

**Análisis de las Técnicas de Prevención y Detección de Enfermedades y Plagas en Cultivos
Agrícolas, Desarrolladas Bajo Tecnologías de IoT**

Adriana Franco Mesa

Asesor

Mario Andrés Ramos Goyes

Universidad Nacional Abierta y a Distancia – UNAD

Escuela de Ciencias Básicas, Tecnologías e Ingenierías – ECBTI

Especialización en Redes de Nueva Generación

2023

Dedicatoria

Con gratitud y profunda humildad, dedico esta tesis principalmente a Dios, quien ha sido mi fuente inagotable de fe, inspiración y fortaleza en cada paso de mi carrera. A mis amados padres, les dedico con profundo agradecimiento por su apoyo incondicional y amor inquebrantable. A mi hermanito por su constante apoyo y alegría en mi camino. A mi querida madrina por su constante apoyo, cariño e interés en mis logros. A mi novio por su paciencia y generoso apoyo en los momentos más difíciles. A ustedes que han sabido comprender con amor y paciencia mis tiempos, envolviéndome con palabras de aliento y sabios consejos, los cuales me han impulsado a seguir adelante sin descanso en la construcción de mi futuro, ustedes, son la base fundamental de mis logros.

Finalmente, a ustedes mi familia y seres queridos, les dedico mi tesis como testimonio de nuestro amor y unidad, como compromiso renovado de continuar creciendo y aprendiendo. Gracias por ser mi fuente de inspiración, fortaleza y motivación constante.

Agradecimientos

Deseo expresar mi profundo agradecimiento principalmente a Dios y mi familia, quienes han sido mi guía constante y mi fuente inagotable de fortaleza, amor y sabiduría a lo largo de este camino académico.

Mi especial agradecimiento al Ing. Mario Andrés Ramos Goyes MSc, mi Asesor de Tesis, quien ha sido el principal colaborador a lo largo de este proceso. Desde el momento en que recibí mi postulación para la especialización como opción de grado en la Ingeniería en Telecomunicaciones, ha estado dispuesto, brindándome dirección, conocimiento y apoyo constante. Su dedicación y paciencia al enseñarme el meticuloso proceso de investigación y proporcionándome las herramientas necesarias para el desarrollo de mi trabajo, son invaluable.

Su orientación ha sido fundamental para mi crecimiento académico.

Por último, deseo expresar mi gratitud a la Universidad Nacional Abierta y a Distancia (UNAD) y a la Escuela de Ciencias Básicas, Tecnologías e Ingeniería (ECBTI) en general. A lo largo de mi trayectoria en la institución, he tenido el privilegio de contar con docentes comprometidos, dedicados y dispuestos a la atención de los estudiantes. Reconozco que la educación a distancia requiere de un gran esfuerzo y disciplina excepcionales, y agradezco a la UNAD por proporcionar los entornos virtuales de aprendizaje propicios para mi desarrollo como estudiante y egresada Unadista.

Este logro es el resultado de un esfuerzo colectivo de la ayuda desinteresada de quienes menciono en este espacio, y estoy profundamente agradecida por haber tenido la oportunidad de aprender y crecer en este entorno educativo. A todos ustedes, mi más sincero agradecimiento por ser parte fundamental de este capítulo de mi vida académica.

Resumen

Las plagas y enfermedades en los cultivos son una de las principales amenazas para la productividad agrícola alimentaria, además, las técnicas tradicionales para combatirlas como el uso de plaguicidas también pueden generar graves deterioros a la productividad agrícola, así como en la salud de las personas y la naturaleza. Por esto, ha sido necesario desarrollar técnicas de agricultura sostenible que involucren diversas tecnologías para tomar acciones preventivas y oportunas. Es aquí donde el IoT (Internet de las cosas) juega un papel importante para la gestión eficiente de recursos y la producción amigable con el medio ambiente. Por lo anterior, en este trabajo se busca realizar una revisión bibliográfica de las técnicas de detección de plagas y enfermedades en los cultivos agrícolas basados en tecnologías IoT, lo que permite construir un estado del arte que sirva para analizar el impacto, viabilidad y alcance de dichas técnicas.

Adicionalmente, esta revisión servirá como base de consulta para la selección de alternativas idóneas para dicho fin, según el escenario de aplicación. Para ello, se busca realizar una recopilación de información actualizada referente a la mitigación de efectos adversos producidos por plagas y enfermedades en los cultivos agrícolas, mediante soluciones tecnológicas en los últimos diez años, posteriormente, se plantea realizar una comparación entre las diversas técnicas y tecnologías basadas en IoT para la detección de plagas y enfermedades, definiendo su alcance y campo de acción. Por último, se presenta un análisis del impacto de las técnicas estudiadas a partir de los resultados de productividad y reducción de efectos de degradación del medio ambiente, así como las debilidades, desafíos y tendencia tecnológica en este campo de aplicación.

Palabras clave: Agricultura de Precisión, Detección de plagas, Internet de las Cosas, IoT, Redes de sensores.

Abstract

Pests and diseases affecting crops represent one of the main threats to agricultural food productivity, in addition, traditional methods for combating these issues, such as the use of pesticides can also generate significant negative impacts on agricultural productivity, human health, and environment. Consequently, the development of sustainable agricultural techniques that involve various technologies to take preventive and timely actions has become essential. This is where the Internet of Things (IoT) plays a crucial role in the efficient management of resources and environmentally friendly production. Therefore, this work aims to conduct a literature review of pests and diseases detection techniques in agricultural crops based on IoT technologies, with the goal to generate a state-of-the-art overview that serves to analyze the impact, feasibility, and scope of these techniques.

Additionally, this review will serve as a reference for selecting suitable alternatives for this purpose, according to the specific application scenario. To achieve this, it seeks to compile updated information regarding the mitigation of adverse effects produced by pests and diseases in agricultural crops, through technological solutions at the last decade, subsequently, the identification of these threats in agricultural crops is proposed, followed by a comparison of various IoT-based techniques and technologies for pests and diseases detection, defining their scope and field of action. Finally, an analysis of the impact of the studied techniques is presented, based on the productivity results and reduction of environmental degradation effects, as well as the weaknesses, challenges, and technological trends on this field of application.

Keywords: Precision Agriculture, Pest Detection, Internet of Things, IoT, Wireless Sensor Networks.

Tabla de Contenido

Introducción	11
Descripción del Problema	12
Planteamiento del Problema.....	12
Justificación	14
Objetivos	16
Objetivo General	16
Objetivos Específicos.....	16
Marco de Referencias	17
Marco Conceptual	17
<i>Plagas</i>	17
<i>Enfermedades en Cultivos</i>	17
<i>Plaguicidas</i>	17
<i>Agricultura Sostenible</i>	18
<i>Productividad Sostenible</i>	18
<i>Internet de las Cosas (IoT)</i>	18
<i>Redes de Sensores</i>	19
<i>Agricultura de Precisión</i>	20
Marco Teórico	20
<i>Plagas y Enfermedades</i>	20

<i>Plaguicidas</i>	21
<i>Agricultura de Precisión</i>	22
<i>Internet de las Cosas (IoT)</i>	22
Protocolo	25
Definición de Criterios	26
Cadena de Búsqueda	27
Interrogantes de Investigación	30
Resultados Etapas de Revisión.....	30
Estado del Arte.....	34
Procesamiento de Imágenes	34
Inteligencia Artificial	38
Redes de Sensores Inalámbricos	64
Tecnología de Asistencia Manual	70
Análisis de Resultados	72
Tipos de Soluciones	72
Técnicas y Tecnologías	76
Análisis Comparativo.....	81
<i>Análisis de Costos</i>	82
<i>Nivel de Precisión</i>	82
<i>Gestión Tecnológica</i>	82

<i>Vigencia</i>	83
Impacto de las Técnicas y Tecnologías en la Productividad Sostenible	84
Temas Abiertos y Áreas Pendientes	87
Tendencias.....	87
Desafíos y Limitaciones.....	93
Conclusiones.....	98
Referencias Bibliográficas	101

Lista de Tablas

Tabla 1 <i>Criterios de Inclusión y Exclusión</i>	26
Tabla 2 <i>Resultados de la Cadena de Búsqueda en IEEE Explore con CII</i>	29
Tabla 3 <i>Resultados de la Cadena de Búsqueda en Scopus con CII</i>	29
Tabla 4 <i>Resumen Resultados de Revisión por Filtros de Inclusión y Exclusión</i>	32
Tabla 5 <i>Análisis Comparativo de Implementación de las Técnicas y Tecnologías con IoT</i>	83
Tabla 6 <i>Resumen Modelos y Técnicas Soluciones IoT Aplicadas</i>	91

Lista de Figuras

Figura 1 <i>Área de Mayor Impacto Potencial de IoT en Diferentes Sectores</i>	23
Figura 2 <i>Identificación de Palabras Clave para la Revisión Bibliográfica</i>	25
Figura 3 <i>Aplicación de Cadena de Búsqueda en IEEE Xplore</i>	28
Figura 4 <i>Aplicación de Cadena de Búsqueda en Scopus con CII</i>	28
Figura 5 <i>Distribución de Títulos por Tipo de Documento</i>	33
Figura 6 <i>Distribución Publicación por Tipo de Técnica Basada en IoT</i>	73
Figura 7 <i>Tendencias Tipo de Técnicas por Año de Publicación</i>	74
Figura 8 <i>Distribución de Artículos por País de Publicación</i>	75
Figura 9 <i>Mapa Superpuesto Análisis Longitudinal por Periodos con SciMAT</i>	77
Figura 10 <i>Mapa de Análisis Evolutivo Índice H con SciMAT</i>	79
Figura 11 <i>Mapa de Análisis Evolutivo del Promedio de Citaciones con SciMAT</i>	81
Figura 12 <i>Diagrama Estratégico Conteo de Documentos Principal del Periodo Intermedio</i>	88
Figura 13 <i>Diagrama Estratégico Conteo de Documentos Principal Último Periodo</i>	90

Introducción

Las plagas y enfermedades en los cultivos afectan la productividad agrícola alimentaria, además, las técnicas tradicionales para combatirlas como el uso de plaguicidas son perjudiciales para la salud de las personas y la naturaleza. Por esto, se han desarrollado soluciones en agricultura sostenible, esto ha permitido aplicar diversas tecnologías en el agro pensando más en acciones preventivas que correctivas. El IoT (Internet de las cosas) ha sido protagonista en la construcción de soluciones inteligentes, permitiendo contar con importantes alternativas que van desde soluciones de bajo costo hasta complejos sistemas de agricultura inteligente. Ante las posibilidades que nos presenta el mundo del Internet de las Cosas, es importante identificar los alcances y escenarios de aplicación de las diferentes técnicas desarrolladas hasta el momento, así como los vacíos y posibilidades de mejora de estas.

Para el desarrollo de esta revisión, se hace uso de una metodología de revisión documental que permite abordar la problemática en un periodo dado, así como extraer información relevante de las tendencias relacionadas con el tema de estudio. Para ello, se define una ventana de tiempo de 10 años, teniendo en cuenta que el campo del Internet de las Cosas ha venido evolucionando vertiginosamente y esto ha permitido mejorar las soluciones acordes a las técnicas y tecnologías emergentes.

Por lo anterior, el trabajo presenta inicialmente una contextualización de la problemática, posteriormente establece la metodología utilizada y el protocolo de búsqueda y selección de literatura. A continuación, se presenta una revisión a partir de las fuentes seleccionadas y respectivo análisis, conclusiones y posibles trabajos futuros.

Descripción del Problema

Planteamiento del Problema

La productividad en el agro está directamente relacionada al comportamiento de los factores naturales que afectan el rendimiento y calidad de un cultivo; entre las amenazas a las que se enfrentan los productores para lograr una cosecha sana y de calidad, se encuentran las enfermedades o plagas causadas por microorganismos volátiles, que como su nombre lo infiere, no pueden verse a simple vista, y que difieren de plagas como el piojo, los gusanos o la roya, que también alteran el crecimiento normal de los cultivos (ICA & Grupo técnico Procaucho, 2012). Es por esto, que los cultivadores solo identifican la enfermedad, cuando los signos ya se hacen visibles, es decir, cuando la planta requiere acciones correctivas. Lo anterior, representa un grave problema para el cultivo, teniendo en cuenta la rápida propagación de estas enfermedades por diferentes medios, desde el suelo, donde la planta adquiere minerales para su desarrollo, hasta el aire, en la polinización por aves y abejas, o incluso por la manipulación de los trabajadores que contribuye a la extensión del agente contaminante.

En la actualidad, para dar solución parcial a este problema, se llevan a cabo diversas prácticas orgánicas e inorgánicas que permiten mitigar enfermedades en los cultivos, siendo la práctica inorgánica la más utilizada por los productores de grandes extensiones, puesto que es más conveniente en términos de inversión y producción, dada su eficacia y rapidez en la eliminación de las plagas, permite alcanzar una tasa de productividad y rentabilidad alta (Silveira et al., 2018). En contraste, los métodos orgánicos, que, aunque presentan efectividad en el control de plagas y su vez, beneficios en la salud del consumidor, tiene un proceso menos rentable (Devine et al., 2008), por lo que su implementación generalmente se aplica en proyectos individuales como invernaderos y parcelaciones pequeñas. Es así, cómo las prácticas inorgánicas

en masa, para enfrentar las plagas, siguen siendo la salida más rápida y efectiva, pero es quizá uno de los métodos que más afecta tanto a los animales que cohabitan en terrenos de cultivo, como al consumidor final, esto debido a los niveles de toxicidad que pueden alcanzar los químicos utilizados para procesar, fertilizar y eliminar las plagas.

Lo anterior, lleva a cuestionarse cómo las prácticas tradicionales pueden llegar a afectar la salud del consumidor final, la calidad del suelo y la sostenibilidad ambiental. Por esto, se plantea necesario realizar una búsqueda documental que permita identificar métodos que incorporen nuevas tecnologías para la prevención de afecciones en los cultivos. Una de las tecnologías con mayor crecimiento en el ámbito de la agricultura de precisión es el Internet de las Cosas o comúnmente conocido como IoT por sus siglas en inglés (Internet of things), la cual incluye múltiples tecnologías como sensores, actuadores, controladores y servicios basados en la nube, para el control y monitoreo de elementos y entornos físicos que antes no contaba con alguna conexión a la red, permitiendo de esta manera el análisis de datos en tiempo real, para dar soporte a las necesidades del sistema en la toma de decisiones oportuna, generando cambios significativos en el sector aplicado (Brewster et al., 2017), así, teniendo en cuenta el papel potencial que brinda la implementación de sistemas basados en IoT para diferentes sectores en la economía, se plantea resolver ¿Cuál es el impacto que ofrecen las técnicas de detección de enfermedades y plagas en cultivos agrícolas, desarrolladas bajo tecnologías de IoT?

Justificación

En la actualidad, las soluciones IoT, ofrecen múltiples posibilidades de monitoreo y acción en tiempo real para diferentes campos de aplicación, uno de ellos es la agricultura, donde la apropiación de este tipo de tecnologías mejora la productividad y fortalece las buenas prácticas con el medio ambiente (Brewster et al., 2017), por ende, es importante realizar una investigación actualizada que detalle este tipo de alternativas para mitigar las plagas y enfermedades; así, con el objeto de mitigar el impacto negativo que tienen las plagas y enfermedades en los cultivos, que como bien se menciona en el artículo académico Las enfermedades de las plantas: impactos, amenazas y control, las soluciones IoT pueden ayudar a maximizar significativamente la cosecha agrícola, así como proteger los cultivos de patógenos (Jiménez, 2017). Es decir, estas soluciones tecnológicas mejoran la producción reduciendo la probabilidad de contagios, minimizando los brotes y sirviendo como medida preventiva para reducir la intervención de soluciones inorgánicas, de esta manera, se trata de buscar soluciones que no sólo se encarguen de prevenir, detectar y mitigar el impacto de las plagas en los cultivos, sino que no afecten el hábitat de otras especies no invasivas. Adicionalmente, otra de las situaciones que se puede llegar a controlar con la implementación de técnicas desarrolladas bajo tecnologías del Internet de las cosas en la agricultura, es la reducción de presencia de sustancias químicas contaminantes en el suelo que pueden generar toxicidad en la producción para el consumo (Agricultura, 2019). Por otro lado, a partir de un estudio de la Universidad de Oregon (EE.UU) se evidencia como la contaminación del suelo, disminuye la productividad de los cultivos, forzando al uso de fertilizantes y pesticidas que puede llegar no solo a afectar el suelo sino también las aguas subterráneas del entorno, dichas prácticas van en contravía de las estrategias que buscan fortalecer una agricultura sostenible (Fernandez, 2009). Por lo anterior, es evidente cómo el exceso de químico o

sustancias contaminantes en recursos hídricos, suelos o aire puede llegar a generar graves problemas que afecten la seguridad alimentaria y la salud pública (Reyes et al., 2016).

Esta investigación se realiza para dar a conocer las nuevas tendencias y alternativas tecnológicas para la detección y control de plagas en los cultivos agrícolas, con intervención de la tecnología IoT, lo que permite una reducción en la implementación e inversión de insumos y fertilizantes, en comparación con las prácticas tradicionales (Guerrero, 2021). Es así como la intervención tecnológica permitiría reducir el uso de pesticidas inorgánicos y garantizar la acción preventiva mediante interacción no invasiva.

Con esto, se presentará un panorama actualizado del impacto y beneficio de las diferentes alternativas tecnológicas basadas en IoT para la detección de plagas en un contexto de Agricultura de precisión, permitiendo automatizar y optimizar procesos de producción agrícola, que como bien lo demuestra David Prieto en su informe, la tecnificación en los cultivos agrícolas funciona como herramienta para generar un impacto exponencial en la productividad del agro (Prieto, 2019). De esta manera, se pretende brindar un análisis objetivo y comparativo de las diferentes técnicas y tecnologías indagadas con el objeto de identificar escenarios de aplicación adecuados a cada tipo de solución.

Este trabajo beneficia en gran medida a los cultivadores, ya que es necesario integrar en sus procesos de fertilización, alguna de las alternativas eco-amigables para el monitoreo de sus cultivos, evitando el uso de pesticidas (químicos), que a su vez sería un beneficio saludable para los consumidores, quienes tendrán acceso a unos productos inocuos y de buena calidad, optimización del uso de recursos hídricos, disminución en la degradación del suelo y mejora en la productividad (Ratnaparkhi et al., 2020). Estos beneficios repercuten en un fortalecimiento del sector agrícola para los países y regiones que soportan gran parte de su economía en este sector.

Objetivos

Objetivo General

Realizar una revisión bibliográfica de las técnicas de prevención y detección de plagas y enfermedades en los cultivos agrícolas basadas en tecnologías IoT para mitigar sus efectos adversos y mejorar la productividad sostenible de los cultivos.

Objetivos Específicos

Recopilar información bibliográfica relacionadas con soluciones IoT para la detección de plagas y enfermedades en cultivos agrícolas.

Comparar las diferentes soluciones de técnicas y tecnologías IoT encontradas para la prevención y detección de plagas y enfermedades en los cultivos agrícolas y la mitigación de sus efectos adversos, desde una perspectiva de productividad sostenible.

