlıklı bitkilere kıyasla önemli ölçüde azalma olduğunu gözlemlemişlerdir.

3.3. Otonom Sistemler

Otonom sistemler, birçok alanda etkin kullanıldığı gibi tarımsal uygulamalarda da güvenli bir şekilde kullanılmaktadır. Bu sistemler insan gücüne olan bağılılığı azaltarak zamandan tasarruf etme imkânı sağlamaktadır. Doğal tarla ortamında zararlıların otonom robotlar ile tespitinin yapıldığı çok sayıda çalışma bulunmaktadır [40-42]. Liu ve ark. [40], yaptıkları çalışmada Pyralidae familyasına ait böceklerin tespiti için otonom robot geliştirmişlerdir. Deneysel sonuçlar, robotun zararlı görüntülerini otomatik olarak yakalayabildiğini ve doğal ekim sahasında %94,3 tanıma doğruluğu elde edebildiğini göstermiştir. 2020 yılında yapılan bir çalışmada yapışkan tuzaklardaki zararlıların tespiti için insansız hava aracı (İHA) ve kara robotlarının birlikte çalıştığı robotik sistem geliştirilmiştir [41]. İHA, yukarıdan görüntüleme yaparak ve tuzakların konumunu belirleyerek kara robotunu yönlendirmektedir. Kara robotu, da arazide hareket ederek tuzakların yakın çekim görüntülerini alarak zararlı tespitini yapmaktadır.

3.4. Zirai İnsansız Hava Aracı (ZİHA)

İnsansız hava araçları (İHA), içinde insan bulunmadan GPS koordinatları ile belirlenen rotada uzaktan kumanda ile ya da tamamen otonom olarak uçabilen, kendi güç sistemiyle çalışabilen, kullanım amacına göre gövdesine farklı ekipman veya yük eklenilebilen hava araçlarını tanımlamaktadır [43-45]. Zirai amaçla kullanılan insansız hava araçlarına kısaca ZİHA olarak tanımlanmaktadır.

Geçmişte daha çok savunma ve güvenlik alanında kullanılan İHA teknolojisi 2010 yılında yapılan yasal düzenlemeler sonucunda sivil uygulamalarda kullanılmaya başlanmıştır. İnsansız hava araçları düşük irtifada uçuş kolaylığı sağlaması, yüksek çözünürlüklü görüntüler elde etmesi, bulutlu havalarda ölçüm yapabilmesi ve uydu görüntülerine kıyasla maliyet açısından daha kullanılabilir olması sayesinde tarımsal alanda da birçok uygulamada kullanılmaktadır (Şekil 4). Kullanım amacına göre İHA'ların üzerine çok farklı kamera, sensör ve uygulama ekipmanı da takılabilmektedir [46, 47].



Şekil 4. İnsansız hava araçlarının tarımda çeşitli kullanım alanları; ürün ve hayvan gözetimi, bina ve ekipman izleme, haritalama, ilaçlama, su stresi tespiti, değişken düzeyli gübreleme, ürün verimi analizi ve toprak erozyonu izleme [47]

İHA'lar, zararlıların zamanında tespiti, popülasyon yoğunluğunun belirlenmesi, ekonomik zarar seviyelerinin ve eşiklerinin değerlendirilmesi, mücadelenin zamanlaması ve uygulama noktalarının belirlenmesi gibi birçok amaç için entegre zararlı yönetiminde kullanılabilmektedir [48-50].

Avrupa ladini *Picea abies*'de zarar yapan sekiz dişli kabuk böceği *Ips typographus* L. (Coleoptera: Curculionidae)'un tespitini yapmak için İHA tabanlı hiperspektral görüntüler kullanarak spektral özelliklerini çıkartmışlardır [51]. Spektral özelliklerin çıkarılması sonucu ağaçları sağlıklı, enfekte ve ölü olarak sınıflandırmışlardır. Bu üçlü sınıflandırmaya göre 0,60 Cohen kappa değeri elde edilmiş ve %76 doğruluk oranı ile zararlıyı tespit etmişlerdir. Floresan pigmenti ile işaretlenen böceklerin UV aydınlatma sistemi monte edilmiş İHA ile tespitine yönelik gerçekleştirilen çalışmada 36 adet böcek floresan pigmenti ile işaretlenerek 15x15m bir alana bırakmışlardır. Kamera, 10 adet UV ışık kaynağı ve gimbal montelenmiş İHA bu alan üzerinde 10 m yükseklikten uçarak görüntüleri toplamıştır. Toplanan görüntüler üzerinde RGB ve HSV (hue, saturation, value) renk eşikleme kullanarak zararlı böcekleri tespit etmişlerdir. Yaptıkları sistemi tespit hassasiyeti ve geri çağırma açısından değerlendirdiklerinde, 0,7'lik geri çağırma oranı için 0,8 bir hassasiyet oranı elde etmişlerdir [52]. *Pinus tabulaeformis* (Çin Kızılçamı) ormanlarında zarar yapan Çin çamı tırtılı *Dendrolimus tabulaeformis* Tsai & Liu (Lepidoptera: Lasiocampidae)'in hasar derecesini hesaplamak için İHA tabanlı hiperspektral görüntüler kullanmışlardır [53]. Hiperspektral görüntüleri ve sınıflandırmayı daha hassas bir şekilde tamamlamak için bir SVM ve kenar koruma filtresini (EPF) birleştirerek 100 m yükseklikten uçan İHA ile zararlı tarafından hasar gören ağaç taçları otomatik olarak çıkarılarak spektral-mekânsal bir sınıflandırma yapmışlardır. Çalışma sonucunda tespit doğruluğunun % 93.17 olduğunu belirterek geleneksel SVM sınıflandırıcısı kullanımı ile elde edilenden verilere göre tespit doğruluğunun 7.50-9.74 oranında daha yüksek olduğunu belirlemişlerdir.

Dronlar, böcek zararı, bitkilerde ortaya çıkan zarar belirtileri gibi zararlı yönetimi ve tespiti çalışmalarında yaygın olarak kullanılmasına rağmen [54, 55], böceklerin doğrudan dronlar tarafından havadan tespitine yönelik sınırlı sayıda çalışma yürütülmüştür [56-58]. Böceklerin küçük olması, sıklıkla kamufle olmaları, hareketli olmaları ve uçabilmeleri nedeniyle, mevcut optiklerle onları tespit etmek zordur ve bu durum doğrudan tespit etmeyi daha da zorlaştırmaktadır [56].

Dronlar kullanılarak tarımsal zararlıların tespiti yapılırken ayrıca yapay zekâ ve görüntü işleme teknikleri de bu sistemlere entegre edilmek suretiyle kullanılmaktadır. Khan ve ark. [59], tarımsal zararlıların tespiti ve sınıflandırması için İHA ve yapay zekâ tekniklerinden yararlanmışlardır.