Identificar tendencias, desafíos y limitaciones en la adopción de técnicas y tecnologías IoT en el contexto de la agricultura de precisión, para la prevención y detección de plagas y enfermedades en cultivos agrícolas.

Marco de Referencias

Marco Conceptual

Se elabora una revisión bibliográfica de los conceptos más relevantes en la investigación, desde los que se sustenta el análisis de la tecnificación del agro para la prevención y detección de plagas y enfermedades en los cultivos agrícolas bajo tecnologías IoT que permita mitigar sus efectos adversos. Se consideran los siguientes conceptos: Plagas, enfermedades en los cultivos, Plaguicidas, Agricultura sostenible, Internet de las cosas (IoT), Redes de sensores (WSN) y Agricultura de precisión.

Plagas

Las plagas son definidas como cualquier organismo o animal (insectos, artrópodos, babosas, gusanos, roedores, pájaros y en ocasiones maleza y enfermedades), que causan daños evidentes a los cultivos, que pueden variar desde manchas menores que disminuyen la calidad del producto en el mercado hasta la destrucción completa del cultivo con pérdida total en el redimiendo y productividad (King, 1984).

Enfermedades en Cultivos

Las enfermedades en las plantas de cultivos, como lo infiere King, se incluye como un tipo de plaga que causan daños en los cultivos (King, 1984). Por otra parte se definen las enfermedades en cultivos como alteraciones fisiológicas causadas por la acción constante de microorganismos tales como virus, hongos o bacterias ocasionando cambios morfológicos como síntoma de enfermedad presente llegando a causar la muerte de la planta (Latorre, 2004).

Plaguicidas

El Código Internacional de Conducta Sobre la Distribución y Uso de Plaguicidas de la Food and Agriculture Organization (FAO) de las Naciones Unidas, define los plaguicidas como

sustancias o mezclas para eliminar, prevenir o controlar parásitos, incluidos los vectores de enfermedades no deseadas que ocasionan daños permanentes u otros daños que interfieren con la producción, procesamiento, almacenamiento, transporte y comercialización de alimentos (Inter-Organization Programme for the Sound Management of Chemicals et al., 2014, p.)

Agricultura Sostenible

La agricultura sostenible se relaciona al proceso ecológico de producción, que incluye la gestión y control de los recursos, es una evolución de la agricultura convencional, por lo que por lo menos debe producir un mínimo efecto negativo al medio ambiente, ya que se minimiza la liberación de sustancias tóxicas, también debe preservar la fertilidad del suelo, cuidar los recursos hídricos así como democratizar el conocimiento y acceso tecnológico aplicado a la producción agrícola (Gliessman, 2002).

Productividad Sostenible

La productividad sostenible se define como la habilidad para generar bienes o servicios de manera eficiente y continua, en un uso consciente y responsable de los recursos naturales como la tierra, el agua, la energía y la biodiversidad, con el propósito de lograr maximizar la eficiencia en la producción, manteniendo un equilibrio con los recursos disponibles y minimizando los efectos negativos en el entorno. Es así como la productividad sostenible, implica un enfoque preventivo de la contaminación con una gestión eficiente de los recursos para reducir los riesgos para la salud humana y el impacto ambiental (*Producción sostenible*, 2018).

Internet de las Cosas (IoT)

El termino IoT (Internet of Things por sus siglas en inglés) Internet de las cosas es una tecnología disruptiva, que se define como una arquitectura emergente basada en la Internet global que facilita el intercambio de bienes y servicios entre redes de la cadena de suministro y

que tiene un impacto importante en la seguridad y privacidad de los actores involucrados (Weber, 2010).

Por su parte (Salazar & Silvestre, 2016), definen IoT, como la interconexión de red de todos los objetos cotidianos, que a menudo están equipados con algún tipo de inteligencia. afirmándose como una verdadera evolución del Internet añadiendo una interconectividad más extensa, una mejor percepción de la información y servicios inteligentes más complejos.

Luego, (Rueda & Talavera, 2017) afirman que el Internet de las Cosas es una infraestructura de red autónoma, en la cual se interconectan objetos para medir variables físicas y dar solución a problemas en una variedad de escenarios de aplicación, como logística, industria, construcciones inteligentes, seguridad, agricultura, entre otros.

Redes de Sensores

Las redes de sensores inalámbricos (WSN, Wireless Sensor Network, por sus siglas en inglés), según Rueda y Talavera, comparten similitud con el término de Internet de las cosas al ser una infraestructura de red autónoma, por la que se interconectan objetos para medir variables físicas y dar solución a problemas en una variedad de escenarios de aplicación (Rueda & Talavera, 2017), por otra parte afirman que las WSN consisten en un conjunto de dispositivos autónomos, denominados nodos sensores, que están distribuidos físicamente en diferentes áreas para monitorizar condiciones físicas o ambientales, con capacidad de almacenar y comunicar datos en una red de forma inalámbrica.

Por su parte, Lazarescu, expone que las aplicaciones que hacen uso de tecnología WSN, interconectan sensores, que son enlazados a un nodo en el que se almacena la información censada; sin embargo, a pesar de contar con limitados recursos, los datos obtenidos son veraces y confiables, ya que estas plataformas suelen estar optimizadas en parámetros clave como costo,

productividad, confiabilidad, interoperabilidad y mantenimiento, para aprovechar los beneficios de los dispositivos en la aplicación (Lazarescu, 2013).

Agricultura de Precisión

La agricultura de precisión se define como el conjunto de técnicas orientadas a la optimización de los procesos de producción, a partir de la medición de variables y adopción de prácticas para la gestión de los recursos en función de la variabilidad de los factores que intervienen en la producción (Roel & Terra, 2006).

Marco Teórico

Plagas y Enfermedades

Las plagas y enfermedades en los cultivos se convierten en uno de los principales factores de preocupación que impiden el desarrollo óptimo de la producción en el campo. Con facilidad pueden confundirse y tratarse con el mismo procedimiento, pero su diferencia radica en el agente que las produce; por un lado, las plagas son ocasionadas por organismos o animales que causan daños evidentes a los cultivos, tales como insectos, vertebrados, artrópodos, moluscos y gusanos (King, 1984); las enfermedades por su parte, son ocasionadas por microorganismos, tales como hongos, virus y bacterias que afectan gravemente el metabolismo de la planta en un cultivo (Latorre, 2004). Aunque los síntomas ocasionados por estas amenazas pueden ser muy similares, presentando cambios en la morfología de las plantas, existen algunas diferencias que pueden verse reflejados en la vitalidad de las plantas en los cultivos, ya que las enfermedades al no ser tratadas con el procedimiento adecuado pueden causar la muerte de la planta, mientras que las plagas pueden ser enfermedades que afectan la calidad del producto.

Una plaga se muestra como el aumento poblacional de una especie u organismo en un determinado terreno, afectando directa o indirectamente el bienestar del ser humano, afectando

en gran medida su salud o comodidad al estar en contacto con terrenos agrícolas, forestales o ganaderos, desde donde el ser humano obtiene los recursos para su supervivencia (Brechelt, 2004a). De esta manera las plagas según su densidad poblacional y permanencia en un cultivo pueden clasificarse como plagas claves, ocasionales, potenciales y migrantes.

Las plagas claves, se muestran de forma permanente y en alta densidad mostrándose resistentes a diferentes prácticas de control, por lo que los estudios y estrategias para mitigarlas se basan siempre en esta categoría; mientras las plagas ocasionales, sólo se presentan por temporadas según el cultivo y cambio climático; por su parte las plagas potenciales, son especies de baja intensidad poblacional alojadas en los cultivos, que puede tener un incremento perjudicial, debido a pérdida de factores naturales en las plantas ocasionado por prácticas de control desmedidas; finalmente las plagas migrantes son especies de insectos no frecuentes que pueden aparecer periódicamente causando daños severos en el cultivo (Brechelt, 2004b).

Plaguicidas

En décadas anteriores el uso de plaguicidas sintéticos era la alternativa común en la producción agrícola, basándose fundamentalmente al control de plagas mediante productos de naturaleza inorgánica (Perez & Vázquez, 2001). Este uso excesivo de plaguicidas sin apoyo técnico previo, en lugar de resolver el problema, ha causado graves daños a la productividad agrícola, las personas y la naturaleza. Por lo anterior, actualmente muchas instituciones están en la búsqueda de alternativas menos dañinas, aprovechando las defensas naturales de los organismos y reorganizando completamente las técnicas de cultivos tradicionales (Brechelt, 2004b).

Agricultura de Precisión

Una producción sostenible va de la mano de unas buenas prácticas de gestión amigable con el medio ambiente, y para lograr este fin se han apropiado técnicas en contravía de la agricultura convencional, principalmente basada en labranza intensiva, irrigación, aplicación de fertilizantes inorgánicos y control químico de plagas (Gliessman, 2002). Una de las oportunidades, para mitigar estos efectos adversos causados por las prácticas tradicionales, es sin lugar a duda la tecnificación y apropiación tecnológica del agro. Esta evolución se ha dado con el paso del tiempo a partir de resultados exitosos en países de primer mundo, lo que ha permitido evidenciar un mayor impacto positivo en los procesos relacionados con la agricultura. Existen diversas alternativas tecnológicas que han sido implementadas, pasando por las redes de sensores, la identificación por radiofrecuencia (RFID), el uso de bluetooth, la comunicación de campo cercano (NFC), entre otras tecnologías que han generado una comunicación inteligente (Khanna & Kaur, 2019). Es así cómo el IoT se ha convertido en una base para dar soluciones en este campo, donde confluyen diversas tecnologías según las necesidades de aplicación.

Internet de las Cosas (IoT)

El auge de la cuarta revolución industrial ha permitido incorporar diversas tecnologías emergentes en diferentes campos de aplicación, la agricultura no ha sido una excepción y la aplicabilidad de estas alternativas evidencian cada vez más una consolidación de la agricultura de precisión, por ejemplo el estudio de redes inalámbricas IoT para la detección y control en tiempo real de parámetros que afectan plantas como la palma africana desde su amarillamiento hasta su secamiento (Molina, 2020), también, se han realizado revisiones de tecnologías habilitadores para el control biológico y de plagas en el sector hortofrutícola para detectar el menor tiempo posible cualquier brote que afecte a este tipo de cultivos (Martín et al., 2021),

incluso, se han implementado sistemas de monitoreo de cultivos en tiempo real que permite recopilar datos y analizarlos para la toma de decisiones en cualquier tipo de alerta que pueda afectar al cultivo (Gómez et al., 2017).

Figura 1

Área de Mayor Impacto Potencial de IoT en Diferentes Sectores

	Ex-post			Current			Future	
	Evaluation and Assessment			Measurement and Real-time Feedback			Prediction and Planning	
Financial Services	Mobile money agent placement			Algorithmic fraud detection	Social network analysis marketing	Agent network monitoring	Enhanced credit scoring	Algorithmic liquidity needs prediction
Economic Development	Income and poverty assessment	Mapping social divides	GDP estimates through mobile data	Migration monitoring			Text analysis economic downturn prediction	Text analysis commodity fluctuation prediction
Health	Assessment of mobility restrictions			Disease containment targeting	Migratory population tracking		Predicting outbreak spread	
Agriculture	Mobile data to track food assistance delivery			Geo-targeted links between suppliers/purchasers	Pests, bad harvest alerts		Agricultural yield/shock predictions	
Commercial	Campaign effectiveness	Social network delineated market areas					Predictive algorithms to anticipate product churn	Social network targeted marketing
Other	Post-disaster refugee reunification	Sentiment analysis of public campaigns	Urban planning	Mobile disaster relief targeting	High frequency surveys	Crime detection	Social unrest prediction	

■ High
■ Medium
■ Low
 Pilot identified

Source: Naef et al. (2014), quoted in the "Measuring the Information Society 2014" report, ITU.

Nota. Areas of Highest Potential Impact across Different Sectors. Tomado de Harnessing-IoT-Global-Development (p.30) por (Biggs et al., 2016), ITU.

En la actualidad, el impacto potencial en la implementación de las tecnologías de Internet de las cosas en el sector agrícola presenta un impacto importante en la medición y realimentación en tiempo real de factores que intervienen en la productividad de los cultivos en la detección de

plagas y alertas tempranas de malas cosechas como se observa en Figura 1, que además presenta una medición de este impacto frente a otros sectores de aplicación, proyectándose a este tiempo, en temas de mayor impacto como es el caso de la predicción y planificación del rendimiento de los cultivos en el sector agrícola alimentario.

Es así como IoT ha permitido diversificar alternativas para mitigar los efectos ocasionados por las plagas y enfermedades en los cultivos, presentando cada vez más soluciones que permiten una convergencia de tecnologías en una sola red incluyendo diferentes dispositivos, instrumentos, vehículos, edificaciones entre otros elementos, integrados con circuitos electrónicos, software, sensores y conectividad, dando soporte al intercambio de información relevante del sistema para la toma de decisiones oportuna sobre el problema detectado (Gokhale et al., 2018), aunque la adopción de tecnologías basadas en IoT para el sector agroalimentario enfrenta algunos desafíos de desarrollo e implementación, también presenta unos impulsos importantes (Brewster et al., 2017), que induce analizar el impacto de cada una de estas posibilidades, su aplicabilidad, alcance y contexto de implementación.

más completa de las tendencias, avances y soluciones en el campo de las tecnologías IoT aplicadas a la mitigación y detección de plagas y enfermedades en los cultivos agrícolas, es así como a partir de la búsqueda preliminar realizada, se diseñó un protocolo de investigación que además de definir las palabras claves, permitió identificar y filtrar con mayor precisión los títulos que mejor se ajustan a la investigación.

Definición de Criterios

A partir de los resultados de búsqueda, se establecieron los Criterios de Inclusión y Exclusión que se muestran en *Tabla 1*, para seleccionar los artículos más relevantes en la revisión bibliográfica resaltando la pertinencia de soluciones practica basadas en tecnologías IoT para mitigar enfermedades y plagas en los cultivos agrícolas:

Tabla 1

Criterios de Inclusión y Exclusión

Criterios de Inclusión		Criterios de Exclusión	
CI1	Artículos y Conferencias	CE1	Se descartan los documentos con menos de cinco páginas debido a su falta de profundidad y detalle.
CI2	Artículos y Conferencias que presenten una solución para mitigar pestes y enfermedades en cultivos agrícolas mediante IoT.	CE2	Se excluyen las revisiones, notas, posters y encuestas, ya que no presentan una solución práctica.
CI3	La solución propuesta debe tener una implementación práctica o resultados medibles.	CE3	Los artículos y conferencias anteriores a 2013 (10 años) no serán considerados, ya que buscan obtener una ventana de investigación más reciente.

CI4	Los términos de la Cadena de Búsqueda deben estar presentes en el título o en el resumen del Artículo.	CE4	Se excluyen soluciones enfocadas en fuentes hídricas, ya que esta investigación pretende abordar las soluciones a plagas en cultivos agrícolas.
		CE5	Las soluciones para agricultura con animales no serán consideradas, ya que se busca un enfoque exclusivo a las plagas que afectan los cultivos agrícolas.
		CE6	Se descartan artículos anteriores a 2020 (mayor a 3 años) sin citas, y los artículos recientemente publicados entre 2020 y 2022 sin citas, ya que se busca evaluar las soluciones con respaldo y reconocimiento en la comunidad científica, considerando un período de tiempo razonable para que los estudios sean evaluados y validados por otros investigadores antes de su implementación.

Nota. La Tabla enlista los Criterios de Inclusión y Exclusión como parte de la revisión documental de la investigación

Cadena de Búsqueda

Para identificar los artículos pertinentes en este estudio se diseñó una ecuación de búsqueda que comprende las palabras claves seleccionadas exhaustivamente para capturar los trabajos relacionados al objetivo de la investigación teniendo en cuenta los criterios CI1 y CE3,

como se muestra en las *Figuras 3 y Figura 4*, donde se observa la aplicación de la cadena de búsqueda en las bases de datos de IEEE Explore y Scopus respectivamente, más adelante se consignas los resultados derivados de la exploración en las dos BD (Bases de Datos) en *Tablas 2 y Tabla 3* respectivamente, en las cuales se incluye una columna con los valores obtenidos del primer Filtro de Inclusión CII.

Figura 3

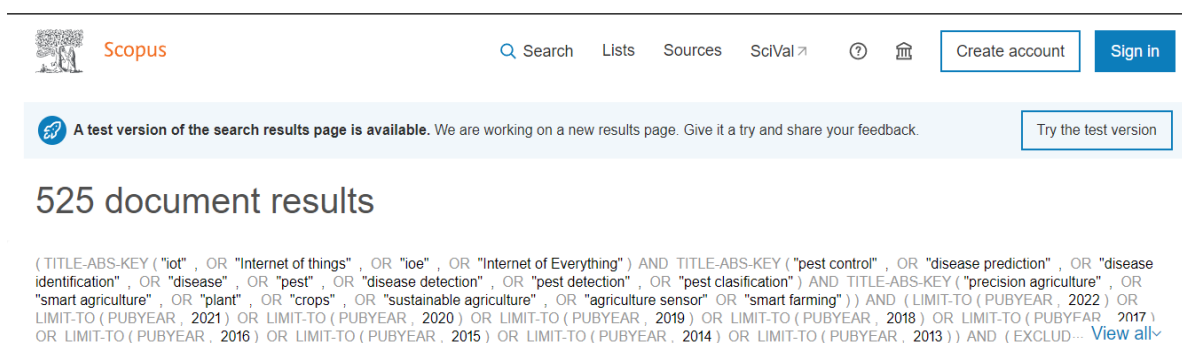
Aplicación de Cadena de Búsqueda en IEEE Xplore



Nota. Captura de Pantalla en IEEE Explore, de Elaboración propia

Figura 4

Aplicación de Cadena de Búsqueda en Scopus con CII



Nota. Captura de Pantalla en Scopus, de Elaboración propia

Tabla 2*Resultados de la Cadena de Búsqueda en IEEE Explore con CII*

Fuente	Tipo documento	Resultados	Result. CII
ConfIEEE	Conferences	199	199
JourIEEE	Journals	32	32
EarlIEEE	Early access articles	3	
BookIEEE	Books	2	
MagaIEEE	Magazines	1	
Total		237	231

Nota. Esta tabla presenta los resultados de búsqueda en IEEE Explore, con primer filtro de Inclusión CII

Tabla 3*Resultados de la Cadena de Búsqueda en Scopus con CII*

Tipo de Documento	Resultados	Result. CII
Article	202	202
Conference Paper	323	323
Review	44	
Book Chapter	45	
Conference Review	91	
Book	4	
Retracted	1	
Data Paper	1	
Erratum	1	
Total	712	525

Nota. Esta tabla presenta los resultados de búsqueda en Scopus, con el primer filtro de Inclusión CII

Interrogantes de Investigación

Las preguntas que se abordarán en esta investigación son las siguientes:

¿Cuáles son las tendencias en la aplicación de soluciones IoT para la mitigación y/o detección temprana de plagas y enfermedades en los cultivos agrícolas?

¿En qué países se presenta mayor número de desarrollo en soluciones bajo tecnologías IoT para la mitigación de plagas y enfermedades?

¿Cuál es el impacto de las soluciones, desarrolladas bajo tecnologías IoT para la mitigación y/o detección temprana de plagas y enfermedades en los cultivos agrícolas?