Araştırmacılar, YOLOv5s (You Only Look Once Version 5s) modelini kullanarak İHA ile alınan görüntülerden bazı karınca ve çekirge türleri ile, kırmızı palmye böceği *Rhynchophorus ferrugineus* Oliver (Coleoptera: Curculionidae), kalkan böceği *Cassida* spp. (Coleoptera: Chrysomelidae) ve eşek arısı *Vespa crabro* (Hymenoptera: Vespidae) zararlılarını tespit etmişlerdir. Karınca için 392, çekirge için 315, kırmızı palmye böceği için 148, kalkan böceği için 392 ve eşek arısı için 318 görüntü kullanmışlardır. Kullanılan görüntülerin %70 veri seti için, %20 doğrulama için ve %10 test için ayrılmıştır. Çalışma sonucunda %96 doğruluk, %93 geri çağırma ve %95 ortalama doğruluk değerlerine ulaşmışlardır. Park ve ark. [60], yaptıkları çalışmada soya fasülyesinde zarar yapan Fasülye böceği *Riptortus pedestris* Fabricius (Hemiptera: Alydidae)'yi tespit ederek neden olduğu zararı azaltmak için Mask-RCNN, Yolov3 ve Detectron2 derin öğrenme modelleri kullanmışlardır. Arazide ve laboratuvar koşullarında soya fasülyesini büyüme periyodu boyunca İHA kullanarak görüntülemişlerdir ve elde ettikleri veri setini kullanarak Mask-RCNN, Yolov3 ve Detectron2 modellerini eğitmişlerdir. Üç modelin mAP değerlerini, performanslarının güvenilirliği açısından karşılaştırmışlardır, sırasıyla 0.95797, 0.97541 ve 0.94435 sonuçlarını elde etmişlerdir bu da üç modelin de *R. pedestris*'in tespitini gerçekleştirmek için kullanılabileceğini göstermektedir.

3.5. Uzaktan Algılama

Yer tabanlı platformlar, İHA'lar ve uydulara yerleştirilmiş sensör ve kameralar ile yeryüzündeki nesnelerin temas kurulmadan izlenmesi ve analiz edilmesi işlemine uzaktan algılama denmektedir. Uzaktan algılama teknolojisi tarımda; haritalama, bitkileri sınıflandırma, bitki sağlığı takibi, hastalık ve zararlı tespiti, yabancı ot tespiti, bitki su isteği takibi, ilaç ya da gübre isteği takibi, toprak nem seviyesi takibi, toprak ve bitki stres takibi, verim tahmini ve hasat zamanı tahmininde kullanılmaktadır (Şekil 5).



Şekil 5. Uzaktan algılama sistemleri; dronlar, uydular ve otonom robotlar

Uzaktan algılama için kullanılan uydu görüntüleri büyük alanlarda veri toplamada elverişli olsa da mekânsal çözünürlüğü düşük ve maliyetli bir uygulamadır. Ayrıca uydular meteoroloji verilerinden etkilenerek bulutlu havalarda doğru veri alınmasını zorlaştırmaktadır [61]. Unlu bit *Solenopsis mealybug* (Hemiptera: Pseudococcidae) şiddetini değerlendirmek için yapılan bir çalışmada unlu bit şiddeti ile uzaktan algılama endeksleri arasındaki ilişkiyi değerlendirilmiştir [62]. Yazarlar, RGB, NIR, kısa dalga kızılötesi ve termal spektral bantlara sahip Landsat TM5 uydu görüntülerini kullandılar. Unlu bit istilasına uğramış pamuk mahsulünün NIR bölgesinde önemli ölçüde daha düşük (%33) ve spektrumun görünür bölgesinde daha yüksek (%14) bir yansıma oranına sahip olduğu, istilaya uğramamış pamuk mahsulünün ise %48 NIR ve %9 görünür bölge yansıma oranına sahip olduğu görüldü. Bu sonuçlar, uzaktan algılamanın unlu bit hasarını ayırt etme ve pamuktaki popülasyon yoğunluğunu ölçme potansiyeline sahip olduğunu göstermektedir. Kırklareli'nin Lüleburgaz ilçesinde bulunan ayçiçeği tarlalarında Çayır tırtılı *Loxostege sticticalis*'in neden olduğu hasarı tespit etmede

farklı görüntü çözünürlüklerine sahip PlanetScope ve Sentinel-2 uydu görüntülerinin etkinliği değerlendirilmiştir [63]. Değerlendirme sonucunda, PlanetScope uydu görüntüleri %90 genel doğruluk ve %84 Kappa istatistiği ile en yüksek doğruluğu göstermiştir. Ainunnisa ve Haerani [64], Sentinel-2 uydu görüntülerini kullanarak Endonezya'daki çeltik tarlalarındaki zararlı ve hastalıkları tespit etmek için çalışma gerçekleştirmişlerdir. Çalışmada bitki örtüsü indeksleri ile pirinç verimliliği arasındaki ilişkiye bakarak mekânsal analiz ve basit doğrusal regresyon analizi yapmışlardır. Araştırma sonuçları, vejetatif dönemin sonunda düşük NDVI ve NDRE değerleri gösteren bazı pirinç tarlalarının zararlı ve hastalıklarla enfekte olduğunu tespit etmişlerdir. Yazarlar yaptıkları saha çalışmaları ile zararlı ve hastalıkları gözlemlemişlerdir ve bitkide oluşturdıkları stres sonucunda klorofil azalışı ve yaprak/sap tahribatları yoluyla bitki indekslerini düşürdüğünü açıklamışlardır.

3.6. Görüntü işleme


Görüntü işleme, kamera, sensör veya tarayıcı kullanılarak elde edilen hareketli ya da sabit dijital (sayısal) görüntülerin belirli amaç doğrultusunda bilgisayar ve özel programlar kullanılarak anlamlandırılması işlemidir. Görüntü işleme teknikleri günümüzde askeri, tıp, tarım, hayvancılık, endüstri, güvenlik, robotik, astronomi, haritalama, sanat ve fizik gibi alanlarda kullanılmaktadır [65-67].

Görüntü işlemenin gerçekleşmesi için bazı temel aşamalar gerekmektedir (Şekil 6). İlk olarak kamera, sensör veya tarayıcı ile edinilen görüntüler programa aktarılır. Görüntü işleme uygulaması ile görüntü azaltma, renk düzenleme ve iyileştirme yapılarak görüntü daha kolay işlenebilecek hale getirilir. Segmentasyon ile nesne arka plandan ayrılır. Özellik çıkarma ile görüntüdeki kenarlar, köşeler, renkler, şekiller önemli özellikler tanımlanarak çıkarılmaktadır. Sınıflandırma ile nesnelerin türü belirlenerek belirli kategorilere ayrılır. Elde edilen bilgilerin iyi olup olmadığına karar verilerek işlem yapılır [68].