Cada uno de estos interrogantes permitirán comprender el estado actual de las soluciones en IoT para la mitigación de plagas y enfermedades en los cultivos agrícolas, consiguiendo a partir del estudio de las tendencias del estudio realizado identificar las innovaciones más recientes, así como las áreas de mayor enfoque en este campo. Además, al conocer los cultivos específicos donde se aplica con mayor frecuencia estas tendencias, se logran identificar con precisión los tipos de cultivos se benefician más de este tipo de soluciones. De esta manera al conocer los países donde se han implementado estas soluciones, permite identificar los entornos más propicios para la implementación de estas tecnologías. Finalmente, al evaluar el impacto de estas soluciones en los cultivos agrícolas, se logra comprender como y en qué medida, contribuyen a mejorar la eficiencia, la productividad y sostenibilidad en la agricultura.

Resultados Etapas de Revisión

Se presenta un resumen de la búsqueda inicial y los filtros aplicados en cada etapa de la revisión y selección de artículos, que busca garantizar la identificación específica de los artículos más relevantes que den respuesta al objetivo de la investigación:

Filtro 1, Exclusión de Duplicidad de artículos: En esta etapa, se eliminaron los artículos duplicados que parecían tanto en la DB IEEE Xplore como en SCOPUS, con lo que se redujo un 23.09% el número total de artículos pasando de 756 en la búsqueda inicial a 581 artículos.

Filtro 2, Criterios CE1 y CI2: En este filtro se permitieron solamente aquellos artículos que presentaban una solución que responda al objetivo de la investigación, y se excluyeron los documentos con menos de 5 páginas de extensión, considerando que no tendrían la profundidad necesaria para abordar la temática propuesta, lo que redujo un 14.29% con respecto al filtro anterior, pasando de 581 a 498 artículos.

Filtro 3, Criterio CE2: Se excluyeron los documentos que atendían a revisiones, las cuales no presentaban una solución práctica para la problemática propuesta, lo que redujo la selección a un 11.24% con relación al filtro 2.

Filtro 4, Criterio CE4, CE5 y CE6: En este filtro de exclusión se omiten los documentos que no implementan una solución orientada específicamente a la mitigación de plagas y enfermedades en los cultivos agrícolas, tales como agricultura de animales, fuentes hídricas, salud humana, entre otros; además se descartaron los artículos sin citas; lo que permitió refinar aún más la selección con resultados más específicos y actualizados, pasando de 442 a 271 artículos.

Filtro 5, Criterios CI3 y CI4: Por último, en esta etapa, se destacaron únicamente los artículos que presentaban una implementación práctica con resultados medibles, asegurando además que los términos de búsqueda estuviesen presentes en gran medida en título o resumen.

Finalmente, la selección de artículos se acotó en un 79.9% con respecto a los resultados de búsqueda inicial como se consolida en *Tabla 4*, lo que permitió obtener una base documental sólida, altamente relevante y respaldada por evidencia.

Tabla 4*Resumen Resultados de Revisión por Filtros de Inclusión y Exclusión*


Base de Datos	Tipo Documento	Resultados Inicial	Resultados				
			Filtro 1	Filtro 2	Filtro 3	Filtro 4	Filtro 5
IEEE	Conferences	199	196	137	124	37	17
	Journals	32	32	32	25	23	19
SCOPUS	Article	202	178	172	155	126	79
	Conference	323	175	157	138	85	36
	Paper						
Total		756	581	498	442	271	151

Nota. Esta tabla presenta los resultados de la revisión realizada por filtros de inclusión y exclusión

Tras esta revisión documental, se ha logrado identificar la distribución de las publicaciones filtradas según tipo de documento como se muestra en la *Figura 5* donde los Artículos muestran el mayor nivel de participación investigativa con 98 publicaciones equivalente al 65% de los hallazgos entre Scopus e IEEE Xplore. Esto no solo evidencia un enfoque investigativo dominante sino también un patrón de preferencia por este tipo de producción investigativa en ambos motores de búsqueda. Mientras las Conferencias representan el 35% con 54 publicaciones identificadas, demostrando también un número significativo en la comunicación e intercambio de ideas en eventos académicos en el área de interés.

Figura 5

Distribución de Títulos por Tipo de Documento



Nota. Gráfica de Elaboración propia con herramientas de Microsoft Excel

Estado del Arte

Se han identificado diferentes alternativas IoT como solución a la prevención y detección de enfermedades y plagas en cultivos agrícolas, entre las más representativas a partir de la revisión realizada en la última década se presentan a continuación.

Procesamiento de Imágenes

Dentro de las técnicas y métodos para la identificación y detección temprana de enfermedades en los cultivos agrícolas, se encontraron diferentes variables y métodos para el reconocimiento y segmentación de imágenes a partir de distintas metodologías, como lo proponen (S. Zhang et al., 2018) mediante la adquisición y análisis de fotogramas tomados de las hojas para el reconocimiento de enfermedades en las plantas, basado en la fusión de algoritmos de agrupación de super-píxeles, K-mean clustering y la pirámide de histogramas de gradientes de orientación (PHOG) en el procesamiento digital de imágenes. De igual manera, (S. Zhang et al., 2020) proponen un sistema de monitoreo y reconocimiento de enfermedades en cultivos agrícolas, basado en el Soft Computing y el procesamiento de imágenes, a partir de un algoritmo de clusterización K-mean para la segmentación de las imágenes tomadas de las hojas de las plantas, en conjunto con el vector características del histograma de suma y diferencia (SADH) que extrae una función de los valores de intensidad de los píxeles vecinos de las imágenes segmentadas, con lo que han alcanzado un 94.4% de precisión en la tasa de reconocimiento de enfermedades en un cultivo de pepino.

La segmentación de imágenes es una de las técnicas que mayor implementación tiene en la identificación y clasificación de enfermedades en las hojas de las plantas, desde donde diferentes propuestas lo exponen implementando diferentes métodos y funciones, por su parte, (Aasha Nandhini et al., 2018) presentan una solución basada en el Sensado Comprimido (CS)

para el ahorro de almacenamiento de los datos obtenidos de una red de sensores controlada por una Raspberry pi, que además facilita más adelante la reconstrucción de las características de los datos medidos de la imagen por la matriz GMCL (Biblioteca de Cálculo Matricial Generativo) y el clasificador SVM (Maquina de soporte Vectorial) para clasificar la enfermedad en las plantas, con la función de clasificación lineal Kernel; con lo que a modo experimental, obtienen una precisión de detección general de aproximadamente 98.5% y 98.4% para una precisión de clasificación general de las enfermedades en las hojas de las plantas. De igual forma, (D. Zhao et al., 2016) presentaron un sistema de control de invernadero en el que incluyen una solución basada en técnicas de minería de datos y análisis de imágenes, a partir de un algoritmo de análisis de texturas para extraer características de las imágenes de las hojas de las plantas, y un clasificador basado en la técnica de SVM para determinar si la planta está sana o infectada por alguna enfermedad o plaga. Igualmente, (Karthickmanoj et al., 2021) presentan el desarrollo de un sistema automatizado para la detección temprana de enfermedades en las hojas de las plantas basado en técnicas de segmentación de píxeles y procesamiento de imágenes soportado en el clasificador SVM, demostrando una precisión de detección superior al 95%.

Así mismo, (Yue et al., 2018) proponen un sistema de reconocimiento de plagas en cultivos agrícolas a partir de una técnica de super resolución recursiva profunda mediante el método de Pirámide Laplaciana para la representación y análisis de imágenes en más de una resolución, que en programación, se basa en la predicción de la apariencia de la siguiente capa fina en una pirámide Gaussiana, consiguiendo desplegar menos cámaras en los cultivos y con ellos aminorar costos de implementación; de esta manera, este método logra restaurar y muestrear la imagen, a una escala de píxeles adaptada a las características del insecto o peste

capturada; lo cual ha permitido demostrar una mejora en la tasa de recuperación de detección en un 202.06%.

Por su parte, (Pandiyan et al., 2020) propone un algoritmo para la detección de enfermedades en las hojas de las plantas, a partir de la segmentación de imágenes con un método de extracción de dimensión segmentada avanzada (ASDE) con aspectos de procedimiento de HIoT (Internet de las cosas Heterogéneo) que permite identificar el gesto de impacto en una imagen, basado en la detección de signos semejantes en tiempo real; logrando así una precisión del 97.35% en la identificación de enfermedades en las hojas de las plantas.

En cambio, (Rustia & Lin, 2017) propone un sistema para el control remoto de plagas e insectos en un cultivo de coles de invernadero, desde la aplicación de una red de imágenes y sensores inalámbricos (WiSN), que, además de medir las condiciones ambientales del entorno, el objetivo de este sistema es contabilizar la cantidad de insectos atrapados en trampas de papel adhesivo amarillo localizados en diferentes puntos del invernadero, a partir del procesamiento de imágenes y algoritmos de aprendizaje automático de clasificación de objetos en blanco y negro; es así como este sistema logra una precisión de clasificación aproximada del 98% en un tiempo de cálculo entre 8 y 9 segundos por imagen.

De la misma manera, (Chunduri & Menaka, 2019) diseñan un sistema soportado en Raspberry Pi, para el monitoreo y control de la salud de las plantas, a partir de la adquisición y procesamiento de imágenes e información sensada (Temperatura, Humedad y pH) para la toma de decisiones en tiempo real; basado en métodos de segmentación de imágenes como el Thresholding que permite separar los objetos de interés de la imagen en escala de grises para detectar pestes e insectos presentes en las hojas; al igual que la conversión de RGB a HSV para destacar los pixeles verdes como el área saludable de la hoja y de esta manera detectar el

porcentaje de región infectada en la planta; logrando reducir los costos de producción (fertilizantes y pesticidas), así como el aprovechamiento de los recursos naturales. De manera similar, (Indira et al., 2018) presentan una solución que involucra en una de sus etapas el procesamiento de imágenes y el uso de sensores en el suelo para la detección de condiciones adversas al cultivo. Así mismo, (Thangadurai et al., 2020) implementan un sistema de automatización para la detección de enfermedades en las hojas de la caña de azúcar aplicando técnicas de procesamiento y segmentación de imágenes, así como un modelo de aprendizaje automático para el entrenamiento del robot con el que logran obtener una precisión de detección del 98,60%. También (Loganathan et al., 2022) propone un sistema de detección de enfermedades en los cultivos utilizando un robot agrícola denominado AgriBOT el cual está dotado con sensores IoT para la medición de factores ambientales y del suelo, así como capturar de imágenes de las hojas del cultivo; además introducen un enfoque de Machine Learning denominado Esquema Neuronal Convolutiva Modificado (MCNS) para la predicción automática de las condiciones climáticas propensas a la aparición de enfermedades.

Anteriormente, (Xiao et al., 2015) había propuesto un sistema de dispositivos y cámaras IoT dotado con un modelo basado en el procesamiento de imágenes para el monitoreo y detección de una plaga de la fruta, denominada *bactrocera dorsalis* utilizando un método de filtrado de Kalman para predecir la posición del movimiento del objeto de estudio a partir del desarrollo de un algoritmo de cuenca hidrográfica basado en el peso del segmento de una imagen para hacer seguimiento al objeto y etiquetarlo; entre otras características que les permitió lograr una precisión de detección del 94.9%.

Inteligencia Artificial

Se destacan además, algunas técnicas que mediante diferentes variantes de la Inteligencia Artificial (IA) logran la identificación y clasificación de enfermedades en las plantas de los cultivos agrícolas, como lo expone (Jiang et al., 2019) con la detección temprana de enfermedades en las hojas del manzano, basado en redes neuronales convolucionales mejoradas (CNN) mediante la introducción de la estructura GoogLeNet Inception y concatenación Rainbow, a partir del estudio de un conjunto de datos compuesto por imágenes de laboratorio e imágenes complejas en condiciones reales de cultivo. De la misma manera, (Chiwamba et al., 2019) propone un sistema de automatización de trampas de feromonas para insectos, basada en el modelo de Aprendizaje Automático InceptionV3 pre entrenado de Google, para la detección de la polilla o gusano cogollero (*Spodoptera frugiperda*) en plantas de maíz, a partir de la adquisición y análisis de datos en la nube, de la captura de imágenes de las trampas automatizadas en una red de sensores controlada y soportadas en una Raspberry Pi3. Por su parte (Pranav et al., 2021) también presenta una solución integral que ofrece la predicción de enfermedades en las plantas basado en el modelo de Aprendizaje Automático pre entrenado de Google Inception V2 soportado en una tarjeta de desarrollo Arduino con servicio en la nube para la interacción con una aplicación para el usuario quien captura imágenes de consulta para la predicción. De esta manera, el modelo alcanza una precisión promedio de validación y entrenamiento del 96%. De la misma manera (Ramana et al., 2022) proponen un sistema compuesto por sensores y cámaras controlados desde un módulo Raspberry Pi3, para recopilar información del cultivo que permita detectar y clasificar enfermedades en las hojas de las plantas, con un algoritmo basado en una arquitectura de red CNN alcanzando una precisión de clasificación del 96%.

Así mismo (Basori et al., 2020) construyen un Framework denominado SMARF que se basa en un modelo de red CNN, para detectar y prevenir enfermedades en las plantas, este sistema además está compuesto por una plataforma IoT que recopila datos sensados del ambiente, como la humedad del suelo y la temperatura para mejorar la detección y prevención de enfermedades en las plantas, logrando de esta manera una precisión de detección de enfermedades del 98,3%. De manera similar, (Patil & Kumar, 2022) presenta un nuevo Framework de fusión de datos multimodal denominado Rice-Fusion para el diagnóstico confiable de enfermedades en el cultivo de arroz, el cual se basa en el modelo Keras que permite la entrada de múltiples modelos de cálculo (numérico o datos de sensores o imágenes) en redes CNN, alcanzando una precisión de detección del 95.3% con extracción de características en modelos unimodales concatenados.

Por su parte, (Nasir et al., 2020) presenta una propuesta basada en CNN, con un enfoque que resalta las características de las frutas y sus diferentes tipos de enfermedades, para su clasificación a través de un modelo de Deep Learning VGG19 afinado y reentrenado a partir de una base de datos de las plantas desde donde se obtienen características del contorno, basado en la segmentación de imágenes mediante el uso de la función PHOG; logrando así una precisión de clasificación múltiple del 99.6%. A su vez, (Kong et al., 2020) propone un modelo de reconocimiento de grano fino de plagas y enfermedades en cultivos agrícolas, basado en redes neuronales de fusión de probabilidad gaussiana de Múltiples Flujos (MPFN), a partir del entrenamiento de redes básicas VGG19 y ResNet en datos aumentados de imágenes obtenidas en una red de cámaras IoT, este modelo Deep Learning, además consta de redes refinadas incluidas Fast-MPN y NTS-Net con aprendizaje de transferencia para la extracción de características de alta dimensionalidad; con lo que consigue obtener una tasa de precisión del 93.18% en el

reconocimiento de 181 clases de plagas y enfermedades en total, siendo un 5.6% mejor que los métodos anteriores en Deep Learning de grano grueso y grano fino. A su vez (Narimani et al., 2021) presentan una solución de un sistema integral de monitoreo y automatización de invernadero, que incluye una función para la detección de enfermedades en las plantas basada en el desarrollo de un Framework de Deep Learning utilizando diferentes arquitecturas de Deep Learning como VGG-19, InceptionResNetV2 e InceptionV3 para analizar las imágenes capturadas periódicamente en el cultivo, demostrando el mejor rendimiento del sistema con el algoritmo VGG-19 con una precisión de detección del 92% sobre las demás arquitecturas. Igualmente, (Naveenkumar et al., 2021) presentan el desarrollo de un Framework basado en redes CNN para la detección y clasificación de enfermedades en las hojas de la papa, entrenado en diferentes modelos de Deep Learning como VGG16, VGG19, ResNet50, InceptionV3 e InceptionResNetV2 alcanzando la mejor precisión de clasificación del 93% con el modelo InceptionResNetV2.

Por su parte, (Jakjoud et al., 2019) realizan la detección automática de enfermedades en las plantas a partir del desarrollo de una aplicación basada en un modelo de redes CNN soportada en la arquitectura VGGnet16 para diferenciar entre hojas sanas y enfermas, que además está compuesta por optimizadores de aprendizaje adaptativo como Adadelta y SGD para evaluar la precisión y estabilidad del modelo. De la misma manera, (Barburiceanu et al., 2021) proponen un método basado en Deep Learning basado en la clasificación de texturas para la detección de enfermedades en las hojas de las plantas, soportada en diferentes técnicas de redes CNN como la arquitectura VGG-16, AlexNet y ResNet, destacando el rendimiento del modelo AlexNet en términos de clasificación y tiempo de procesamiento en tiempo real. También, (S. Garg et al., 2021) implementan un sistema integral multimodal para el monitoreo de cultivos en el que

incluyen una función para la detección de enfermedades en las plantas basado en una red CNN pre-entrenada con modelos como VGG-16, RestNet50 y DenseNet121 para la clasificación y extracción de características de imágenes, demostrando un rendimiento sectorizado en la precisión de detección de cada modelo según el tipo de cultivo. A su vez, (Akther et al., 2021) también presentan una solución basada en la arquitectura VGG-16 para la predicción de la enfermedad de tizón de papa, pre entrenada en ImageNet para la extracción de características de las imágenes capturadas del cultivo, alcanzando una precisión de detección del 96.88%. (Alatawi et al., 2022) establecen una solución basada en el modelo VGG-16 para la detección temprana de enfermedades en las plantas que permite a los usuarios tomar medidas de tratamiento de manera oportuna, logrando una precisión de detección del 95.2% con pérdidas de 0.4418.

Así mismo, (Y. Zhao et al., 2020), desarrollan un sistema de Deep Learning basado en CNN, desde un enfoque denominado Multi-Context Fusion Network (MCFN) para el reconocimiento de enfermedades en cultivos silvestres a partir de la extracción de las características relevantes de las imágenes tomadas de los sensores de adquisición de imágenes, como basa para la clasificación de enfermedades en el sistema ContextNet la cual permite incorporar información de contexto global en capas de convulsión; obteniendo una precisión del 97.5% en identificación de enfermedades comunes en los cultivos silvestres. Igualmente, (Hu et al., 2020) expone un sistema en Deep Learning, con un modelo de redes neuronales residual de compensación de características multidimensional MDFC-ResNet, para el reconocimiento y análisis de enfermedades de grano grueso y grano fino en los cultivos agrícolas, para enviar resultados de diagnóstico de enfermedades en los cultivos a los agricultores, con la mejora de este sistema IoT y la aplicación de modelo MDFC-ResNet, logran demostrar una mejoría en los

efectos de identificación detallada, comparado con los modelos comunes de Deep Learning. De manera similar, (Wu et al., 2022) abordan un enfoque basado en redes CNN compuesta por técnicas de procesamiento de imágenes para la detección y categorización precisa de enfermedades en las hojas de las plantas, a partir de la extracción de características y la clasificación de grano fino para la identificación de brote.