Şekil 6. Temel görüntü işleme aşamaları; görüntü edinme, ön işleme, segmentasyon, özellik çıkartma, sınıflandırma ve karar verme [68]

Akıllı tarım alanındaki gelişmeler sayesinde görüntü işleme teknikleri tarımsal uygulamalarda da kullanılmaktadır (Şekil 7). Tarım alanında bitkilerinin tür, boyut ve şekil özelliklerine göre sınıflandırılması [69, 70], bitki gelişiminin gözlenmesi [71], hastalık tespiti [72-79], zararlı tespiti [80-83], yabancı ot tespiti [84-85], verim tahmini [86, 87], toprak ve bitki stres durumlarının belirlenmesi, yaprak yüzey alanının belirlenmesi [88], toprak neminin belirlenmesi [89], kök gelişimi takibi [90], pestisit uygulamaları [91], tahmini hasat zamanı belirlenmesi [70] gibi uygulamalar da kullanılmaktadır.



Şekil 7. Akıllı tarımda görüntü işleme iş akışı: dronlarla veri toplama, bulut depolama, görüntü işleme yazılımı, veri tabanı entegrasyonu ve ürün yönetiminde otomatik karar verme [92]

Gelişen teknolojinin tarım alanında kullanımı zararlıların gerçek zamanlı olarak tanımlama, sınıflama, bitkide oluşturduğu zarar, çıkış zamanı, konumu, popülasyon yoğunluğunun belirlenmesini mümkün kılmıştır. Görüntü işleme uygulamalarının zararlı tespitinde kullanımı ile işlem süresi kısalarak doğru sonuçlar elde edilmektedir.

Xia ve ark. [99], böceklerin tanımlanması ve sınıflandırılması için CNN kullanmışlardır. *Aelia sibirica*, *Atracto morphasinensis*, *Chilo suppressalis* vb. gibi zararlıların görüntülerini veri artırma tekniği kullanarak artırmışlardır ve önceden eğitilmiş 19 katman derinliğinde bir evrimsel sinir ağı olan VGG19 ile %85.5 doğruluk oranında zararlı tespiti yapmışlardır. Gong ve ark. [94], derin öğrenme tekniği kullanarak FCN'lere dayalı pirinç zararlılarını tanımlama ve sınıflandırma için bir algoritma önermişlerdir. FCN algoritmasını temel çerçeve olarak kullanarak, FCN algoritmasının özellik çıkarma ağı olarak DenseNet'i kullanmışlardır ve böcek kenar özelliklerini çıkarmaya odaklanan bir kanal dikkat mekanizmasını tanıtarak FCN-ECAD geliştirmişlerdir. Standart derin evrimsel sinir ağı modelleri olan VGG-16, VGG-19, ResNet50 ve DenseNet'i karşılaştırma modeli olarak seçmişlerdir. FCN-ECAD modeli %98.28'lik bir test doğruluk oranı ile mevcut yöntemlere kıyasla daha yüksek bir performans sergilediğini tespit etmişlerdir. Cheng ve ark. [95], YOLOLite-CSG adını verdikleri evrimsel sinir ağlarına dayalı zararlı tespit modeli kullanmışlardır. Kalıntı blok sayısını ve kanal sayısını ayarlayarak orijinal YOLOv3'ü basitleştirmişlerdir ve YOLOLite'ı oluşturmuşlardır. Daha fazla mekânsal bilgi çıkarmak için LightSandGlass adlı hafif kum saati blokları yerleştirmişlerdir. Modeli CP15 zararlı veri kümesi üzerinde denemişlerdir ve tespit hassasiyeti %82.9 ile YOLOv3'ü aşmıştır. YOLOLite-CSG modeli; YOLOv3, YOLOv5m, CenterNet, Faster R-CNN, YOLOv3-tiny, Nanodet-artı-m-1.5x ve YOLOv5s modelleri ile karşılaştırıldığında en iyi performans gösteren YOLOv5m'den %0.3 daha yüksek tespit doğruluğuna sahip olduğunu belirlemişlerdir. Cihazın sınırlamaları nedeniyle, İHA'larda veya yapışkan tuzaklarda gerçek etki değerlendirmesini gerçekleştirmemişlerdir. Du ve ark. [96], Çin'de yaptıkları çalışmada; mısır arazilerindeki Güz tırtılı *Spodoptera frugiperda* J.E. Smith (Lepidoptera: Noctuidae)'nın lokasyon ve beslenme şiddeti derecesini belirlemek için klasik nesne algılama modeli Faster R-CNN'e dayanan Pest R-CNN adlı uçtan uca derin öğrenme nesne algılama modelini kullanmışlardır. Modeli, insansız hava aracı tarafından elde edilen yüksek mekânsal çözünürlüklü kırmızı-yeşil-mavi (RGB) orto-görüntüler kullanılarak eğitmişlerdir. Pest R-CNN'in doğruluğunu değerlendirmek için ortalama kesinlik değerleri, Faster R-CNN ve YOLOv5 modeliyle karşılaştırıldığında doğruluğunun sırasıyla %12 ve %19 arttığını belirlemişlerdir. Li ve ark. [97], böcek zararlılarının tespitinde verimi artırmak için derin evrimsel sinir ağı (DCNN) modelleri olan Faster-

RCNN, Mask-RCNN ve Yolov5 modellerini kullanmışlardır. Çalışmada Baidu AI ve IP102 böcek tespit veri setindeki görüntüleri kullanarak derin öğrenme modellerini karşılaştırmışlardır. Baidu AI böcek tespit veri seti için %99'un üzerinde doğruluk ile en iyi ve hızlı sonucu Yolov5 modelinin verdiğini bulmuşlardır. IP102 veri seti için Faster-RCNN ve Mask-RCNN modellerinin daha yüksek doğruluğa sahip olduğunu belirtmişlerdir.

Şin ve Öztürk [98], fındıkta sorun olan Turuncgil uzun antenli böceği (*Anoplophora chinensis* Forster)'nin görüntü işleme yöntemi kullanılarak tespitine yönelik bir çalışma gerçekleştirmişlerdir. Yapmış oldukları çalışma ile 87 resimde 157 adet etiketleme gerçekleştirmişler ve yapmış oldukları bu etiketleri Yolov5 modelini kullanarak test etmişlerdir. Çalıştırılan Yolo modelinden alınan sonuçlar doğrultusunda %99'a varan oranda doğruluk ve 0.97 F1 skoruna sahip olduğunu bildirmişlerdir. Elde ettikleri bu sonuç ile *A. chinensis*'in dijitalleştirilerek bilgisayar ortamına aktarılması sağlanmıştır. Ayrıca yapılacak olan yeni çalışmalar ve daha detaylı veri setleri sayesinde kesin doğruluk payına sahip sistemlerin temelini oluşturacağını belirtmişlerdir.

Güler [11] tarafından yapılan çalışmada ise görüntü işleme tekniği kullanılarak Amerikan beyaz kelebeği, *Hyphantria cunea* (Drury) (Lepidoptera: Erebidae) larvalarının varlığı ve meydana getirdiği zararın tespiti araştırılmıştır. Derin öğrenme metodu için Phyton yazılım dilinde geliştirilmiş olan YOLOv5 programı kullanılmıştır. *Hyphantria cunea*'nin bulunduğu görüntü veri kümesinin; %70'i eğitim için, %15'i doğrulama için ve %15'i test için ayrılmıştır. Bu nedenle, eğitim için 2189 görüntü, doğrulama için 468 görüntü ve test için 450 görüntü kullanılmıştır. Yapılan çalışmalar neticesinde larva ve oluşturulan ağ küme sayıları %97 doğrulukla tespit edilmiştir. *Hyphantria cunea* larvalarının yapmış olduğu ağların tespitinde drone ile yapılan havadan araştırmanın hassasiyeti ve doğruluğunun, görsel yer araştırmasına göre çok daha yüksek olduğu belirlenmiştir. Yapılan bu çalışma zararlının hızlı bir şekilde tespiti, yaygınlık durumu, zarar boyutu ve ekonomik zarar eşiğinin belirlenmesi gibi çalışmalara katkı sağlayacağı rapor edilmiştir.

4. Sonuç ve Öneriler

Tarımsal üretimde zararlı organizmaların neden olduğu problemler yalnızca ekonomik boyutla sınırlı kalmayıp; aynı zamanda kullanılan kimyasallar nedeniyle ekolojik denge, gıda güvenliği ve sürdürülebilir üretim üzerinde de etki oluşturmaktadır. Geleneksel zararlı kontrol yöntemleri, kısa vadede etkili olsa da uzun dönemde pestisit direnci, biyolojik çeşitlilik kaybı ve çevresel kirlilik gibi ciddi sonuçlara yol açmaktadır. Bu nedenle, entegre zararlı yönetimi (EZY) yaklaşımı, modern tarımın temel taşlarından biri olarak öne çıkmaktadır.

Dijital tarım teknolojilerindeki hızlı ilerlemeler, entegre zararlı yönetiminde köklü bir dönüşüm yaratmaktadır. Nesnelerin interneti (IoT), sensör teknolojileri, otonom sistemler, insansız hava araçları (ZİHA) ve uzaktan algılama yöntemleri, zararlıların erken dönemde ve yüksek doğrulukla tespit edilmesini mümkün kılmaktadır. Bu teknolojiler, makine öğrenmesi ve derin öğrenme algoritmalarıyla birleştirildiğinde, zararlı popülasyonlarının izlenmesi, stres belirtilerinin tanımlanması ve mücadele stratejilerinin optimize edilmesi açısından önemli kazanımlar sağlamaktadır.

Görüntü işleme ve sensör tabanlı sistemlerle yapılan çalışmalar, bitkilerde zararlı kaynaklı stresin spektral, termal veya akustik değişimlerle belirlenebildiğini ortaya koymaktadır. Özellikle dron tabanlı görüntüleme sistemleri ve otonom robotlar, geniş tarım alanlarında hızlı veri toplama ve yerinde değerlendirme olanağı sunarak klasik gözlem yöntemlerinin ötesine geçmektedir. Bu sayede pestisit kullanımında azalma, çevresel yükte düşüş ve verimlilikte artış sağlanabileceği öngörülmektedir.

Bununla birlikte, mevcut sistemlerin bazı sınırlılıkları bulunmaktadır. Sensörlerin çevresel koşullardan etkilenmesi, veri çeşitliliğinin yetersizliği, algoritmaların genellenebilirlik düzeylerinin sınırlı olması ve

maliyet faktörleri bu teknolojilerin yaygınlaşmasını zorlaştırmaktadır. Bu bağlamda, gelecekteki çalışmalarda sistemlerin dayanıklılığını ve hassasiyetini artıracak hibrit teknolojilerin geliştirilmesi, geniş ve çeşitlendirilmiş veri setlerinin oluşturulması, yerli donanım ve yazılım entegrasyonunun sağlanması gerekmektedir.

Ayrıca, üreticilerin dijital okuryazarlık düzeylerinin yükseltilmesi, sensör verilerinin yorumlanmasına yönelik eğitim programlarının yaygınlaştırılması ve politika düzeyinde teşvik mekanizmalarının oluşturulması, bu teknolojilerin sürdürülebilir biçimde benimsenmesine katkı sağlayacaktır.

Sonuç olarak, dijital teknolojilerin entegre zararlı yönetimi ile bütünleştirilmesi, tarımsal üretimde çevre dostu, ekonomik ve yüksek verimliliği katkı sağlayacak bir dönemin habercisidir. Bu yaklaşım, yalnızca zararlı kontrolünde değil; aynı zamanda iklim değişikliğine uyum, kaynak verimliliği ve sürdürülebilir tarım hedeflerinin gerçekleştirilmesinde de stratejik bir öneme sahiptir.

5. Beyanname

5.1. Rakip Çıkarlar

Bu çalışmada herhangi bir çıkar çatışması yoktur.

5.2. Yazarların Katkıları

Ceyda Güler: Literatür taramasını gerçekleştirmiş; araştırma sürecini yürütmüş; veri toplama, düzenleme ve değerlendirme aşamalarında sorumluluk almış; makalenin ilk taslağını hazırlamış ve literatürün yorumlanması ile yazının geliştirilmesi süreçlerini yürütmüştür.

Bahadır Şin: Çalışmanın bilimsel doğruluğu ve yöntemsel uygunluğu açısından değerlendirmelerde bulunmuş; metnin son kontrolü, içerik doğrulaması ve akademik tutarlılık yönünde katkı sağlamıştır.

Salih Karabörklü: Araştırma fikrinin ve çalışmanın temel hipotezinin oluşturulmasına katkı sağlamış; yöntem seçimi, bilimsel yaklaşım ve çalışmanın genel kurgusunda danışmanlık yapmış; makalenin tümünü bilimsel içerik açısından değerlendirerek akademik doğruluk ve tutarlılığı kontrol etmiş ve çalışmayı yayına hazırlamak için entelektüel katkı sunmuştur.

5.3. Teşekkür

Bu çalışmaya katkılarından dolayı SUBÜ Bilimsel Araştırma Projeleri Birimine (Proje No: 158-2023) teşekkür ederiz.