En contraste, (Dai et al., 2020) construyen un método para la detección de enfermedades en plantas, basado en una Red Generativa Adversarial (GAN) para aumentar la resolución de las imágenes de baja resolución de las hojas de las plantas, junto con una Red Residual (ResNet) y Densa de atención mejorada para identificar las características y patrones de la imagen que permiten la clasificación y detección temprana, la presencia de enfermedades en las plantas a partir de imágenes de alta resolución de las hojas de las plantas. Al igual que (Prabu et al., 2022), desarrollan un sistema de protección del cultivo (ICFPS) para el monitoreo y protección de plagas y enfermedades, basado en una red WSN para la medición de diferentes parámetros ambientales y de presencia, como sensores ultrasónicos, cámaras hiperespectrales y zumbadores grabados por voz, esto con el fin de detectar y dispersar los animales en el cultivo. Cabe mencionar que esta propuesta, utiliza técnicas de Deep Learning como redes neuronales RCNN y RGAN para la extracción de características de las imágenes tomadas del cultivo en el proceso para la detección de enfermedades y plagas. De la misma manera, (Bala Murugan et al., 2021) propone una solución integral para el monitoreo remoto de cultivos desde una red WSN con adquisición y análisis de datos en la nube basado en un modelo Deep Learning RestNet para la predicción temprana de enfermedades en las hojas de las plantas, alcanzando un 99.35% de precisión de detección.

También, (Sowmyalakshmi et al., 2021) establece una solución basada en redes CNN con ResNet v2 para la extracción de características de las imágenes y un modelo de clasificación para el diagnóstico de enfermedades de las plantas de arroz denominado Optimal Weighted Extreme Learning Machine (CNNIR-OWELM), el cual está compuesto por una red de sensores y dispositivos IoT para la captura de imágenes de las plantas de arroz, que luego son almacenadas en la nube a través de internet, luego utiliza la segmentación por Histograma para identificar la zona afectada en la imagen; de esta manera, los resultados experimentales muestran que el modelo propuesto logra una precisión del 94,2%, una sensibilidad del 90,5% y una especificidad del 96,1%, lo que lo convierte en un modelo altamente efectivo para la detección de enfermedades en plantas de arroz. De manera similar (Karar et al., 2021) proponen un framework desarrollado bajo un algoritmo Clasificador de aprendizaje automático InceptionResNet-V2 que permite analizar e identificar de manera temprana, la infección por el insecto picudo rojo de la palma, a partir de la adquisición de datos en el tronco de la palmera utilizando sensores de sonido TreeVibes, logrando una precisión de clasificación promedio del 97.18%.

A su vez, (Pavel et al., 2021) implementa un sistema inteligente de reconocimiento de enfermedades en las plantas basado en diferentes redes CNN de Deep Learning experimentales como Inception-V3, InceptionResNet-V2 y ResNet34, que soportada en una arquitectura IoT de sensores y una aplicación de usuario tipo Android, el sistema es capaz de reconocer enfermedades en 14 especies diferentes que incluyen cultivos de manzana, papa, maíz pimentón, entre otros, a partir del conjunto de datos PlantVillage; logrando demostrar la mayor precisión de detección del 97.03% con la arquitectura ResNet34.

Por su parte, (Agarwal et al., 2020) presenta un modelo de CNN por capas basado en Deep Learning para la detección de enfermedades a partir del análisis de la interpretación visual de las hojas en diferentes cultivos de papa, el cual está compuesto por cuatro capas de convulsión con 32, 16 y 8 filtros en cada capa, consiguiendo una precisión de entrenamiento del 99.47% y un 99.8% en la precisión de la prueba. Así mismo (Khan et al., 2020) presenta un sistema de monitoreo de invernadero para el control de las condiciones ambientales del cultivo, a partir de una red WSN y cámaras IoT, basado en un preprocesamiento y segmentación de imágenes con un algoritmo de clusterización K-Mean y soportado en una red CNN denominada AlexNet, capaz de reconocer características de una imagen y clasificarla por completo. También, (Delnevo et al., 2022) proponen un modelo basado en una red neuronal CNN para la detección de enfermedades en las imágenes de las hojas de las plantas soportado en una red WSN para recopilar información ambiental (temperatura, humedad y radiación solar) que permiten a partir de un entrenamiento Deep Learning, predecir la aparición de enfermedades en las plantas antes de que se manifiesten visualmente.

Por su parte, (Kishan Das Menon et al., 2020) establece una solución para el monitoreo del crecimiento de las plantas, en la que se incluye la detección de enfermedades en las plantas soportada en una red CNN aplicando un modelo de Deep Learning (AlexNet) para la identificación de la infección en las hojas de las plantas a partir de la captura de imágenes. De la misma manera (Madhulatha & Ramadevi, 2020) presenta una solución basada en una red CNN de arquitectura pre-entrenada AlexNet y optimización de capas para la detección y clasificación de diferentes enfermedades en las plantas en 38 clases diferentes alojados en un conjunto de datos PlantVillage, con una precisión del 96.5% en términos de clasificación. Así mismo (Zakzouk et al., 2021) proponen el desarrollo de una solución basada en la arquitectura Deep

Learning de Clasificación AlexNet para la detección de tres enfermedades diferentes en la hoja del arroz, alcanzando una precisión del 99.71%, mostrándose superior a los resultados obtenidos en trabajos anteriores.

De igual manera, (J. Zhang et al., 2021) han desarrollado una propuesta basada en una red CNN para el reconocimiento de enfermedades en las hojas del pepino, incluyendo un método de segmentación de imágenes en dos capas para la extracción de características diferenciable de la mancha de enfermedad en las hojas del pepino para el entrenamiento de una red CNN-Dilatada, consiguiendo como resultado una precisión de identificación promedio de 96.11% y de un 90.67% con la adquisición de imágenes sin procesar con la identificación de tres enfermedades diferentes en la hoja del pepino. En el mismo sentido, (Pang et al., 2021) presentan un algoritmo basado en el procesamiento de imágenes y el concepto de red Neuronal Artificial (ANN) para la detección y seguimiento de las enfermedades del tomate durante todo el proceso de producción (plantación-cosecha), a partir de la adquisición de imágenes de infección para el entrenamiento de la red ANN, donde son clasificadas por color, textura y morfología, logrando un 93% de precisión de detección de enfermedades con la clasificación morfológica. Así mismo (Latif et al., 2022) validan una sistema basado en una red de sensores de humedad relativa, luz y temperatura, junto a una red ANN para la predicción temprana del barrenador amarillo en el tallo del cultivo de arroz, que a partir del análisis de los parámetros medidos del cultivo es capaz de generar alertas al usuario; de esta manera el sistema logra demostrar una precisión de detección del 85.6%.

De manera similar, (Sweetwilliams et al., 2019) presentan un sistema basado en aprendizaje automático (ML) para la detección de la enfermedad Sigatoka en la hoja del plátano, a partir del procesamiento de los parámetros ambientales e imágenes tomadas de la hoja del

plátano, los cuales son soportados por una red WSN controlada por una tarjeta Raspberry Pi 3 que recopilan y transmiten inalámbricamente los datos sensados hacia ThingSpeak una plataforma IoT en la nube, desde aquí un algoritmo basado en algoritmos de extracción de características y textura como el descriptor de color escalable (SCD) e Histograma de gradiente orientado (HOG) procesa las imágenes para detectar la presencia de la enfermedad a partir de la clasificación realizada por una red ANN de perceptrón multicapa (MLP-ANN); de esta manera el sistema alcanzó la mejor precisión del 98% con el descriptor HOG.

De esta manera, (Mellit et al., 2021) propone un sistema de monitoreo inteligente para un invernadero basado en IoT y una red DCNN de aprendizaje profundo multiclase, soportada en una tarjeta de desarrollo Raspberry Pi, para la identificación y clasificación de enfermedades en la hoja del tomate, a partir de un algoritmo de procesamiento de imágenes en red CNN de extracción de características por capas de agrupación y convolución máxima para la identificación de amenazas, así como una transformación no lineal de las características extraídas con la matriz de aplanado y las capas completamente conectadas para la clasificación de enfermedades; consiguiendo una precisión del 88% en la clasificación de enfermedades del tomate, sugiriendo una mejora con la implementación de una base de datos más robusta con imágenes de alta calidad.

A su vez, (Kale & Sonavane, 2019) implementan un sistema de soporte para agricultura inteligente compuesto por un Algoritmo Genético mejorado (IGA) basado en un algoritmo de selección de variables y características de clasificación multinivel optimizado para el clasificador ELM (IGA-ELM) que permite comparar en tiempo real, conjuntos de datos biomédicos de alta dimensión sobre las enfermedades en las plantas, para su detección y clasificación, logrando una

mejora en la precisión de la clasificación de enfermedades en las plantas del 9,52 % y el 5,71 % al conseguir reducir las características en un 58,50 % y un 72,73 %, respectivamente.

Por su parte, (W.-L. Chen et al., 2020) propone el uso de IA y dispositivos IoT para la adquisición de datos hiper espectrales sin imágenes (nonimage) donde, los sensores son entrenados y analizados por la IA, para detectar brote de enfermedades en el arroz en tiempo real con una precisión de predicción del 88,9%. Por su parte (Khattab et al., 2019) desarrollan un sistema experto compuesto por algoritmos de predicción con IA alimentado por la información recolectada de una red de sensores WSN basado en IoT instalado en el cultivo, que permite emular la capacidad de toma de decisiones humana, para identificar enfermedades en las plantas y así emitir alertas tempranas de brote al usuario, logrando una sostenibilidad en los cultivos, al reducir la aplicación de químicos.

Por otro lado, (Tan et al., 2015) presentan una propuesta de un asistente en tiempo real, basado en un método para el reconocimiento y diagnóstico de patologías mediante imágenes a través de una red neuronal de Deep Learning, el cual se experimentó con el reconocimiento de la esfera de la fruta como en este caso la manzana. Logrando una tasa de recuperación del 98.4%, mejorando así sustancialmente el rendimiento de la red y por tanto optimizando el desempeño del asistente propuesto. De la misma manera, (Chatterjee et al., 2019) propone un sistema de asistencia y detección inteligente en tiempo real, denominada Green Sense, que se basa en una red CNN para la detección de enfermedades en las plantas a partir de la clasificación de imágenes de las hojas de las plantas.

(Kundu et al., 2021) propone el desarrollo de un Framework basado en Deep Learning para la Recolección y Clasificación de datos Automático e Inteligente a partir de dispositivos IoT y Cámaras para la captura de imágenes y datos paramétricos de las tierras del cultivo de millo,

recolectados por una CPU Raspberry Pi y enviados a un servidor Cloud, donde los datos son procesados y analizados por el método Grad-CAM que en CNN se encarga de la visualización de las características imagen que luego son extraídas por la función Custom-Net, logrando mejorar con el aprendizaje de transferencia, la extracción de características, con una precisión de clasificación de las enfermedades en el millo de un 98.78%, además con su eficiencia logra reducir el tiempo de entrenamiento en un 86.67%. De la misma manera (Zinonos et al., 2022) proponen un sistema que combina tecnologías LoRa WAN con técnicas de Deep Learning para la transmisión de imágenes de baja resolución y la identificación de posibles enfermedades en las hojas de la uva con alta disponibilidad; de esta manera, utilizan el método Grad-CAM para la visualización de datos de salida de la red CNN pre-entrenada, que le permite distinguir con alta precisión la mancha presente en las hojas que le permite identificar entre diferentes enfermedades de la hoja de las uvas.

La tecnificación del campo ha permitido el desarrollo de nuevas tecnologías que facilitan el monitoreo e intervención de las grandes extensiones de cultivos a partir de dispositivos no tripulados como los drones, es así como (D. Gao et al., 2020) presentan un diseño de un Framework de monitoreo y detección en tiempo real de plagas y enfermedades en los cultivos agrícolas, basado en Deep Learning y adquisición de datos, a través de la captura de imágenes tomadas desde dispositivos UAV (Unmanned Aerial Vehicles) sobre volando el terreno cultivado, y manteniendo una correlación con las condiciones climáticas del ambiente a partir de la información obtenida de una red de dispositivos IoT alimentados por paneles de seguimiento solar; de esta manera el Framework diseñado ha logrado demostrar de manera experimenta para un cultivo de Trigo que tiende a ser más susceptible a enfermedades y plagas a bajas

temperaturas entre 14°C y 16°C y que a precipitaciones altas, se reduce la propagación de enfermedades específicas del Trigo.

De esta manera (Shukla et al., 2021) también establecen una solución basada en técnicas de aprendizaje automático y la adquisición de imágenes multiespectrales del cultivo utilizando dispositivos UAV, de esta manera, aplican técnicas de aprendizaje automático para la segmentación y clasificación de imágenes capaces de identificar con precisión las regiones de interés en las imágenes, que corresponden a las partes de las plantas afectadas por enfermedades. También, (Kumar et al., 2021) proponen un modelo basado en una red CNN entrenada para reconocer patrones específicos en las imágenes capturadas por drones UAV, estas imágenes se procesan utilizando técnicas de visión por computadora y se analizan utilizando un modelo de Deep Learning en la red neuronal; de esta manera obtienen una precisión promedio del 94% en la detección de enfermedades en las plantas con el método propuesto, permitiendo una detección temprana de las enfermedades en las plantas, que puede prevenir la propagación y reducir el daño causado a los cultivos. Igualmente, (Bajpai et al., 2019) presentan una solución para la detección de plagas y enfermedades en plantas utilizando una red CNN basada en un concepto de clasificación de imágenes de hojas; este sistema es soportado en una placa de desarrollo de código abierto Raspberry Pi instalada en un dron UAV automatizado compuesto de conectividad IoT para la transferencia de imágenes a una base de datos local en un servidor global.

Así mismo, (Kakamoukas et al., 2019) definen una arquitectura denominada MARS (sMart fArming with dRoneS) compuesta por una red de sensores WSN, nodos con estaciones meteorológicas y vehículos aéreos no tripulados (UAV) para el monitoreo y soporte en la toma de decisiones con enfoque en la productividad, administración de recursos y protección ante amenazas en el cultivo, a partir del procesamiento de información con aprendizaje automático,

soportado en LoRaWAN, para el análisis de la adquisición de datos meteorológicos e imágenes del cultivo, que permitirán una respuesta rápida ante la aparición de amenazas, al tiempo que reduce la intervención de fertilizantes o pesticidas (costos de producción), mejorando la calidad de la producción en los cultivos.

Para la adquisición de datos del comportamiento de los cultivos agrícolas, existen algunas herramientas y técnicas basadas en el Cloud Computing que permiten la identificación y monitoreo en tiempo real de enfermedades en las plantas, como lo demuestran (Kim et al., 2018) en el estudio de un sistema IoT-Hub basado en la nube para el monitoreo y predicción de enfermedades en los cultivos de fresa, a partir del registro, conexión y administración de dispositivos IoT en una plataforma Cloud denominada Farm as a Services (FaaS).

Por otro lado, (C.-J. Chen et al., 2020) propone una solución para la identificación de plagas en los cultivos agrícolas, a partir de la combinación de técnicas basadas en reconocimiento de imágenes, Deep Learning y la aplicación de sensores ambientales IoT para la identificación de plagas en los cultivos agrícolas; desarrollado bajo un algoritmo de visión de Inteligencia Artificial YOLOv3 para la detección de objetos en tiempo real y de esta manera analizar la información ambiental obtenida desde la red de sensores IoT a través de una red neuronal recurrente RCNN LSTM (Long Short-Term Memory) para la predicción de ocurrencia de plagas en el cultivo, logrando de esta manera una precisión del 90% en la identificación de plagas. Un año más tarde, (C.-J. Chen et al., 2021) actualizarían su propuesta, con la aplicación de Computación de Borde (Edge Computing) para la adquisición de datos masiva, así como la implementación de UAVs para tomar las capturas del cultivo, dotado de un sistema integrado NVIDIA Jetson TX2 con el modelo CNN YOLOv3, consiguiendo además de detectar la plaga,

localizar su posición en tiempo real a lo largo del cultivo; consiguiendo una reducción en la implementación de pesticidas mientras se controla la propagación de plagas en el cultivo.

Por su parte, (Patle et al., 2021) también construyen una solución basada en la construcción de un sensor de humedad de la hoja (LWS) y un sensor de humedad del suelo (SMS) habilitados para IoT para medir diversos parámetros relacionados con la salud de la planta, además utiliza una red neuronal LSTM para procesar los datos medidos y predecir la presencia de enfermedades o plagas, alcanzando una precisión promedio del 96%. De la misma manera, (C.-J. Chen et al., 2022) definen una solución basada en una red LSTM para identificar la correlación entre la amenaza de plagas y los factores ambientales sensados a través de dispositivos IoT, haciendo uso de algoritmos Machine Learning como KNN (K-Nearest-Neighbor), SVM y modelos de bosques aleatorios, alcanzando una precisión del 85% en la predicción de plagas. Así mismo (Nancy et al., 2022) elaboran un Framework basado en aprendizaje automático para la identificación y clasificación de enfermedades en las plantas, utilizando algoritmos de Clasificación en Machine Learning como KNN, SVM y CNN, con un preprocesamiento a partir de la ecualización de histogramas y enfoque de PCA para extraer características relevantes de los datos de entrada.

En el caso de (X. Wang et al., 2021) también proponen una solución basada en YOLOv3 para la detección temprana de plagas y enfermedades en el cultivo del tomate, el cual consiste en unas capas de convulsión dilatada que logra mantener una alta resolución y campo receptivo, para optimizar la capacidad de detección de objetos pequeños, además utiliza la métrica IOU (Intersection Over Union) para evaluar la precisión en la detección de objetos, consiguiendo una precisión de detección en un valor-F de 94.77% y 91.81% de precisión promedio AP, para un valor de detección falso de 2.1%. De la misma manera, (X. Wang & Liu, 2021) trabajan un

modelo multi escala MP-YOLOv3, que consiste en un algoritmo basado en el modelo de red liviana MobileNeyv2-YOLOv3 para optimizar la precisión de detección en múltiples capas de la enfermedad del moho gris en el cultivo de tomate en un entorno natural real, con lo que logran obtener un valor F1 del 95,6% y una precisión promedio de detección del 93,4 %.

En contraste, (Geetha Lekshmy et al., 2022) exploran un sistema auto adaptativo integral para agricultura de precisión, en el que incluyen una función para la detección de plagas principalmente presencia de aves que atacan los cultivos, basado en un modelo de red CNN para la detección de objetos YOLOv4, a partir de la captura de imágenes por cámaras IoT en el campo. También (Walia et al., 2021) propone una solución para la detección, predicción y clasificación de enfermedades en las hojas de las plantas, a partir de la detección de objetos en tiempo real con el modelo YOLOv4. Mientras (Verma et al., 2021) presenta una solución para la detección de plagas en el cultivo de soya, implementando tres algoritmos de visión artificial de detección de objetos en el campo del cultivo, como YOLOv3, v4 y v5, demostrando una mejor precisión de detección promedio del 99.5% con YOLOv5. De manera similar (Sindhu & Indirani, 2022) proponen un modelo optimizado con una arquitectura de visión artificial SqueezeNet basado en redes DCNN con el objetivo de reconocer y clasificar enfermedades en la hoja de la uva, logrando una precisión promedio del 98.6% con exactitud del 99.29% en la identificación de diferentes enfermedades.