6. Kaynakça

- [1] FAO. (2023). *The impact of pests and diseases on agricultural productivity*. <https://www.fao.org> (27.11.2025)
- [2] Oerke, E. C. (2006). Crop losses to pests. *Journal of Agricultural Science*, 144(1), 31–43. <https://doi.org/10.1017/S0021859605005708>
- [3] Savary, S., Willocquet, L., Pethybridge, S.J., Esker, P., McRoberts, N., Nelson, A. (2019). The global burden of pathogens and pests on major food crops. *Nature Ecology & Evolution*, 3, 430–439. <https://doi.org/10.1038/s41559-018-0793-y>
- [4] Karabörklü, S., Azizoglu, U., Azizoglu, Z.B. (2018). Recombinant entomopathogenic agents: a review of biotechnological approaches to pest insect control. *World Journal of Microbiology and Biotechnology*, 34(1), 14.
- [5] Tiryaki, O., Canhilal, R., Horuz, S. (2010). Tarım ilaçları kullanımı ve riskleri. *Erciyes üniversitesi fen bilimleri enstitüsü fen bilimleri dergisi*, 26(2), 154-169.
- [6] Sanyal, D., Bhowmik, P.C., Anderson, R.L. Shrestha, A. (2008). Revisiting the perspective and progress of integrated weed management. *Weed Science*, 56(1), 161-167.
- [7] Stern, V.M., Smith, R.F., Van den Bosch, R.R. Hagen, K. (1959). The integration of chemical and biological control of the spotted alfalfa aphid: the integrated control concept. *Hilgardia*, 29(2), 81-101.
- [8] Smith, R.F., Reynolds, H.T. (1966). Principles, Definitions and Scope of Integrated Pest Control. *Proceedings Symposium on Integrated Pest Control*, Rome, Italy, s. 11-17.
- [9] Zhang, J., Huang, Y., Pu, R., Gonzalez-Moreno, P., Yuan, L., Wu, K., Huang, W. (2019). Monitoring plant diseases and pests through remote sensing technology: A review. *Computers and Electronics in Agriculture*, 165, 104943.

- [10] Saygılı, F., Kaya, A.A., Çalışkan, E.T., & Kozal, Ö.E. (2018). Türk tarımının global entegrasyonu ve Tarım 4.0. İzmir Ticaret Borsası, İzmir. <https://itb.org.tr/img/userfiles/files/ITB%20TARIM.pdf>
- [11] Güler, C. (2025). *Derin Öğrenme Yönteminin Hyphantria cunea (Drury) Larvalarının ve Zararının Belirlenmesindeki Etkinliğinin Araştırılması* (Yüksek Lisans Tezi). Sakarya Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Sakarya.
- [12] Dhanaraju, M., Chenniappan, P., Ramalingam, K., Pazhanivelan, S., Kaliaperumal, R. (2022). Smart farming: Internet of things (IoT)-based sustainable agriculture. *Agriculture*, 12(10), 1745. <https://doi.org/10.3390/agriculture12101745>
- [13] Makine İmalat Sanayii Dernekleri Federasyonu (MAKFED). (2020). *Tarım ve Makine Sanayi Etkileşim Raporu*. MAKFED Yayınları.
- [14] Çilesiz, Y., Karaköy, T. (2022). *Akıllı Tarım Teknolojilerinin Tarımsal Üretimde Kullanımı*. İksad Yayınevi.
- [15] Ertaş, B.A. (2020). Tarım 4.0 ile sürdürülebilir bir gelecek. *Icontech International Journal of Surveys*, 4, 1-12. <https://doi.org/10.46291/ICONTECHvol4iss1pp1-12>
- [16] Miorandi, D., Sicari, S., De Pellegrini, F., Chlamtac, I. (2012). Internet of things: Vision, applications and research challenges, *Ad Hoc Networks*, 10(7), 1497- 1516. <https://doi.org/10.1016/j.adhoc.2012.02.016>
- [17] Ercan, T., Kutay, M. (2016). Endüstride nesnelerin interneti (IoT) uygulamaları. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 16(3), 599- 607.
- [18] Gökrem, L., Bozuklu, M. (2016). Nesnelerin interneti: yapılan çalışmalar ve ülkemizdeki mevcut durum. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, (13), 47–68.
- [19] Bıçakçı, S.N. (2019). Nesnelerin interneti. *Takvim-i vekayi*, 7(1), 24-36.
- [20] Citoni, B., Fioranelli, F., Imran, M.A., Abbasi, Q.H. (2019). Internet of things and LoRaWAN-enabled future smart farming. *IEEE Internet of Things Magazine*, 2(4), 14-19. <https://doi.org/10.1109/IOTM.0001.1900043>
- [21] Goedde, L., Katz, J., Ménard, A., Revellat, J. (2020). Agriculture's connected future: How technology can yield new growth. McKinsey & Company. <https://www.mckinsey.com>
- [22] Kumar, T.U., Periasamy, A. (2021). IoT based smart farming (E-FARM)'S. *International Journal of Recent Advances in Multidisciplinary Topics*, 2(4), 85-87.
- [23] Pratheepa, M., Verghese, A., Bheemanna, H. (2016). Shannon information theory a useful tool for detecting significant abiotic factors influencing the population dynamics of *Helicoverpa armigera* (Hübner) on cotton crops. *Ecological Modelling*, 337, 25-28.
- [24] Chopda, J., Raveshiya, H., Nakum, S., Nakrani, V. (2018). Cotton crop disease detection using decision tree classifier. *International Conference on Smart City and Emerging Technology (ICSCET 2018)*, s. 1-5. <https://doi.org/10.1109/ICSCET.2018.8537336>
- [25] Blanco-Carmona, J., Aranda-Bueno, A., Martín-Gómez, J., Pérez-Valero, E., García-Sánchez, A.-J. (2023). AIIoT in agriculture: Safeguarding crops from pest and disease threats. *Sensors*, 23(24), 9733. <https://doi.org/10.3390/s23249733>
- [26] Sharan, R.V., Moir, T.J. (2016). An overview of applications and advancements in automatic sound recognition. *Neurocomputing*, 200, 22-34.
- [27] Vick, K.W., Webb, J.C., Weaver, B.A., Litzkow, C. (1988). Sound detection of stored-product insects that feed inside kernels of grain. *Journal of Economic Entomology*, 81(5), 1489–1493. <https://doi.org/10.1093/jee/81.5.1489>
- [28] Yazgaç, B.G., Kırıcı, M., Kıvan, M. (2016). Detection of sunn pests using sound signal processing methods. *Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*. IEEE, Tianjin, China
- [29] Latha, Y.L.M., Manoranjini, J. (2020). Automatic pest detector in agricultural farms using acoustic and image wireless sensor network technology. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 9(4S2), 115–119. <https://doi.org/10.35940/ijitee.D1002.0394S220>
- [30] Guarnieri, A., Maini, S., Molari, G., Rondelli, V. (2011). Automatic trap for moth detection in integrated pest management. *Bulletin of Insectology*, 64(1), 247–251.
- [31] González-Pérez, M.I., Faulhaber, B., Williams, M., Bhandari, B. (2022). A novel optical sensor system for the automatic classification of mosquitoes by genus and sex with high levels of accuracy. *Parasites & Vectors*, 15(1), 276. <https://doi.org/10.1186/s13071-022-05324-5>
- [32] Welsh, T.J., Bentall, D., Kwon, C., Mas, F. (2022). Automated surveillance of Lepidopteran pests with smart optoelectronic sensor traps. *Sustainability*, 14(15), 9577. <https://doi.org/10.3390/su14159577>
- [33] Rydhmer, K., Bick, E., Still, L., Strand, A., Luciano, R., Helmreich, S., Nikolajsen, T. (2022). Automating insect monitoring using unsupervised near-infrared sensors. *Scientific Reports*, 12(1), 2603.
- [34] Wu, Y., Ji, R., Liu, Q., Fan, R. (2019). Mosquito counting system based on optical sensing. *Applied Physics B*, 125(2), 22. <https://doi.org/10.1007/s00340-019-7361-2>
- [35] Zhong, Y., Gao, J., Lei, Q., Zhou, Y. (2018). Vision-based counting and recognition system for flying insects in intelligent agriculture. *Sensors*, 18(5), 1489. <https://doi.org/10.3390/s18051489>
- [36] Bakkay, M.C., Chambon, S., Rashwan, H.A., Lubat, C., Barsotti, S. (2018). Support vector machine (SVM) recognition approach adapted to individual and touching moths counting in trap images. *arXiv preprint*, arXiv:1809.06663. <https://arxiv.org/abs/1809.06663>
- [37] Chen, Y., Why, A., Batista, G., Mafra-Neto, A., Keogh, E. (2014). Flying insect classification with inexpensive sensors. *Journal of insect behavior*, 27(5), 657-677.
- [38] Delalieux, S., Somers, B., Hereijgers, S., Verstraeten, W. W., Keulemans, W., Coppin, P. (2007). Hyperspectral indices to diagnose leaf biotic stress of apple plants considering leaf phenology. *International Journal of Remote Sensing*, 28(9), 1895–1910. <https://doi.org/10.1080/01431160600637735>
- [39] Nigam, R., Kot, R., Sandhu, S.S., Bhattacharya, B.K., Chandi, R.S., Singh, M., Singh, J., Manjunath, K.R. (2016). Ground-based hyperspectral remote sensing to discriminate biotic stress in cotton crop. *Proceedings Volume 9880*,