Por su parte, (R. Gao et al., 2020) presentan un modelo de aprendizaje automático para la detección y diagnóstico de enfermedades del pepino cultivado en invernadero, basado en un conjunto de parámetros de múltiples estructuras, que incluye redes neuronales convolucionales (CNN), redes neuronales recurrentes (RCNN) y árboles de decisión (DT), con lo que obtuvieron una tasa de reconocimiento de muestras de 79,4% a 93,6%. De la misma manera (Pothuganti

et al., 2021) propone un sistema integral de monitoreo de cultivos de invernadero con IoT, con enfoque en la predicción de enfermedades en la hoja del tomate basado en redes RCCN y MobileNet, soportado en bibliotecas de aprendizaje automático como Keras y Tensorflow; es así como alcanza una precisión de detección mayor al 80% sobre vídeos en tiempo real. Al igual que (Manick & Srivastava, 2022) presentan el desarrollo de un nuevo modelo de arquitectura CNN para la detección de enfermedades en las hojas de Yuca, ambientado en Keras con TensorFlow, alcanzando una precisión de rendimiento en clasificación promedio superior al 95% para un conjunto de datos aumentado.

Mientras, (Mishra et al., 2021) definen un modelo automatizado en la detección de enfermedades por reconocimiento y clasificación de características en imágenes, mediante el desarrollo de un clasificador denominado RideNN (Red Neuronal Ciclista) basado en el algoritmo Seno Coseno (SCA) para la detección de enfermedades en las hojas de las plantas con el objetivo que los pesos en la red neuronal se elijan de forma optimizada; obteniendo como resultado una mejora en el rendimiento de detección con una precisión del 96,5%.

También (Chandana et al., 2020) diseñan un sistema experto con procesamiento de imágenes, para la identificación de plagas y enfermedades en el cultivo de maíz, a partir de detección de objetos más rápida con Red Neuronal Convolutiva Regional (Faster R-CNN) que permite la extracción de características de la región de interés en la imagen utilizando ConvNet y de esta manera clasificarlas en diferentes clases con marcos delimitadores a través del método RPN (Region Proposal Network), presentando una eficiencia en términos de rendimiento de operación en la fracción de los 0.2 segundos. Mientras, (Song et al., 2020) proponen un modelo basado en Computer Vision y Deep Learning para la segmentación semántica de imágenes de alta resolución, conocida como pirámide espacial multi nivel extremadamente eficiente (EESP)

con el fin de extraer las características semánticas de alto nivel en las imágenes tomadas de las hojas de las plantas que permita detectar las enfermedades y plagas presentes en ellas; de esta manera, se definen cavidades diferentes en cada capa de la pirámide para la extracción de información en varias escalas, luego al integrar la información de cada capa de entrenamiento, lograron una precisión de detección del 88.4%, superando en 3 puntos porcentuales los métodos tradicionales.

A su vez, (Angin et al., 2020) construyen un framework de gemelos digitales denominado AgriLora, que consiste en una red de sensores WSN aplicada a las tierras de cultivo y servidores en la nube que despliegan algoritmos de visión por computadora para la detección de enfermedades en las plantas, maleza y deficiencia de nutrientes de las plantas; desarrollado a partir de los modelos de Deep Learning en Redes Neuronales, MobileNet y UNet para la ejecución de tareas de detección y clasificación de objetos de en Computer Vision, orientado a la segmentación de imágenes, con lo que han logrado un resultado exitoso en rendimiento y precisión de detección. De la misma manera (Kaissari et al., 2021) presentan una solución denominada Plantech, basada en una Red Híbrida de Sensores Inalámbricos (HWSN) y Deep Learning para la detección temprana de enfermedades en las plantas, que soportada en una red CNN, se encarga de procesar las imágenes de las hojas de las plantas y detectar signos de enfermedades consiguiendo una tasa de precisión del 98,09% en la detección de cinco enfermedades diferentes en las hojas de la planta.

Asimismo, (Chouhan et al., 2021) presentan un modelo de detección y clasificación de enfermedades a partir de las hojas de plantas, utilizando una red de funciones basada en una red de lógica difusa (FBFN) con entrenamiento de la red optimizada soportada en el algoritmo Firefly, de esta manera logran demostrar una precisión media de detección del 96,17% y una

precisión media de clasificación del 94,67%. De la misma manera, (Sharma et al., 2022) proponen un mecanismo de predicción de plagas de cultivos de arroz y millo, basado en lógica difusa FBFN soportado en la correlación entre la reproducción de plagas con los parámetros ambientales sensados en el cultivo como la temperatura, la humedad y las precipitaciones.

Por su parte (Roihan et al., 2020) diseñan un dispositivo repelente inteligente de aves destructoras de los campos de arroz, basado en técnicas de Computer Vision alimentado por los datos adquiridos de una red de sensores de cámaras para detectar el objeto (aves) en la imagen, la cual es procesada en un microcontrolador que luego da orden a un actuador de activar una frecuencia de sonido capaz de alejar las plagas de aves presentes en el cultivo. En la misma línea, (Roy et al., 2021) presentan un sistema de detección y disuasión de presencia de aves-plaga en los cultivos basado en Computer Vision a través de la captura de imágenes por dispositivos UAV, las cuales al ser detectadas (las aves), las repele automáticamente mediante el uso de señales acústicas y visuales. También (Balaji et al., 2021) presenta una solución para la detección de enfermedades en las plantas basado en técnicas de Computer Vision en procesamiento de imágenes con OpenCV controlado desde una tarjeta de desarrollo Raspberry Pi. Igualmente (Kolli et al., 2021) proponen el desarrollo de un modelo de Machine Learning basado en una red CNN pre entrenada con soporte OpenCV para detección de enfermedades en los cultivos a partir del uso de cámaras dispuestas en cualquier dispositivo (IoT, teléfonos, drones o cámaras) del usuario, alcanzando una precisión de detección del 94.87%.

Además, (Ponnusamy et al., 2021) presenta una solución basada en el desarrollo de un Framework de Realidad Aumentada (AR) para la visualización en tiempo real de los resultados de detección de enfermedades en las hojas de las plantas, utilizando técnicas de aprendizaje

automático e IoT para la adquisición y análisis de datos en la nube que permiten la interacción en tiempo real del agricultor con el estado del cultivo.

Por su parte, (Nagasubramanian et al., 2021) construyen una solución soportada en técnicas de aprendizaje automático (ML: Machine Learning) para el monitoreo de crecimiento y brote de enfermedades en las hojas de las plantas en tiempo real, mediante un análisis estadístico del comportamiento y patrones de amenaza en el cultivo, a partir de un algoritmo basado en una red CNN de procesamiento de imágenes con SVM para la predicción de las enfermedades, compuesto por un clasificador lineal probabilístico Naïve Bayes (NBC) para soportar la predicción desde el cálculo de la probabilidad posterior de cada clase, así como un algoritmo de clasificación supervisada K-nearest neighbors (KNN) que se enfoca en la búsqueda de puntos K más cercanos de consulta en la imagen para definir una clasificación etiquetada, logrando de esta manera optimizar los procesos de clasificación y predicción de manera significativa. De la misma manera (Nadeem et al., 2021) implementan un sistema de predicción de la plaga Barrenador de tallo en el cultivo de caña de azúcar, a partir de la medición de parámetros ambientales y la decisión basada en datos de enfoque con el modelo Naïve Bays de Machine Learning.

A su vez, (Ahmad et al., 2021) construye una solución soportado en una red CNN para clasificar automáticamente los síntomas de enfermedades de las hojas del cultivo de pimentón, a partir del entrenamiento de maquina con pequeños conjuntos de datos basado en Aprendizaje de Transferencia (TL: Transference Learning) que transfiere pesos pre-entrenados aprendidos en un gran conjunto de datos, y para evitar el aprendizaje negativo utiliza un TL paso a paso (Stepwise Transfer Learning) que además, reduce el sobreajuste y ayuda en la convergencia rápida; consiguiendo una precisión de clasificación de un 99% para el conjunto de datos capturado del

cultivo de Pimentón. Así mismo, (Esmail Karar et al., 2022) proponen un sistema basado en una combinación de redes neuronales CNN de profundidad mixta (MixConvNet) con una técnica de Transferencia de Aprendizaje (TL) entrenado con técnicas de segmentación de imágenes basada en la combinación de umbrales de color y segmentación de superpíxeles, para detectar las larvas de la polilla roja de la palma (RPW) en las palmeras de dátiles, alcanzando una precisión de detección promedio del 96.2%.

Por su parte, (Ram et al., 2020) presentan un modelo que combina el procesamiento de imágenes en una etapa de preprocesamiento y extracción de características que soportan el modelado del sistema a través del uso de redes neuronales NN para predecir patrones de comportamiento en los cultivos mediante técnicas de entrenamiento K-Fold. Por último, una etapa de acciones requeridas que va desde la notificación al agricultor, hasta el diagnóstico y recomendación de tratamiento de la enfermedad. De la misma manera (C.-C. Chen et al., 2021) construyen un Framework soportado en la arquitectura de red CNN EfficientNet que se basa en la escalabilidad compuesta (compound scaling) capaz de ajustar de forma simultánea las dimensiones de la red, la cual utiliza técnicas de mejora de datos como el aumento del tiempo de prueba (TTA) y Cutmix, así como técnicas de clasificación de imágenes como Cutout y K-Fold para evaluar con precisión la presencia de enfermedades en las hojas de Yuca; esta solución además utiliza cámaras y dispositivos IoT para la adquisición de datos. Así mismo, (Ghofrani et al., 2021) proponen un sistema de reconocimiento de enfermedades en las plantas basado en Deep Learning, utilizando una red CNN EfficientNet pre-entrenada y optimizada para alcanzar una precisión promedio del 99.77%. También (Maryum et al., 2021) implementa una solución basada en la Aprendizaje de Transferencia con la arquitectura EfficientNet Modelo B4 utilizando Segmentación U-Net para la extracción de características de las hojas de las plantas y lograr

detectar enfermedades en las plantas de yuca, logrando de esta manera, una precisión de detección del 89.09%.

Por su parte, (Lee et al., 2021) implementan una plataforma de inspección óptica para la detección de plagas y enfermedades en las hojas de orquídeas, basada en un algoritmo modelado por métodos de aprendizaje automático como XGBoost (Extreme Gradient Boosting: refuerzo de gradientes extremo) utilizado como método de clasificación y regresión; también implementa el método K-Fold CV (Cross Validation) para evaluar y analizar los resultados obtenidos para identificar datos de entrenamiento y prueba en la detección de enfermedades en las hojas de orquídeas, con lo que lograron demostrar una precisión de detección del 89%. De manera similar (Rajeshwari et al., 2021) trabajan en una solución integral para la gestión de cultivos que incluye una función para la detección de enfermedades en las hojas de las plantas basado Machine Learning con una técnica de Regresión Logística de analítica de datos optimizado para mejorar la precisión de detección con procesamiento de imágenes. Igualmente (Salim et al., 2021) presentan un sistema integral de prevención ante el ataque del insecto langosta, basado en un algoritmo de Machine Learning con diferentes técnicas de analítica como SVR (Support Vector Regression), Regresión Lineal y Regresión logística para la optimización de los datos medidos por los sensores ambientales dispuestos en el cultivo, para la detección y mitigación del insecto utilizando como pesticida dispositivos de luz ultravioleta y ruido. También (Liu et al., 2022) presentan una solución basada en un modelo de ML como Regresión Lineal Multiple (MLR) para el análisis y predicción de la enfermedad por tizón de ampolla en las plantas de té utilizando los datos ambientales recolectados como la humedad y temperatura del cultivo a partir de dispositivos IoT, demostrando una mejora gradual desde el 2015 hasta el 2019, alcanzando un 91% de precisión en la predicción de la enfermedad.

Además, se encontró un modelo de Deep Learning para el diagnóstico de enfermedades y plagas en cultivos agrícolas a partir de la aplicación de Redes de Creencia Profunda DBN (Deep Belief Networks) el cual consiste en un modelo de superposición compuesto por diferentes Máquinas Boltzmann restringidas RBM (Restricted Boltzmann machines). Así es, como (X. Wang et al., 2018) establecen un modelo basado en un DBN Adaptativo Discriminatorio (ADDDBN) para mejorar el tiempo de predicción que junto a la medición de las condiciones ambientales, presentan un modelo para el pronóstico de enfermedades y plagas en un cultivo de Algodón; demostrando una mejora significativa en el rendimiento de predicción del 19,248%, 24,916% y 27,774% que los modelos tradicionales BPNN, SFSVM y RBFNN respectivamente. De la misma manera, (Saleem et al., 2021) diseñan un sistema basado en un algoritmo RBFN de Deep Learning que se apoya en diferentes parámetros ambientales como la temperatura, la humedad, la lluvia y la velocidad del viento para predecir la infección por la mosca blanca en el cultivo de Algodón; logrando una precisión de predicción promedio del 73.5% en puntos de mayor afectación del área experimental, mientras que con la red CNN entrenada se observó con una precisión del 82.88%

De la misma manera, (S. Zhang et al., 2017) presenta un modelo basado en una red DBN modificada para la predicción oportuna de enfermedades y plagas de insectos del azufaifo de invierno; capaz de simular una estructura de red neuronal con información supervisada para restringir la similitud entre los vectores característicos en el proceso de aprendizaje, además es capaz de aprender automáticamente información ambiental tomada del comportamiento del azufaifo de invierno, lo que permite la clasificación e importación de datos de alto nivel con el clasificador de red neuronal de propagación inversa BP (Back Propagation) para mejorar la precisión en la predicción de enfermedades minimizando los errores en el proceso de aprendizaje

automático, logrando de esta manera una tasa de precisión pronóstico por encima del 84%. Así mismo, (Vimala et al., 2021) presentan una solución basada en un modelo DBN soportada en una Red Neuronal Regresiva, desarrollada bajo un algoritmo de optimización Sunflower EarthWorm (S-EWA) para predecir el grado de la enfermedad en el cultivo de arroz; logrando un mejor rendimiento de detección en términos de precisión de 95,2% sensibilidad de 95,51% y especificidad de 94,89% al variar el porcentaje de entrenamiento, y precisión de 95,7%, sensibilidad de 95,86% y especificidad de 95,54% al variar las capas ocultas.

También, (Nalini et al., 2021) construyen un nuevo modelo de clasificación para la identificación de enfermedades en las hojas del arroz, basado en una arquitectura de red neuronal profunda DNN (Deep Neural Network), utilizando datos extraídos de las imágenes de plantas preprocesadas con el método de clusterización K-Means; minimizando los errores de clasificación desde el preentrenamiento y ajuste, con la optimización de pesos y sesgos en el modelo DNN, a partir de del algoritmo de búsqueda de cuervos CSA (Crow Search Algorithm); logrando de esta manera demostrar una eficiencia y precisión de clasificación de enfermedades en las hojas de la planta, superior a una SVM con múltiples validaciones cruzadas. De la misma manera, (Mewada & Patoliaya, 2021) proponen el desarrollo de un algoritmo de aprendizaje automático basado en técnicas de SVM, para la detección y clasificación de cinco tipos de enfermedades en las hojas de las plantas a partir de la adquisición y análisis de imágenes tomadas del cultivo, logrando una precisión de detección del 97% para la recopilación de imágenes adquiridas. En este mismo sentido, (Suresh & Seetharaman, 2023) construyen una técnica basada en modelos de aprendizaje automático a partir de la segmentación de área afectada desde las capturas obtenidas de la hoja de maní para la detección de enfermedades,

soportado en algoritmos de optimización y una red DNN para la clasificación de especies de enfermedad, que logra demostrar una precisión promedio del 97% con sensibilidad del 1%.

Por su parte, (Manrique-Silupu et al., 2021) presentan una solución basada en técnicas de Machine Learning en SVM para predecir la incidencia de trips en las plantaciones de plátano, haciendo uso de variables atmosféricas como la temperatura, la humedad y la presencia de otras plagas y enfermedades, a partir de la instalación de una red WSN en el cultivo como datos de entrada, con lo que han logrado un alto nivel de precisión. De manera similar (Madhav et al., 2021) establecen una solución basada en SVM, en este caso para clasificar las plantas en función de si presenta alguna anomalía, y qué tipo de plaga o enfermedad tienen, a partir del procesamiento de datos recopilados del cultivo mediante dispositivos IoT como sensores y cámaras de detección. También, (Vijayalakshmi et al., 2021) basados en técnicas de ML y procesamiento de imágenes validan el modelo SVM para la predicción temprana de enfermedades en las plantas a partir de la clasificación y extracción de características de imágenes obtenidas del cultivo, logrando una precisión de clasificación promedio del 92%. Mientras (Murugamani et al., 2022) también presentan una solución de monitoreo integral de cultivos, con un enfoque en la detección y control de plagas y enfermedades en las hojas del cultivo de algodón; el sistema es soportado en el modelo SVM, demostrando su eficiencia con una precisión del 98.34% para el diagnóstico de enfermedades causadas por el tizón bacteriano del algodón.

Así mismo, (Fatima et al., 2021) aportan un sistema integral de automatización de invernadero, en el que se incluye el monitoreo y predicción de enfermedades en las hojas de las plantas aplicando un modelo más eficiente de Deep Learning haciendo uso además de variables atmosféricas tomadas del cultivo. A su vez (Paulchamy et al., 2021) proponen un sistema

automatizado de monitoreo, basado en una red WSN controlada por un microcontrolador PIC16F877A y una placa de desarrollo NodeMCU (ESP82666), que incluye una función de detección de enfermedades en las hojas de las plantas a partir de técnicas de Machine Learning y el análisis de parámetros medidos del suelo.

Mientras tanto (Hossain et al., 2021) comparan tres modelos basados en la segmentación de imágenes, para el reconocimiento de enfermedades en las hojas de las plantas PLD (Plant Leaf Disease) soportados en una red CNN, utilizando inicialmente una segmentación basada en el centroide adaptable modificada (ACS) para trazar ruta a la Región de Interés adecuada (ROI) en la imagen, de lo que derivan tres modelos de reconocimiento PLD convolucionales separables en profundidad (DSCPLD), compuestos por una red CNN Mobilenet, el primero segmentado con S modificada (S-modified MobileNet), el segundo segmentado con S reducida (S-reduced MobileNet) y el tercero segmentado con S extendida (S-extended MobileNet), utilizados para representar el compromiso constructivo entre la precisión, el tamaño del modelo y la latencia computacional. Luego, en simulación de los modelos DSCPLD utilizando imágenes de las hojas de las plantas, tanto complejas como segmentadas, consiguen mejorar la precisión y puntaje F1 con todos los modelos DSCPLD propuestos al utilizar ACS modificado, donde el modelo S-modified, logra la mejor precisión alcanzando un 99.55% y un valor F1-score del 97,07 %.

Así mismo (G. Garg et al., 2021) proponen el desarrollo de una aplicación móvil denominada Cropcare, basada en una arquitectura de aprendizaje profundo (deep learning) para la detección y prevención de enfermedades en los cultivos en tiempo real, que utiliza una red CNN de superresolución (SRCNN) compuesta por un modelo pre entrenado MobileNet-V2 para generar un modelo de decisión entrenado sobre diversas enfermedades; además la aplicación se integra con una red de sensores IoT y servicios de Google cloud para la adquisición y analítica

de datos tomados del cultivo. De manera similar, (Rishiikeshwer et al., 2020) establecen una solución IoT para la detección temprana de enfermedades en las hojas de las plantas mediante el desarrollo de una aplicación web móvil basada en un modelo de redes CNN utilizando una combinación de conjuntos de datos reales y sintéticos aumentados para mejorar la precisión de la detección.; este método les permitió alcanzar una precisión de detección promedio del 95% con 400 imágenes de hojas reales y hasta un 98% con 3600 conjuntos de datos aumentados. De manera similar (Musa et al., 2021) presentan un sistema de detección de enfermedades en las plantas para cultivos hidropónicos basado en una red DCNN pre-entrenada y probada en una maquina en la nube como Google Cloud Platform (GCP) con Plant Village como base de datos de entrenamiento; con lo que el modelo alcanza una precisión de detección del 98%.