- Multispectral, Hyperspectral, and Ultraspectral Remote Sensing Technology, Techniques and Applications VI*. SPIE Asia-Pacific Remote Sensing Conference, New Delhi, India, s. 89-98. <https://doi.org/10.1117/12.2223444>
- [40] Liu, B., Hu, Z., Zhao, Y., Bai, Y., Wang, Y. (2019). Recognition of pyralidae insects using intelligent monitoring autonomous robot vehicle in natural farm scene. *arXiv preprint arXiv:1903.10827*.
- [41] Berger, G.S., Teixeira, M., Cantieri, A., Lima, J., Pereira, A., Valente, A., de Castro, G.G.R., Pinto, M.F. (2023). Cooperative heterogeneous robots for autonomous insects trap monitoring system in a precision agriculture scenario. *Agriculture*, 13(2), 239.
- [42] Yehoshua, A., Edan, Y. (2023). Mobile robots sampling algorithms for monitoring of insects populations in agricultural fields. *arXiv preprint arXiv:2308.13806*.
- [43] Özguven, M.M. (2018). The newest agricultural technologies. *Current Investigations in Agriculture and Current Research*, 5(1).
- [44] Rani, A., Chaudhary, A., Sinha, N.K, Mohanty, M., Chaudhary, R.S. (2019). Drone: The green technology for future agriculture, *Harit Dhara*, 2(1): 3-6.
- [45] Mogili, U.R., Deepak, B.B.V.L. (2020). An intelligent drone for agriculture applications with the aid of the MAVlink protocol. *Innovative Product Design and Intelligent Manufacturing Systems: Select Proceedings of ICPIDIMS*, Singapore, s. 195–205. https://doi.org/10.1007/978-981-15-2696-1_19
- [46] Türkseven, S., Kızmaz, M.Z., Tekin, A.B., Urkan, E., Serim, A.T. (2016). Tarımda dijital dönüşüm, insansız hava araçlarının kullanılması, *Tarım makinaları bilim dergisi*, 12 (4), 267-271.
- [47] Şin, B., Kadioğlu, İ. (2019). İnsansız Hava Aracı (İHA) ve görüntü işleme teknikleri kullanılarak yabancı ot tespiti yapılıması. *Turkish Journal of Weed Science*, 22(2), 211–217.
- [48] Carrière, Y., Ellsworth, P. C., Dutilleul, P., Eilers-Kirk, C., Barkley, V., Antilla, L. (2006). A GIS-based approach for area wide pest management: the scales of *Lygus hesperus* movements to cotton from alfalfa, weeds, and cotton, *Entomologia Experimentalis et Applicata*, 118: 203–210, <https://doi.org/10.1111/j.1570-7458.2006.00384.x>
- [49] Backoulou, G.F., Elliott, N.C., Giles, K., Phoofolo, M., Catana, V. (2011). Development of a method using multispectral imagery and spatial pattern metrics to quantify stress to wheat fields caused by *Diuraphis noxia*, *Computers and electronics in agriculture*, 75(1), 64-70, <https://doi.org/10.1016/j.compag.2010.09.011>
- [50] Dara, S. K. (2019). The new integrated pest management paradigm for the modern age. *Journal of Integrated Pest Management*, 10: 12, <https://doi.org/10.1093/jipm/pmz010>
- [51] Näsi, R., Honkavaara, E., Lyytikäinen-Saarenmaa, P., Blomqvist, M., Litkey, P., Hakala, T., Viljanen, N., Kantola, T., Tanhuanpää, T., Holopainen, M. (2015). Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level, *Remote Sensing*, 7(11), 15467-15493, <https://doi.org/10.3390/rs71115467>
- [52] Stumph, B., Virto, M.H., Medeiros, H., Tabb, A., Wolford, S., Rice, K., & Leskey, T. (2019). Detecting invasive insects with unmanned aerial vehicles. *2019 International Conference on Robotics and Automation (ICRA)*, s. 648–654. <https://doi.org/10.1109/ICRA.2019.8794116>
- [53] Zhang, N., Wang, Y., Zhang, X. (2020). Extraction of tree crowns damaged by *Dendrolimus tabulaeformis* Tsai et Liu via spectral-spatial classification using UAV-based hyperspectral images, *Plant Methods*, 16(1):1–19, <https://doi.org/10.1186/s13007-020-00678-2>
- [54] Banu, T.P., Borlea, G.F., Banu, C. (2016). The use of drones in forestry, *J. Environ. Sci. Engineer*, 5: 557–562, <https://doi.org/10.17265/2162-5263/2016.11.007>
- [55] Severtson, D., Callow, N., Flower, K., Neuhaus, A., Olejnik, M., Nansen, C. (2016). Unmanned aerial vehicle canopy reflectance data detects potassium deficiency and green peach aphid susceptibility in canola, *Precision Agriculture*, 17, 659- 677, <https://doi.org/10.1007/s11119-016-9442-0>
- [56] Park, Y.L., Cho, J.R., Lee, G.S., Seo, B.Y. (2021). Detection of *Monema flavescentis* (Lepidoptera: Limacodidae) cocoons using small unmanned aircraft system, *Journal of Economic Entomology*, 114(5), 1927-1933, <https://doi.org/10.1093/jee/toab060>
- [57] Sorbelli, F. B., Palazzetti, L., Pinotti, C. M. (2023). YOLO-based detection of *Halyomorpha halys* in orchards using RGB cameras and drones, *Computers and electronics in agriculture*, 213, 108228, <https://doi.org/10.1016/j.compag.2023.108228>
- [58] Giannetti, D., Patelli, N., Palazzetti, L., Betti Sorbelli, F., Pinotti, C.M., Maistrello, L., (2024), First use of unmanned aerial vehicles to monitor *Halyomorpha halys* and recognize it using artificial intelligence, *Pest Management Science*, 80(8), 4074-4084, <https://doi.org/10.1002/ps.8115>
- [59] Khan, A., Malebary, S.J., Dang, L.M., Binzagr, F., Song, H.K., Moon, H. (2024). AI-enabled crop management framework for pest detection using visual sensor data, *Plants*, 13(5), 65, <https://doi.org/10.3390/plants13050653>
- [60] Park, Y.H., Choi, S.H., Kwon, Y.J., Kwon, S.W., Kang, Y.J., Jun, T.H. (2023). Detection of soybean insect pest and a forecasting platform using deep learning with unmanned ground vehicles, *Agronomy*, 13(2):477, <https://doi.org/10.3390/agronomy13020477>
- [61] Thenkabail, P.S., Nolte, C., Lyon, J. G. (2000). Remote sensing and GIS modeling for selection of a benchmark research area in the inland valley agroecosystems of West and Central Africa. *Photogrammetric Engineering & Remote Sensing*, 66(6), 755–768.
- [62] Singh, S.K., Dutta, S., Dharaiya, N. (2016). A study on geospatial technology for detecting and mapping of *Solenopsis mealybug* (Hemiptera: Pseudococcidae) in cotton crop. *Journal of Applied and Natural Science* 8, 2175–2181.
- [63] Ercan, B.S., Maden, B., Kara, S., Sunar, F., Aysal, T., Ozkaya, N., Saglam, O. (2024). Comparative Study of Satellite Image Resolutions for Detecting Pest Damage in Sunflower Fields. The International Archives of the Photogrammetry, *Remote Sensing and Spatial Information Sciences*, 48, 133-139.
- [64] Ainunnisa, I., Haerani, H. (2023). The identification of pests and diseases of rice plants using Sentinel-2 satellite imagery data at the end of the vegetative stage. *IOP Conference Series: Earth and Environmental Science*, 1230(1), 012148. <https://doi.org/10.1088/1755-1315/1230/1/012148>.

- [65] Sabancı, K., Aydın, C., Ünlerşen, M.F. (2012). Görüntü işleme ve yapay sinir ağları yardımıyla patates sınıflandırma parametrelerinin belirlenmesi, *Journal of the Institute of Science and Technology*, 2(2 Sp: A): 59-62.
- [66] Aybars, U., *Görüntü işleme giriş*, *Introduction to image processing*, Ege Üniversitesi Bilgisayar Mühendisliği, 17, İzmir, Türkiye, 2013.
- [67] Solak, S., Altınışık, U. (2018). Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması, *Sakarya University Journal of Science*, 22(1): 56-65, <https://doi.org/10.16984/sofenbilder.303850>
- [68] MathWorks. (2008). *MATLAB for Image Processing*. The MathWorks, Inc.
- [69] Guijarro, M., Pajares, G., Riomoros, I., Herrera, P.J., Artizzu, X.P.B., Ribeiro, A. (2011). Automatic segmentation of relevant textures in agricultural images, *Computers and Electronics in Agriculture*, 75: 75–83, <https://doi.org/10.1016/j.compag.2010.09.013>
- [70] Reis, M.J., Morais, R., Peres, E., Pereira, C., Contente, O., Soares, S., Valente, A., Baptista, J., Ferreira, P.J., Cruz, J.B. (2012). Automatic detection of bunches of grapes in natural environment from color images, *Journal of Applied Logic*, 10: 285–290, <https://doi.org/10.1016/j.jal.2012.07.004>
- [71] Bendig, J., Bolten, A., Bareth, G. (2013). UAV-based imaging for multi-temporal, very high resolution crop surface models to monitor crop growth variability. *Photogrammetrie, Fernerkundung, Geoinformation*, 2013(6), 551–562. <https://doi.org/10.1127/1432-8364/2013/0200>
- [72] Camargo, A., Smith, J.S. (2009). An Image-Processing Based Algorithm To Automatically Identify Plant Disease Visual Symptoms. *Biosystems Engineering*, 102 9–21, <https://doi.org/10.1016/j.biosystemseng.2008.09.030>
- [73] Zhang, M., Meng, Q. (2011). Automatic citrus canker detection from leaf images captured in field. *Pattern Recognition Letters*, 32 2036–2046, <https://doi.org/10.1016/j.patrec.2011.08.003>
- [74] Mahlein, A.K., Rumpf, T., Welke, P., Dehne, H.W., Plümer, L., Steiner, U., Oerke, E.C. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128 21–30, <https://doi.org/10.1016/j.rse.2012.09.019>
- [75] Kruse, O.M.O., Prats-Montalbán, J.M., Indahl, U.G., Kvaal, K., Ferrer, A., Futsaether, C.M. (2014). Pixel classification methods for identifying and quantifying leaf surface injury from digital images. *Computers and Electronics in Agriculture*, 108(2014), 155–165. <https://doi.org/10.1016/j.compag.2014.07.010>
- [76] Pujari, J.D., Yakkundimath, R., Byadgi, A. (2015). Image processing based detection of fungal diseases in plants. *Procedia Computer Science*, 46:1802-1808. <https://doi.org/10.1016/j.procs.2015.02.137>
- [77] Zhang, S., Wu, X., You, Z., Zhang, L. (2017). Leaf image based cucumber disease recognition using sparse representation classification. *Computers and Electronics in Agriculture*, 134, 135–141. <https://doi.org/10.1016/j.compag.2017.01.014>
- [78] Salgadoe, A.S.A., Robson, A.J., Lamb, D.W., Dann, E.K., Searle, C. (2018). Quantifying the severity of phytophthora root rot disease in avocado trees using image analysis. *Remote Sensing*, 10, 226, <https://doi.org/10.3390/rs10020226>
- [79] Sanchis, J.G., Guerrero, J.D.M., Olivas, E.S., Sober, M.M., Benedito, R.M., Blasco, J. (2012). Detecting rottenness caused by *Penicillium* genus fungi in citrus fruits using machine learning techniques. *Expert Systems with Applications*, 39: 780–785. <https://doi.org/10.1016/j.eswa.2011.07.073>
- [80] Barbedo, J.G.A. (2014). Using digital image processing for counting whiteflies on soybean leaves. *Journal of Asia Pacific Entomology*, 17, 685–694. <https://doi.org/10.1016/j.aspen.2014.06.014>
- [81] Wang, D.C., Yang, Y., Qiang, Z.J., Kai, Z.H., Fei, L. (2014). Detection of thrips defect on Green-Peel Citrus using hyperspectral imaging technology combining PCA and Bspline lighting correction method. *Journal of Integrative Agriculture*, 13(10), 2229-2235. [https://doi.org/10.1016/S2095-3119\(13\)60671-1](https://doi.org/10.1016/S2095-3119(13)60671-1)
- [82] Yao, Q., Xian, D., Liu, Q., Yang, B., Diao, G., Tang, J. (2014). Automated counting of rice planthoppers in paddy fields based on image processing. *Journal of Integrative Agriculture*, 13(8), 1736-1745. [https://doi.org/10.1016/S2095-3119\(14\)60799-1](https://doi.org/10.1016/S2095-3119(14)60799-1)
- [83] Artizzu, X.P.B., Ribeiro, A., Guijarro, M., Pajares, G. (2011). Realtime image processing for crop/weed discrimination in maize fields. *Computers and Electronics in Agriculture*, 75, 337–346, <https://doi.org/10.1016/j.compag.2010.12.011>
- [84] Montalvo, M., Pajares, G., Guerrero, J.M., Romeo, J., Guijarro, M., Ribeiro, A., Ruz, J.J., Cruz, J.M. (2012). Automatic detection of crop rows in maize fields with high weeds pressure. *Expert Systems with Applications*, 39, 11889-11897. <https://doi.org/10.1016/j.eswa.2012.02.117>
- [85] Rahman, M., Blackwell, B., Banerjee, N., Saraswat, D. (2015). Smartphone-based hierarchical crowdsourcing for weed identification. *Computers and Electronics in Agriculture*, 113, 14–23. <https://doi.org/10.1016/j.compag.2014.12.012>
- [86] Aggelopoulou, A.D., Bochtis, D., Fountas, S., Swain, K.C., Gemtos, T.A., Nanos, G.D. (2011). Yield prediction in apple orchards based on image processing. *Precision Agriculture*, 12, 448–456. <https://doi.org/10.1007/s11119-010-9187-0>
- [87] Zhou, R., Damerow, L., Sun, Y., Blanke, M.M. (2012). Using colour features of Cv. ‘Gala’ apple fruits in an orchard in image processing to predict yield. *Precision Agri.* 13, 568-580. <https://doi.org/10.1007/s11119-012-9269-2>
- [88] Mora, M., Avila, F., Benavides, M.C., Maldonado, G., Cáceres, J.O., Fuentes, S. (2016). Automated computation of leaf area index from fruit trees using improved image processing algorithms applied to canopy cover digital photographs. *Computers and Electronics in Agriculture*, 123, 195-202. <https://doi.org/10.1016/j.compag.2016.02.011>
- [89] Robinson, D. A., Abdu, H., Lebron, I., & Jones, S. B. (2012). Imaging of hill-slope soil moisture wetting patterns in a semi-arid oak savanna catchment using time-lapse electromagnetic induction. *Journal of Hydrology*, 416–417, 39–49. <https://doi.org/10.1016/j.jhydrol.2011.11.034>