Por su parte, (Kailasam et al., 2022) trabajan en un sistema de mantenimiento de cultivo basado en técnicas de aprendizaje automático de bosques aleatorio, así como la utilización de técnicas de segmentación de umbrales para la detección temprana de enfermedades y plagas en el cultivo. Igualmente (Xenakis et al., 2020) presentan in sistema robotizado para el diagnóstico y clasificación en tiempo real de enfermedades en cultivos de invernadero, basado en una red CNN de tres capas, para identificar entre plantas saludables e infectadas, proporcionando además sugerencias de tratamiento de ser necesario; de esta manera el sistema logra un precisión de clasificación promedio del 96.73% para todos los estados de enfermedad.

Por otra parte, (Musa et al., 2022) proponen un modelo Deep Learning de baja potencia para la detección de enfermedades en las plantas basado en técnicas de Destilación de Conocimiento (Knowledge Distillation), el cual consiste en una red CNN poco profunda con parámetros reducidos en un 90%, demostrando su eficiencia con una precisión del 99,4% de detección.

Similar a documentos anteriores (de Vita et al., 2020) presentan un sistema inteligente denominada Deep-Leaf para la detección de enfermedades en las hojas del cultivo de café, basado en un modelo de Red Convolutiva Neuronal Cuantizada (Q-CNN), capaz de realizar análisis cuantitativos sobre diferentes modelos de Deep Learning, logrando alcanzar un precisión promedio del 96% en la condición de salud de la planta. Por su parte (Karnati et al., 2022) utilizan la Computación Profunda para presentar un modelo que permite la detección de dióxido de azufre en el suelo del cultivo para determinar el estado de salud en las plantas, utilizando en una red CNN Depp Q-Network basado en un algoritmo IWC (Ciclo del Agua Invasivo) propuesto por los autores, el cual demostró una precisión del 94.1% de estimación del componente presente en el suelo.

Redes de Sensores Inalámbricos

Por otra parte, se han encontrado diferentes sistemas, redes de sensores (Wireless Sensor Network) y dispositivos basados en IoT, que a partir de la medición en tiempo real de las condiciones del ambiente en el área de estudio, permiten la prevención de enfermedades en los cultivos, como lo proponen VineSens (Pérez et al., 2017) en la aplicación de un sistema WSN para la automatización en detección de enfermedades en un viñedo, compuesto por nodos de sensores autónomos, que se interconectan entre si a lo largo del cultivo, con el fin de obtener información detallada de las condiciones y procesos de la viticultura, almacenando información meteorológica que consigue advertir al viticultor de las medidas que debe tomar según el estado de alerta. Un año más tarde, (Pérez et al., 2018) presentan una actualización a su propuesta anterior basada WSN, esta vez con Sensado Comprimido (CS), compuesto por una red de sensores de aprendizaje exhaustivo de procesos Vitivinícolas (sector que agrupa los sectores de agricultura de vides y producción de vino), que soporta es capaz de almacenar una mayor

variedad de modelos epidemiológicos con el propósito de detectar y prevenir diferentes enfermedades en el área del cultivo.

En esa misma línea una red de nodos de sensores IoT denominado SEnviro (nodo), dotado de conectividad 3G, actualizaciones remotas OTA (Over-the-Air), autonomía y alimentación por energía solar; aplicado a los cultivos Vinícolas, es propuesto (Trilles et al., 2018) con el objetivo de monitorear de las condiciones meteorológicas en el cultivo, que permiten detectar posibles enfermedades en los viñedos. Más adelante, (Trilles et al., 2019) presenta una adaptación de los modelos de alerta de temprana de enfermedades en tiempo real a partir de variables meteorológicas tomadas desde dispositivos IoT, y dos años más tarde, (Trilles et al., 2020) presentan una nueva versión con una plataforma sensorizada IoT para el monitoreo de las condiciones meteorológicas del viñedo, con el objetivo de brindar alertas tempranas en tiempo real sobre la aparición de enfermedades en los viñedos a partir de un modelo de Computación de Borde, siguiendo diferentes paradigmas de GIScience (Geographic Information Science). De manera similar (Harun et al., 2021) proponen una solución basada en Computación de Borde controlada por una tarjeta Raspberry Pi donde se procesan y analizan los datos obtenidos a partir del procesamiento de imágenes y extracción de características de las hojas de las plantas para identificar de manera automática infección entre tres tipos de enfermedades de la hoja de arroz, alcanzando una precisión de clasificación del 97.5%.

En su caso (Bischoff & Farias, 2020) describe un enfoque para la predicción y detección de enfermedades en viñedos denominado VitForecast, que implementa una aplicación móvil en conjunto con una red de sensores para la medición de parámetros ambientales y la presencia de ciertos gases que pueden indicar la presencia de enfermedades, los cuales son controlados desde una tarjeta de desarrollo Raspberry Pi soportada en técnicas y algoritmos de aprendizaje

automático para detectar enfermedades en el cultivo a partir del análisis de los datos obtenidos de los sensores IoT. De manera similar, (Salehin et al., 2021) realizan la implementación de un sistema inteligente de detección de plagas en cultivos agrícolas, basado en una red WSN, compuesta principalmente por sensores de imágenes de alta calidad que detecta los rayos naturales emitidos por la planta, sensores de gas capaces de detectar los gases provenientes de la enfermedad en la planta, así como sensores de sonido para una optimización del sistema; dichos sensores recolectan información en tiempo real del cultivo para compararlos en una base de datos central, que permite emitir una alerta SMS de análisis de detección al usuario a través de un módulo GSM soportado en una tarjeta Arduino UNO R3. A su vez (Nawaz et al., 2020) propone un Framework para la detección de enfermedades en las hojas de las plantas a partir del análisis de parámetros sensados por dispositivos en una WSN, como la temperatura, viscosidad y tono de la hoja, que son alojados en la nube a través de un módulo WiFi (Wireless Fidelity), soportado en una tarjeta de control Arduino UNO. Así mismo (Sanghavi et al., 2021) presenta una solución soportada en una red WSN controlada por un dispositivo IoT NodeMCU (ESP8266) para la detección temprana de enfermedades de la uva a partir del análisis basado en condiciones ambientales obtenido desde la red de sensores como el pluviómetro y sensores de temperatura, permite notificar al usuario de la vulnerabilidad del cultivo; de esta manera el sistema alcanza una precisión de detección general del 94.4% para el moho Downey y el 96% para el moho Powdery.

También, (Varandas et al., 2020) trabajan en una solución basada en un prototipo IoT soportado en LoRaWAN, de bajo costo para el monitoreo de condiciones ambientales en tiempo real para mitigar los efectos adversos ocasionados por la aplicación de pesticidas. Este sistema es capaz de monitorear la temperatura interna y externa de las plantas, así como la humedad del

suelo y el ambiente, para lograr predecir posibles apariciones de enfermedades y plagas. De la misma manera (Blessy Annie Flora et al., 2021) propone una red WSN basada en LoRaWAN, de bajo costo, para la detección de enfermedades en la planta de banano, a partir del monitoreo y análisis de parámetros ambientales a través de una plataforma IoT en la nube y un panel de Ubidots, para notificar al usuario de la presencia de amenazas en el cultivo. Así mismo (Abu et al., 2022) presentan una Plataforma IoT de gestión remota de cultivos, basada en redes WSN soportada en sistemas y dispositivos de comunicación con tecnología LoRaWAN (Gateway) para la medición de diferentes parámetros ambientales y del suelo, integrados con una tarjeta de desarrollo Raspberry Pi, en función de la detección de plagas en el cultivo.

Por otra parte, (Koubaa et al., 2020) proponen el desarrollo de un prototipo para el monitoreo inteligente remoto de un cultivo de Palmeras, compuesto por una red de sensores inteligentes que a partir de un análisis estadístico de los datos medidos permite la detección temprana de la infestación de piojo en la palma, información que es entregada al usuario a través de una plataforma IoT. Así mismo (Hsiao & Sung, 2021) construyen una solución basada en una red WSN para la medición de parámetros ambientales del cultivo que permite detectar anomalías que puedan indicar la presencia de plagas o enfermedades, utilizando técnicas de análisis en series de tiempo y estadística como la desviación estándar y la media móvil. De igual manera, (Shaikh et al., 2018) implementan un sistema de monitoreo y análisis de la enfermedad del moho gris en el cultivo de Chili en tiempo real a través de una red WSN, para conocer los parámetros y condiciones ambientales como la temperatura y humedad como los factores más relevantes para obtener un análisis del comportamiento de la enfermedad, ante cualquier brote o cambio crítico en el cultivo. También (Shi et al., 2019), aportan a través de un Framework basado en una red WSN en el que han incluido el análisis de las condiciones ambientales para predicción de las

plagas y enfermedades en el cultivo a partir de su comportamiento, con lo que lograron identificar el crote del moho de polvo de trigo en condiciones de humedad relativa del 60% con temperaturas de 15°C.

Así mismo, (Francis et al., 2018) proponen la implementación de un sistema automatizado para cultivos aeropónicos compuesto por una red de sensores y actuadores de riego y niebla, que permiten mantener el cultivo libre de virus, regulando las condiciones del ambiente como la temperatura y humedad del suelo con la activación de ventiladores y niebla, procesos de crecimiento como la fotosíntesis con luz LED artificial para cultivos, así como la regulación del pH del suelo y mantenerlo en un valor ideal de 6.0; valores que se obtienen de forma periódica, almadrándolos de forma continua en la nube, para su monitoreo. De manera similar (Pan & Wang, 2021) presenta una solución integral para la detección y diagnóstico de enfermedades y tratamientos en los cultivos, basado en una red WSN que especialmente utiliza un sensor de color para identificar características anormales en las hojas de las plantas, luego estos datos son comparados con los parámetros ambientales también sensados del cultivo en una plataforma IoT con el protocolo NB-IoT, para detectar vulnerabilidades en el cultivo y sugerir ajustes o tratamientos al usuario para el cultivo a través de una aplicación web.

Otro sistema propuesto para la automatización de monitoreo remoto de insectos en los cultivos agrícolas (Potamitis et al., 2017) se basa en la implementación de tres tipos de trampas de plástico con feromonas para insectos, dotadas de sensores y tecnología optoelectrónica para la detección de entrada, con etiquetado de tiempo y GPS; con la posibilidad de identificar la especie de los insectos a partir de su aleteo; es así como a partir de este enfoque, logran alcanzar una precisión de detección entre el 98% y 99%, comparado con los resultados de detección de las trampas convencionales por separado. Mientras, (F. Yang et al., 2021) establece la incorporación

de lámparas solares insecticida (SIL) en una red WSN basado en el protocolo de comunicación ZigBee, siguiendo el método de implementación de nodos conscientes de agujeros HANDM (Hole-Aware Node Deployment Method) de dos etapas, basado en el algoritmo Voraz (Greedy) para resolver el problema de optimización restringida, que selecciona la mejor opción disponible en el momento; demostrando de esta manera un mejor rendimiento que los algoritmos por separado, además del bajo costo de implementación.

Así mismo, (Albanese et al., 2020) presentan una trampa para insectos, compuesta por un sistema electrónico controlado por placa de desarrollo Raspberry Pi3 para el procesamiento de imágenes, la cual soporta una red CNN Intel Movidius Neural Compute Stick (NCS) para la clasificación de imágenes de la planta, para la detección automática de polillas de la manzana desde una cámara situada en la trampa electrónica para insectos. De manera similar (Q. Zhao et al., 2021) proponen un sistema de monitoreo basado en el procesamiento de imágenes, el cual utiliza trampas de feromonas para atraer y capturar los insectos invasores, así como cámaras para la detección de presencia de plagas a partir de técnicas de aprendizaje automático de segmentación de color y análisis de forma en las imágenes obtenidas.

Por su parte (Patle et al., 2021) diseñan e implementan un sensor electrónico interno de humedad de la hoja (LWS: Leaf Wetness Sensor) habilitado para IoT compuesto por un sustrato flexible y un módulo de comunicación inalámbrica que permite el envío de datos a un servidor en la nube para su análisis, este sensor ha sido diseñado para la gestión integrado de las enfermedades en las plantas, a partir de una técnica capacitiva que mide la humedad de las hojas. De manera similar, (L. Wang et al., 2021) proponen un sistema integral de inspección de invernadero, basado en el desarrollo de un dispositivo electrónico tipo Robot, el cual incluye una función para la detección temprana de enfermedades en el cultivo, dotado de una sensores

ambientales y cámaras inteligentes, controlados desde una Raspberry Pi como Gateway para la adquisición y análisis de datos, así como el procesamiento de imágenes para el envío de alertas tempranas al usuario a través de una aplicación móvil. También (Menon & Prabhakar, 2021) utilizan un sistema de monitoreo inteligente Rover para la detección temprana de plagas en el cultivo, basado en la medición de parámetros ambientales en el entorno, a partir de sensores y cámaras IoT controlados por una placa de desarrollo Arduino Mega.

Tecnología de Asistencia Manual

Por otra parte, se encontraron algunas técnicas que además de basarse en la implementación de tecnologías de IoT, comprometen el factor humano o monitoreo asistido para el análisis, diagnóstico y tratamiento de enfermedades en los cultivos agrícolas, como lo propone (Sarangi et al., 2016) con la automatización de un sistema de soporte para el diagnóstico y asesoría en la aparición de enfermedades en las plantas, mediante el uso de una plataforma IoT denominada Wisekar que actúa como puente de comunicación con un sistema de asesoramiento agrícola (basado en un centro de llamadas) y el software de detección de enfermedades, desarrollado bajo el concepto de servicio automatizado de asesoramiento en enfermedades de los cultivos agrícolas ACAS (Automated Crop-disease Advisory Service) basado en RTBI (Real-time business intelligence) de latencia casi nula y el acceso a los datos bajo demanda. Mientras tanto, (De La Concepcion et al., 2014) implementa una plataforma para el monitoreo de una red de sensores inalámbricos WSN, pero asistida por expertos que brinda asesoría instantánea a los agricultores al detectar anomalías en el cultivo, lo que permitiría en su momento, una mejora significativa en la sostenibilidad del agro, al minimizar el uso de pesticidas y productos químicos, nocivos para el cultivo.

Por su parte, (Nocera et al., 2017) presenta una solución IoT que combina una red WSN con el desarrollo de una aplicación móvil para la gestión Integral del cultivo. El sistema diagnostica la enfermedad presente en el cultivo y su porcentaje de infección a partir de la medición de variables como la temperatura y humedad del aire, así como el pH y temperatura del suelo, adicionalmente presenta una serie de recomendaciones de tratamiento y alertas que permiten mitigar los efectos adversos de plagas y enfermedades. Cabe mencionar que el sistema proporciona información de consulta al usuario según la solicitud, pero este no automatiza los procesos de intervención en el cultivo. También (Coletta et al., 2022) desarrollan una plataforma de crowdsensing que utiliza la participación de los agricultores y la tecnología móvil para detectar y monitorear enfermedades en las plantas a partir de la captura de imágenes de las plantas afectadas a través de una aplicación móvil que las envía a un servidor central para su análisis utilizando técnicas de procesamiento de imágenes y aprendizaje automático para identificar las enfermedades y enviar recomendaciones de tratamiento a los agricultores.

Análisis de Resultados

A partir de la revisión bibliográfica realizada sobre las técnicas de prevención y detección de plagas y enfermedades en los cultivos agrícolas, basadas en tecnologías de Internet de las Cosas, se presenta un análisis exhaustivo de los resultados obtenidos, con el objetivo de identificar las mejores prácticas y avances más relevantes en este campo. Es así, como este análisis permitirá comprender el estado actual de conocimiento en el área y así poder destacar las oportunidades y soluciones disponibles para enfrentar desafíos fitosanitarios que se presentan.

Este capítulo tiene el propósito de sentar las bases para futuras investigaciones y desarrollos en el área de la agricultura de precisión y productividad sostenible de los cultivos agrícolas basado en tecnologías IoT, proporcionando una visión integral de los hallazgos tanto para los investigadores como para los agricultores y profesionales del sector agrícola. De esta manera, se presenta un análisis dividido en las siguientes secciones:

Tipos de Soluciones

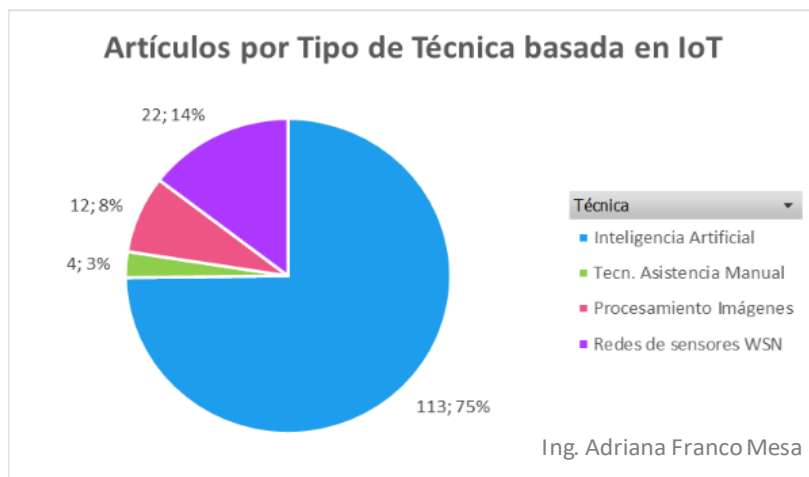
El análisis de resultados de los tipos de soluciones identificados en esta revisión proporciona una visión integral de las soluciones IoT organizadas en diferentes grupos representados gráficamente según las técnicas utilizadas, años de publicación y países de origen en un total de 151 artículos obtenidos.

Es así, cómo esta revisión presenta una distribución significativa de las técnicas basadas en IoT para la detección y prevención de enfermedades en los cultivos agrícolas, que se logran reflejar en cuatro grupos diferentes como se muestra gráficamente en la *Figura 6*, donde se observa una clara preferencia por las soluciones basadas en Inteligencia Artificial, representada en un 75% de las soluciones identificadas en la revisión para un total de 113 artículos, destacando su potencial para transformar la agricultura a través del desarrollo de algoritmos y

modelos inteligentes, tales como algoritmos de Aprendizaje Profundo, Aprendizaje de Maquina, Aprendizaje Automático, Redes Neuronales, Visión por Computadora, entre otros.

Figura 6

Distribución Publicación por Tipo de Técnica Basada en IoT



Nota. Gráfica de Elaboración propia con herramientas de Microsoft Excel

Por otra parte, se logra identificar que las Redes de Sensores WSN (Wireless Sensor Networks) también juegan un papel importante en esta investigación constituyendo un 14% de los artículos analizados; demostrando ser una herramienta valiosa para monitorear y recopilar variables ambientales, así como las condiciones en los cultivos en tiempo real, ofreciendo una detección temprana y precisa de posibles amenazas.

Las soluciones basadas en técnicas de Procesamiento de Imágenes digital conforman también un enfoque relevante en la investigación, la cual, permite el análisis de diferentes características importantes de imágenes y videos capturados en los cultivos, facilitando la identificación temprana de plagas y enfermedades, para una toma decisiones más eficiente y oportuna. De esta manera, este tipo de soluciones representa un 8% de las técnicas identificadas.


En cuanto a las Tecnologías de Asistencia Manual, se destaca su aplicación en la interacción tecnológica con el usuario o agricultor por medio de plataformas de GUI (Graphic

User Interface) para la toma de decisiones y gestión adecuada de los cultivos asistida por expertos en el área. Sin embargo, en esta revisión representan un menor porcentaje con sólo un 3% de las soluciones presentadas en los artículos analizados; demostrando finalmente una tendencia a la automatización de los procesos agrícolas para la identificación y prevención de plagas y enfermedades en los cultivos.

Por otra parte, se evalúa la distribución de las publicaciones analizadas por año de publicación, que como se muestra en la gráfica *Figura 7*, la adopción creciente de soluciones IoT en la agricultura muestra un enfoque cada vez más orientado hacia la eficiencia, la precisión y la sostenibilidad; marcando una notable tendencia de crecimiento exponencial en la aplicación de la Inteligencia Artificial en las soluciones encontradas con un aumento significativo a partir del año 2018, demostrando una clara preferencia como técnica principal para el desarrollo de soluciones en la prevención y detección de plagas y enfermedades en los cultivos agrícolas.

Figura 7

Tendencias Tipo de Técnicas por Año de Publicación



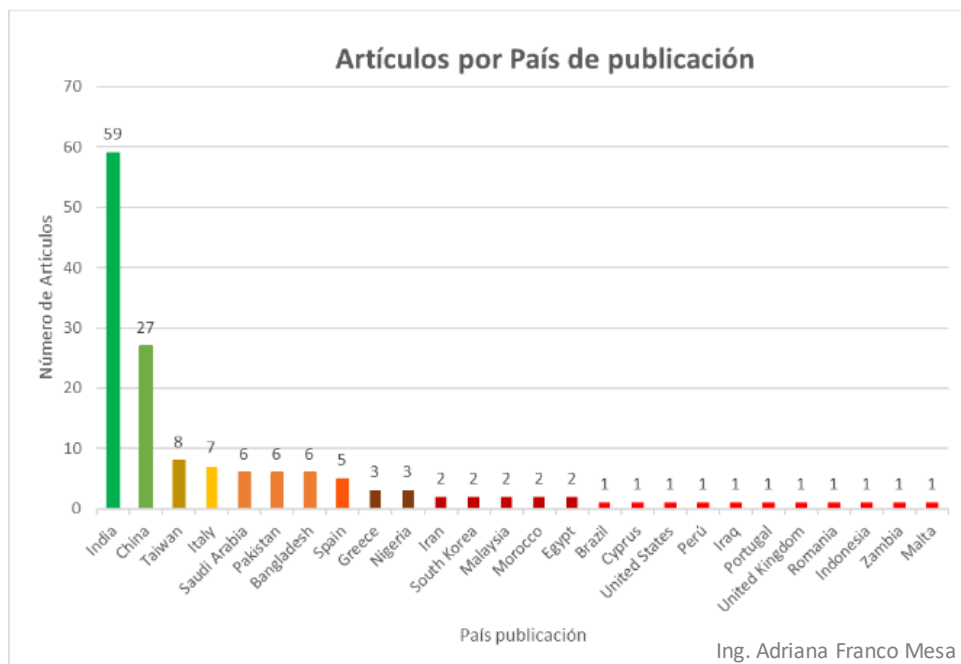
Nota. Gráfica de Elaboración propia con herramientas de Microsoft Excel

Además, como se observa en la gráfica anterior, la aplicación independiente de las técnicas con Procesamiento de imágenes muestra una tendencia moderna con una creciente adopción entre los años 2018 y 2020, mientras las Redes de Sensores WSN muestran un crecimiento sostenido a partir del año 2017 siendo su año de mayor impacto el 2021. Contrario a las técnicas por Asistencia Manual, las cuales tienen una menor presencia a través del tiempo. Es de destacar que la combinación de estas tecnologías con la Inteligencia Artificial abre una posibilidad para enfrentar las amenazas en los cultivos, permitiendo una gestión más efectiva y mayor protección de los recursos agrícolas.

A continuación, se relaciona en *Figura 8*, la distribución de las publicaciones realizadas por país en la ventana de tiempo en revisión, permitiendo vislumbrar la presencia geográfica de los avances investigativos en este campo.

Figura 8

Distribución de Artículos por País de Publicación



Nota. Gráfica de Elaboración propia con herramientas de Microsoft Excel

De acuerdo con la investigación realizada, se logra identificar una distribución geográfica de los artículos obtenidos, liderada por India y China con un total de 59 y 27 artículos publicados respectivamente, representando un 56,95% de la participación investigativa, que evidencia una fuerte influencia en la adopción de tecnologías avanzadas en la agricultura. Otros países como Taiwan, Italia, Arabia Saudita, Pakistan, Bangladesh y España también representan una contribución significativa en menor medida, destacando un notable interés en el desarrollo de alternativas para enfrentar los desafíos agrícolas en la prevención y detección de amenazas en los cultivos.

En general, estos resultados reflejan una distribución global de la investigación, enfocada en la aplicación de tecnologías IoT para la protección y mejora de los cultivos agrícolas en diferentes regiones del mundo, destacando cada vez más el interés de los países que inician su proceso investigativo de incorporación de estas tecnologías en su agricultura.

Técnicas y Tecnologías

A partir de un análisis detallado de las bases de datos de referencia, y soportado en la herramienta de mapeo científico SciMAT, se han identificado una gran variedad de soluciones tecnológicas, que se han visto evolucionar a lo largo de 9 años dividido en 3 grupos temporales (2014-2016, 2017-2019 y 2020-2022), donde se refleja un despliegue evolutivo y adaptativo de las diferentes técnicas y tecnologías soportadas en el Internet de las Cosas (IoT) para la prevención y detección de plagas y enfermedades en cultivos agrícolas. Estas divisiones temporales permiten una exploración más profunda de las tendencias emergentes, enfoques y avances innovadores en el campo, proporcionando una visión holística y de mayor precisión en la evolución del Internet de las cosas en la agricultura.

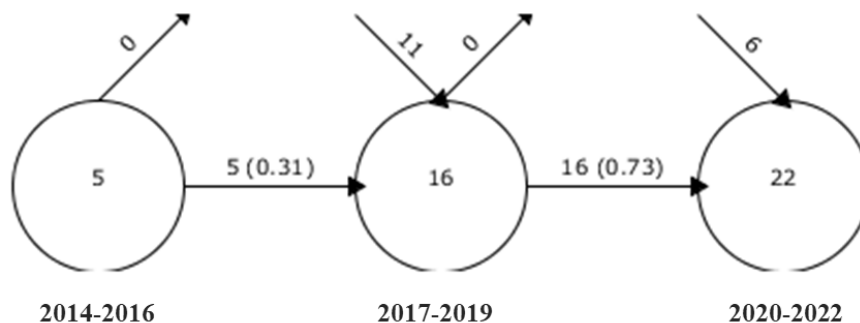
A través de esta revisión longitudinal que se muestra en el mapa superpuesto resultante en la *Figura 9* brinda una perspectiva significativa evidenciando una evolución gradual de las palabras clave extraídas de las 151 publicaciones analizadas, resaltando su permanencia a lo largo del tiempo mientras se integran nuevas palabras clave.

El análisis de los tres periodos distintos revela patrones evolutivos claros. Inicialmente, durante el primer período (2014-2016), se identifican 5 grupos de palabras clave fuertes las cuales, se mantienen y amplían en el periodo siguiente (2017-2019), con la incorporación de 11 nuevas palabras clave. Este crecimiento continúa hasta el último periodo (2020-2022), donde se observa un total de 22 grupos de palabras clave.

Figura 9

Mapa Superpuesto Análisis Longitudinal por Periodos con SciMAT

Mapa superpuesto



Técnicas de Prevención y Detección de Enfermedades y Plagas en Cultivos Agrícolas con IoT

SciMAT

Nota. Overlapping Map obtenido con herramienta de Mapeo científico SciMAT

Este análisis secuencial refleja tanto la consolidación de conceptos a lo largo del tiempo como la introducción de nuevos enfoques, lo que evidencia la dinámica cambiante y la

profundización constante en el campo de la prevención y detección de plagas y enfermedades en cultivos agrícolas basadas en Internet de las cosas (IoT).

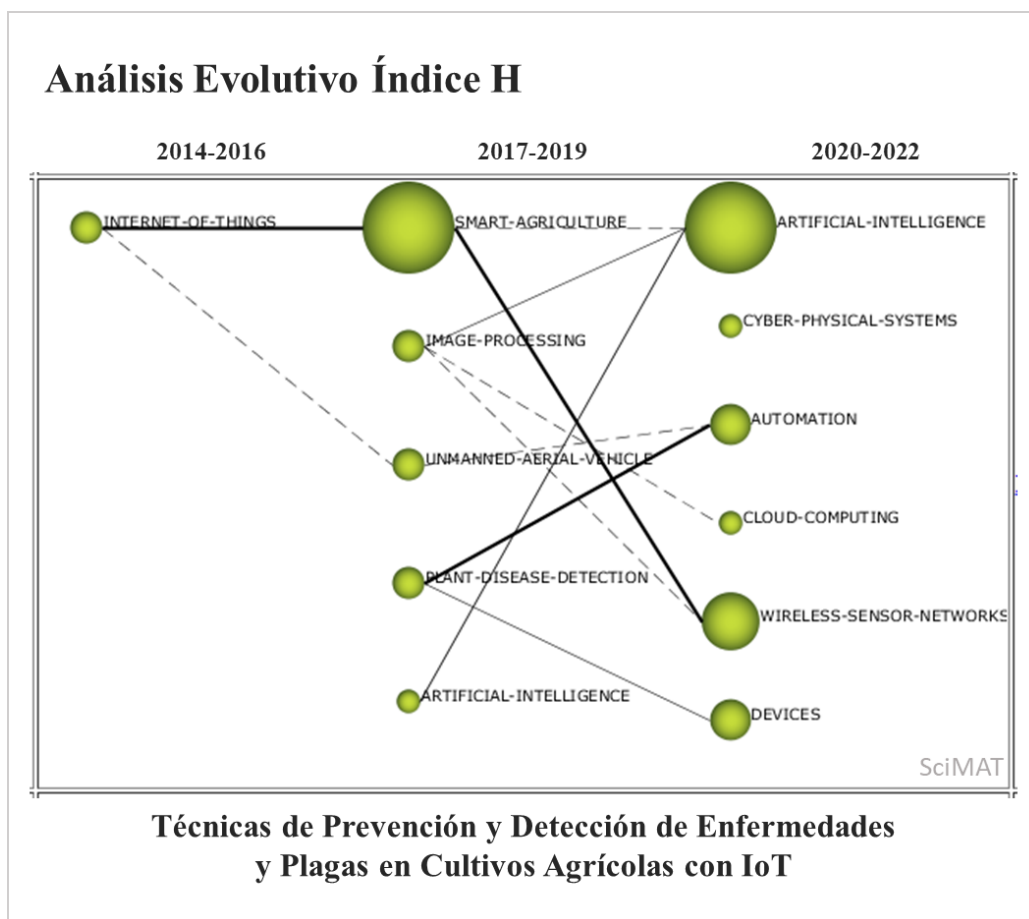
Por otra parte, esta revisión brinda dos perspectivas más profundas que evidencian un análisis evolutivo de los documentos consultados, basados en métricas del Índice H (Hirsch Index) y el Promedio de Citaciones, lo que permite medir el impacto de palabras claves de la investigación en función de la cantidad de citaciones de los artículos. Asimismo, conocer el promedio de citaciones de las palabras en los documentos, ofreciendo así una evaluación más completa del alcance y la influencia de los conceptos investigados en la ventana de tiempo seleccionada.

De esta manera, el primer mapa obtenido con el Índice H en *Figura 10*, refleja una evolución de las 12 palabras clave más significativas de la investigación, donde se logra observar la primer palabra *Internet of Things (IoT)* que emerge desde la etapa inicial, demostrando una evolución sólida con la capacidad de adaptarse a nuevos conceptos, más específicos en el campo de investigación, esto se evidencia en la siguiente etapa donde esta palabra se interconecta con la temática de mayor impacto en este periodo, *Smart Agriculture* un concepto con un enfoque definido para el ámbito de la agricultura basado en tecnologías de IoT; para finalmente continuar su evolución y mantener su relevancia en el último periodo con una de las palabras más relevante de esta etapa *Wireless Sensor Network*, consolidando su impacto en el desarrollo de la investigación.

Asimismo, se destaca la palabra *Artificial Intelligence* como otra de las palabras de mayor impacto sobre todo para el último periodo, donde lidera la tendencia que se abre paso desde el periodo intermedio donde se interconecta también con *Image Processing*, lo que quiere mostrar una evolución de conceptos y ecosistemas tecnológicos más complejos y adaptativos.

Figura 10

Mapa de Análisis Evolutivo Índice H con SciMAT



Nota. Mapa de Evolución coreDocuments-hIndex obtenido con herramienta de Mapeo científico SciMAT

El siguiente mapa, se basa en la medición promedio de citas el cual se comporta como indicador de calidad de las citas que permite evidenciar la importante acogida académica que ha tenido el estudio investigativo basado en tecnologías IoT para la detección y prevención de plagas y enfermedades en cultivos agrícolas.

Es así, como en *Figura 11*, se puede observar aún una evolución solididad del concepto *Internet of Things (IoT)* demostrando una fuerte influencia sobre otros conceptos a través de los diferentes periodos representados en la gráfica. Esto se manifiesta a través de las conexiones que establece en el periodo intermedio con palabras claves como *Unmanned Aerial Vehicle* y *Smart*

Agriculture siendo esta última, una de las palabras más relevantes de esta etapa, Además, es pertinente destacar la importancia evolutiva que tiene el Internet de la Cosas en el último periodo con los conceptos *Wireless Sensor Networks* y *Artificial Intelligence*.

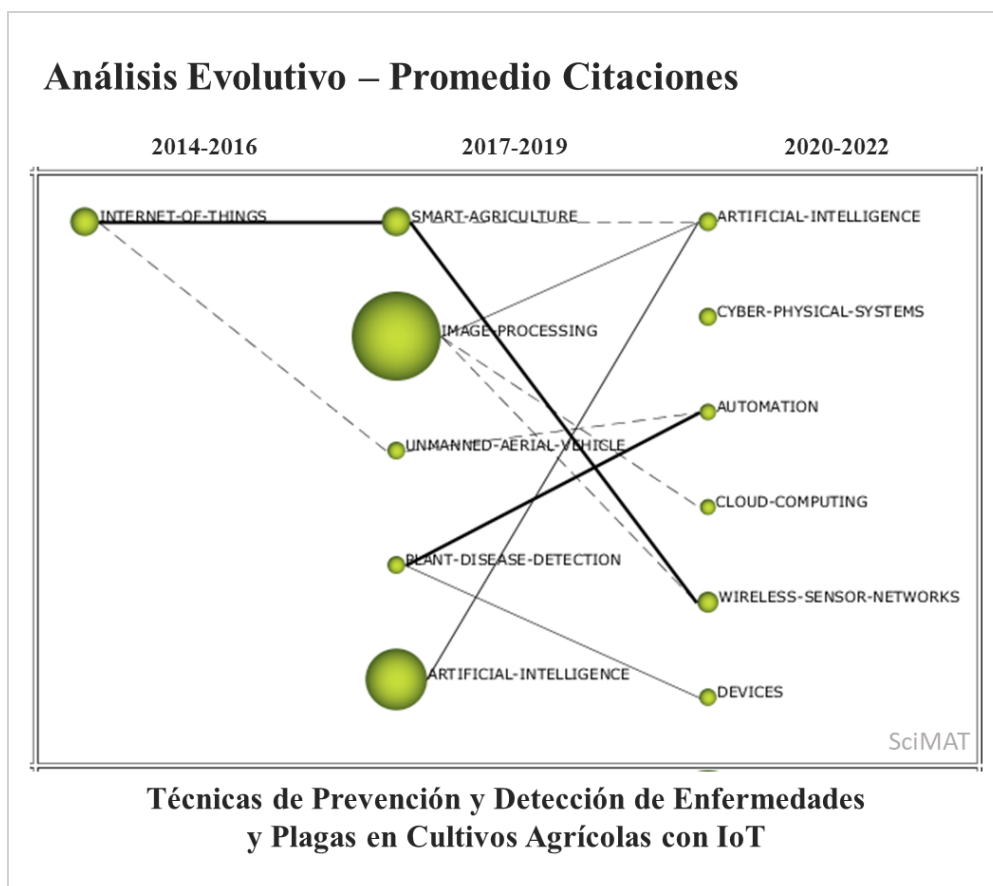
Por su parte, *Wireless Sensor Networks* además de la estrecha relación ya mencionada con la Agricultura Inteligente muestra una influencia significativa de la palabra clave *Image Processing*, el cual se destaca como uno de los concepto de mayor impacto de citas promedio para el periodo intermedio, de esta manera, *Image Processing* destaca su gran importancia como una tecnología influyente también para el desarrollo de aplicaciones con *Artificial Intelligence* y *Cloud Computing* para el último periodo de análisis

Sin lugar a duda, *Artificial Intelligence* es uno de los conceptos con mayor auge e impacto de los últimos tiempos, como se puede apreciar claramente en la gráfica. Este concepto, se ve influenciado también por otras tecnologías de vanguardia como el Internet de las Cosas y la Agricultura Inteligente, en el contexto del desarrollo de aplicaciones de control de plagas y enfermedades en los cultivos, evidenciando su mayor impacto en esta área durante el periodo intermedio de la ventana de investigación.

En resumen, esta gráfica muestra una evolución de la investigación en la ventana de tiempo 2014-2022, centrada en conceptos como IoT y Agricultura Inteligente hacia un enfoque más amplio en Inteligencia Artificial y área relacionadas, demostrando la interconexión de estos conceptos y cómo ha evolucionado la investigación en función del indicador promedio de citas destacando el procesamiento de imágenes y la Inteligencia Artificial como los conceptos más influyentes en el estudio realizado.

Figura 11

Mapa de Análisis Evolutivo del Promedio de Citaciones con SciMAT



Nota. Mapa de Evolución coreDocuments-averageCitations obtenido con herramienta de Mapeo científico SciMAT

Análisis Comparativo

A partir de los datos obtenidos en la revisión, se realiza un análisis comparativo utilizando algunos criterios de evaluación, con el objetivo de validar el desempeño de implementación de las técnicas y Tecnologías basadas en IoT para la detección y prevención de enfermedades y plagas en los cultivos agrícolas.