- [90] Marié, C.L., Kirchgessner, N., Marschall, D., Walter, A., Hund, A. (2014). Rhizoslides: paper-based growth system for non-destructive, high throughput phenotyping of root development by means of image analysis. *Plant Methods*, 10, 13. <https://doi.org/10.1186/1746-4811-10-13>
- [91] Tellaèche, A., Pajares, G., Artizzu, X.P.B., Ribeiro, A. (2011). A computer vision approach for weeds identification through Support Vector Machines, *Applied Soft Computing*, 11, 908–915. <https://doi.org/10.1016/j.asoc.2010.01.011>
- [92] Ömercikoğlu, M.A.Y. (2023). *Endüstri 4.0 ile akıllı tarım uygulamaları ve veri analizi* (Yüksek Lisans Tezi). Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Sakarya, 35 s.
- [93] Xia, D., Chen, P., Wang, B., Zhang, J., Xie, C. (2018). Insect detection and classification based on an improved convolutional neural network. *Sensors*, 18(12), 4169, <https://doi.org/10.3390/s18124169>
- [94] Gong, H., Liu, T., Luo, T., Guo, J., Feng, R., Li, J., Ma, X., Mu, Y., Hu, T., Sun, Y. (2023). Based on FCN and DenseNet framework for the research of rice pest identification methods. *Agronomy*, 13(2), 410. <https://doi.org/10.3390/agronomy13020410>
- [95] Cheng, Z., Huang, R., Qian, R., Dong, W., Zhu, J., Liu, M. (2022). A lightweight crop pest detection method based on convolutional neural networks. *Applied Sciences*, 12(15), 7378. <https://doi.org/10.3390/app12157378>
- [96] Du, L., Sun, Y., Chen, S., Feng, J., Zhao, Y., Yan, Z., Zhang, X., Bian, Y. (2022). A novel object detection model based on faster R-CNN for *Spodoptera frugiperda* according to feeding trace of corn leaves. *Agriculture*, 12(2), 248, <https://doi.org/10.3390/agriculture12020248>
- [97] Li, W., Zhu, T., Li, X., Dong, J., Liu, J. (2022). Recommending advanced deep learning models for efficient insect pest detection. *Agriculture*, 12(7), 1065. <https://doi.org/10.3390/agriculture12071065>
- [98] Şin, B., Öztürk, L. (2025). Detection and Quantification of Citrus Long-horned Beetle (*Anoplophora chinensis*) in Hazelnut Orchards Using YOLOv5 Deep Learning. *Applied Fruit Science*, 67(4), 228. <https://doi.org/10.1007/s10341-025-01418-3>



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) license (<https://creativecommons.org/licenses/by/4.0/>)