De esta manera, como se refleja en *Tabla 5* cada criterio presenta una calificación cualitativa para determinar el nivel de impacto o dificultad de la implementación de estas

técnicas y tecnologías. A continuación, se describen los resultados de esta evaluación por cada criterio:

Análisis de Costos

En términos de inversión basado en los resultados de investigación, las *Tecnologías de asistencia manual*, destacan por su bajo costo de inversión, siendo una opción accesible y económica para agricultores con recursos limitado. Mientras las tecnologías de *Procesamiento de Imágenes e Inteligencia Artificial* a menudo representan costos significativos de desarrollo debido a la necesidad de implementar recursos tecnológicos especializados como equipos y software avanzados que las soporten.

Nivel de Precisión

A nivel de Precisión, la *Inteligencia Artificial* se destaca por presentar los resultados más cercanos al 99% de precisión en la recopilación, detección y análisis de datos en diferentes soluciones en el área de investigación, siendo capaz de ofrecer resultados altamente confiables en tiempo real. Por otra parte, las *Tecnologías de asistencia manual* suelen presentar una precisión muy limitada, debido a su dependencia de la interacción e interpretación humana.

Gestión Tecnológica

Este criterio evalúa el despliegue, integración y uso eficiente de los recursos tecnológicos que permitan la gestión efectiva de la solución IoT; así, en el caso de la *Inteligencia Artificial* se muestra como una tecnología con enfoque avanzado con un nivel de gestión alto ya que requiere de una gestión eficiente para su implementación y desarrollo continuo. Mientras las *Tecnologías de asistencia manual*, presenta un nivel de gestión tecnológica bajo, ya que no requieren de una infraestructura tecnológica compleja, puesto que a menudo dependen del factor humano para la adquisición e interpretación de datos para la toma de decisiones.

Vigencia

La tendencia temporal en la utilización de estas tecnologías nuevamente señala que las *Tecnologías de asistencia manual* tienen una menor duración en términos de relevancia, lo que sugiere que su aplicación disminuye con el tiempo en comparación con tecnologías más avanzadas y automatizadas. Por otro lado, la *Inteligencia Artificial* se muestra altamente vigente demostrando un crecimiento importante en aplicaciones agrícolas especializadas, gracias a su capacidad de adaptación continua con otras tecnologías que le permite abordar con éxito los nuevos desafíos y demandas en el campo de investigación agrícola, lo que la convierte en una tecnología duradera y altamente relevante en el tiempo.

Tabla 5

Análisis Comparativo de Implementación de las Técnicas y Tecnologías con IoT

Técnicas y Tecnologías	Análisis de costos	Nivel Precisión	Gestión Tecnológica	Vigencia
Redes de sensores (WSN)	Medio	Medio	Medio	Medio
Procesamiento de Imágenes	Alto	Medio	Medio	Medio
Tecnologías de Asistencia Manual	Bajo	Bajo	Bajo	Bajo
Inteligencia Artificial	Alto	Alto	Alto	Alto

Nota. Esta tabla presenta un análisis comparativo con calificación cualitativa de la implementación de la técnicas y tecnologías con IoT para la prevención y detección de plagas en cultivos agrícolas

Impacto de las Técnicas y Tecnologías en la Productividad Sostenible

La tecnología en el campo agrícola ha estado en una evolución constante, con desafíos importantes en el desarrollo de soluciones sostenibles. En este contexto, el Internet de las Cosas (IoT) emerge como una solución clave para la detección y prevención tanto de plagas como de enfermedades en los cultivos agrícolas. En este sentido, el IoT en los últimos años ha tomado un impulso significativo que ha permitido generar un avance importante en el fortalecimiento de la agricultura sostenible. Independientemente de su marco temporal de implementación de todas las soluciones tecnológicas revisadas en la última década, presentan un impacto positivo en el desarrollo sostenible. Sin embargo, se evidencia un mayor aporte en algunas soluciones donde la intervención tecnológica coexiste de manera no invasiva con el medio ambiente, lo que amplía aún más su influencia en la promoción de prácticas agrícolas respetuosas con la naturaleza.

Por su parte, el procesamiento de imágenes digital ha logrado un avance significativo en la agricultura con mejoras notables en términos de precisión en la detección de enfermedades y plagas, así como la gestión deficiente de los cultivos; ya que esta tecnología, en lugar de adquirir información directamente en el campo, utiliza la captura de imágenes y el procesamiento digital, para la toma de decisiones oportuna, a partir del análisis detallado de características específicas en las imágenes de las plantas, logrando identificar la presencia de enfermedades y plagas en el cultivo de manera más eficiente.

Como una tecnología adaptativa, el procesamiento de imágenes es capaz de integrarse con otras tecnologías más avanzadas como la inteligencia artificial y las redes de sensores inalámbricas. Esta sinergia posibilita una acción inmediata, esencial para la protección y optimización de los cultivos, siendo un impulso importante a la agricultura sostenible al brindar información detallada y en tiempo real sin la necesidad de intervención con el uso invasivo de

equipos o herramientas en el entorno agrícola, brindando así mejoras importantes en la productividad como en la calidad de los cultivos.

Por su parte, las soluciones basadas en IoT soportadas en Inteligencia Artificial (IA) también han generado una revolución destacada en la agricultura en términos de desarrollo y productividad sostenible. La IA aporta un nivel de sofisticación sin precedentes, permitiendo una optimización más precisa y profunda de los procesos agrícolas. Al ser un sistema con capacidad de procesar datos en tiempo real y tomar decisiones determinantes para productividad, la IA ha logrado revolucionar la gestión de los cultivos agrícolas, mejorando la eficiencia en el uso de recursos hídricos por ejemplo, reduciendo al mínimo el desperdicio de agua, lo que resulta esencial en una agricultura más eficiente y sostenible en un mundo donde el agua es cada vez más escasa.

En este sentido, la optimización y uso responsable de recursos naturales toman gran relevancia en el desarrollo de este tipo de soluciones, que logren reducir la huella de carbono en la agricultura de precisión, de esta manera las fuentes de energía renovable, como la energía solar, desempeñan un papel fundamental en el desarrollo de soluciones y prácticas sostenibles, siendo especialmente atractivas gracias a su comportamiento no invasivo en los cultivos como en el medio ambiente. A diferencia de las infraestructuras energéticas tradicionales, la recepción de energía solar se puede implementar en espacios no utilizados para la agricultura, minimizando así, los niveles de interferencia con la producción agrícola.

Es de destacar que las energías alternativas presentan una mayor preferencia en este tipo de soluciones, ya que proporciona la alimentación necesaria para los circuitos electrónicos de bajo consumo utilizados en el despliegue de soluciones IoT y sensores en los cultivos, logrando reducir la dependencia de fuentes de energía convencionales, con una mayor eficiencia y

sostenibilidad en la agricultura moderna, al tiempo que ofrece un equilibrio entre los costos de producción de alimentos y la preservación del medio ambiente.

Este tipo de soluciones basadas en IoT, en especial aquellas desarrolladas bajo la influencia de la Inteligencia Artificial, enmarcan una transición significativa en la agricultura correctiva tradicional hacia una agricultura preventiva más sana. Estas tecnologías ofrecen una detección temprana con el objetivo de prevenir enfermedades y plagas generando un ambiente hostil para su proliferación, en lugar de simplemente reaccionar a la aparición de amenazas; lo que convierte a estas soluciones en un hito fundamental en la búsqueda de la sostenibilidad agrícola.

Esta evolución de la agricultura sostenible hacia prácticas agrícolas más amigables con el medio ambiente no sólo tendrá un aporte importante en la reducción de la vulnerabilidad de los cultivos a los desafíos fitosanitarios, sino que también mejora significativamente la calidad e inocuidad alimentaria, manteniendo los nutrientes naturales de los alimentos, a su vez que tiene un impacto directo en la salud humana al reducir la exposición de los alimentos a productos químicos nocivos para el consumo.

Temas Abiertos y Áreas Pendientes

En este capítulo se evaluará el área fronteriza de la investigación donde la innovación se encuentra con los desafíos por resolver en el ámbito de las tecnologías basadas en IoT aplicadas en la gestión agricultura de plagas y enfermedades. Esto, con el objetivo de brindar un panorama más completo de la dirección que puede tomar este campo en el futuro próximo.

Tendencias

En orden de comprender a profundidad la evolución de las temáticas más relevantes del estudio realizado, se presentan los siguientes diagramas estratégicos que representan visualmente las relaciones de densidad y centralidad de los conceptos clave de la revisión que permite identificar su impacto en los últimos periodos de la ventana de revisión. De esta manera, estas gráficas proporcionan una visión panorámica de las temáticas de investigación en tendencia, los enfoques emergentes especializados y las interacciones entre los conceptos más relevantes en este campo de la agricultura impulsada por IoT.

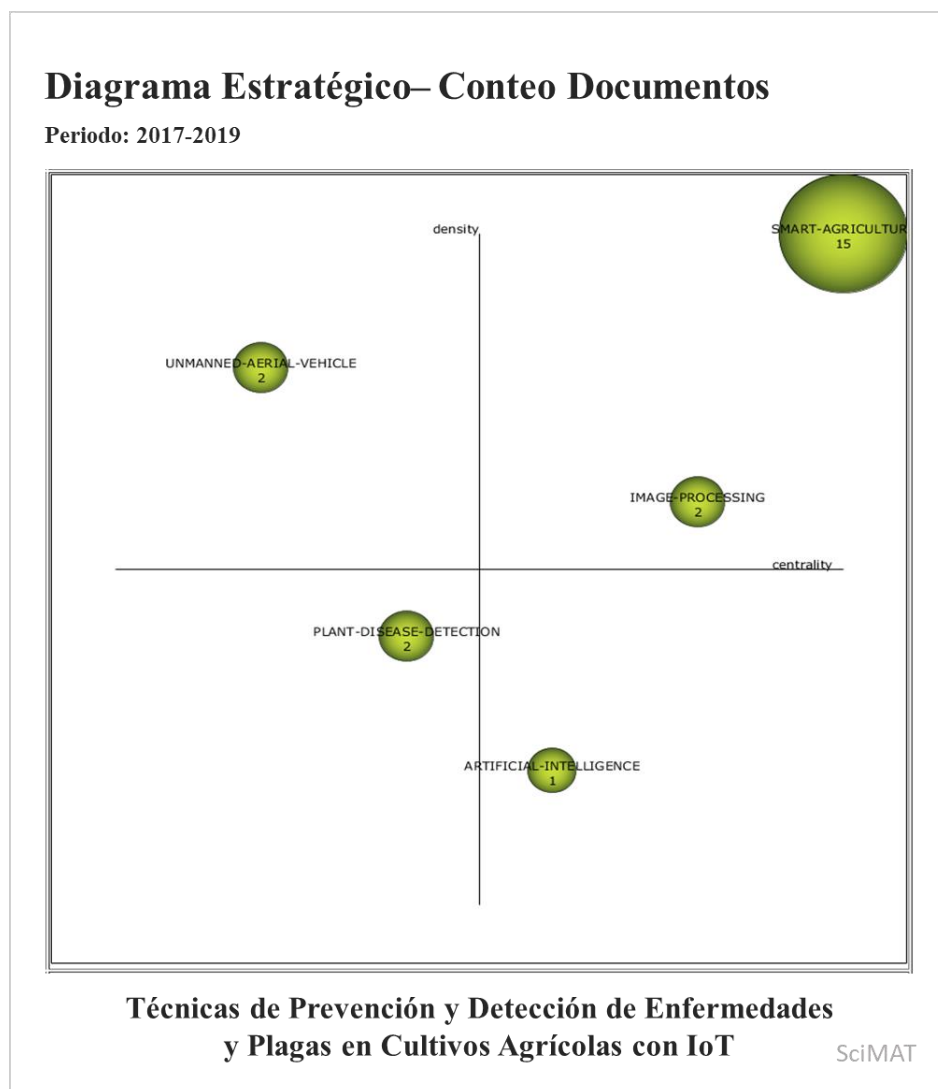
Así, como se puede observar en *Figura 12*, se presenta el Diagrama Estratégico referente a las temáticas identificadas de la investigación, y el número de documentos centrales en cada uno de ellos, para el periodo intermedio de la ventana temporal, donde se observa un plano de cuatro cuadrantes, que permiten identificar la relevancia central de los conceptos en la investigación.

De esta manera, se logra identificar sobre el primer cuadrante como temática central *Smart Agriculture*, la cual destaca como el concepto más importante en el mapa de la investigación con un alto número de documentos centrales asociados; sobre este mismo cuadrante se muestra el impacto de *Image Processing* que la convierte en uno de los ejes centrales de la investigación en este periodo, aunque en menor medida que *Smart Agriculture*.

Mientras los conceptos de *Unmanned Aerial Vehicle*, ubicado en el tercer cuadrante, y *Plant Disease Detection* sobre el cuarto cuadrante, presentan una importancia moderada, al igual que *Artificial Intelligence* en el segundo cuadrante, que se muestra como una temática central en desarrollo, durante el periodo intermedio de la investigación.

Figura 12

Diagrama Estratégico Conteo de Documentos Principal del Periodo Intermedio



Nota. Diagrama Estratégico coreDocuments-documentsCount obtenido con herramienta de Mapeo científico SciMAT

Asimismo en *Figura 13* se presenta el diagrama estratégico del conteo de documentos para el periodo final de la ventana temporal, donde se logra observar un cambio destable que conecta con la gráfica inmediatamente anterior, donde se observaba *Artificial Intelligence* como tecnología en desarrollo, ahora esta temática se observa con un gran impulso destacando como el eje central más importante de la investigación, con un altísimo número de documentos centrales con gran densidad de conexiones con otras temáticas.

En este mismo cuadrante, *Cyber-Physical Systems* y *Automation* emergen como nuevos conceptos en la investigación con un gran impacto en el último periodo, aunque ligeramente menos que la temática que lidera el cuadrante *Artificial Intelligence*.

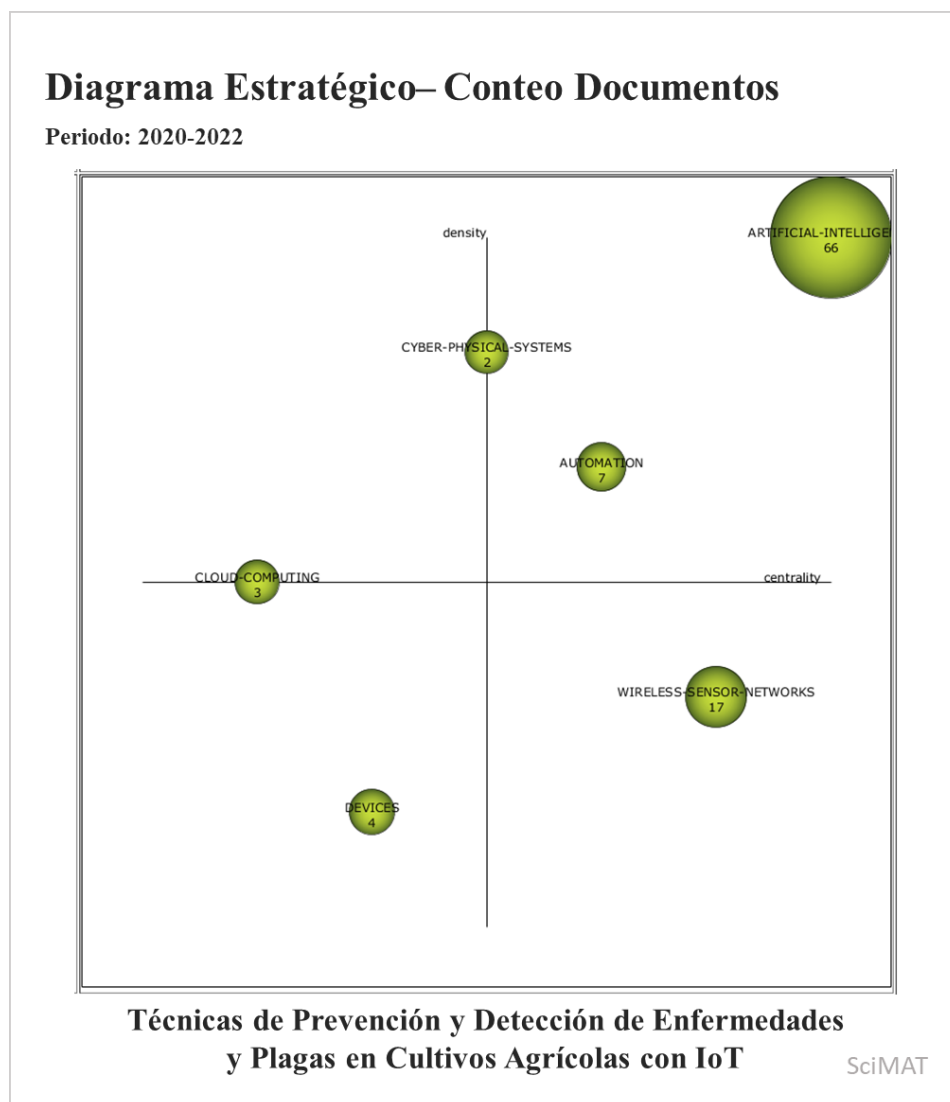
Se destaca también, el concepto *Wireless Sensor Networks* en este mapa de investigación, por la cantidad de documentos asociados y que demuestra una gran densidad de conexiones con otras temáticas; además, su ubicación en el segundo cuadrante destaca su importancia como una tendencia en desarrollo, para el futuro próximo.

En menor densidad se presentan las temáticas *Devices* y *Cloud Computing* las cuales se sitúan sobre el cuarto cuadrante, mostrándose como temáticas poco desarrolladas para el mapa de investigación, aunque logran un nivel de importancia moderada por su cantidad de documentos centrales asociados.

En general, estos datos sugieren que la tendencia durante los últimos años es la *Artificial Intelligence* siendo campo de investigación más destacado y denso interconectado en el conjunto de datos de análisis estratégico, representando en un gran registro de documentos centrales asociados para la prevención y detección tanto de plagas como enfermedades en los cultivos agrícolas

Figura 13

Diagrama Estratégico Conteo de Documentos Principal Último Periodo



Nota. Diagrama Estratégico coreDocuments-documentsCount obtenido con herramienta de Mapeo científico SciMAT

Finalmente, para soportar y consolidar estos hallazgos relacionados con las tendencias tecnológicas de esta revisión, se presenta en *Tabla 6* un resumen que brinda una visión general los modelos y técnicas implementadas para el desarrollo de las soluciones basadas en IoT para la prevención y detección tanto de plagas como enfermedades en los cultivos agrícolas. Destaca en

particular la presencia significativa de modelos de Redes Neuronales diferentes soportados como tecnologías de Inteligencia Artificial. Estos resultados subrayan la creciente importancia de la IA y las Redes Neuronales, proporcionando una visión clara de las tecnologías que vienen liderando en miras hacia una agricultura más inteligente y sostenible

Tabla 6

Resumen Modelos y Técnicas Soluciones IoT Aplicadas

Tecnologías	Técnicas o Modelos Implementación
Redes de sensores (WSN)	<ul style="list-style-type: none"> - <i>Sensado comprimido (CS)</i> - <i>ThingSpeak</i> - <i>IoT: LoRa WAN, ZigBee, NB-IoT</i> - <i>Microcontroladores: Raspberri Pi3, Arduino UNO R3, Arduino MEGA, NodeMCU(ESP8266), PIC16F877A</i> - <i>Módulos: GSM, WiFi, GPS</i> - <i>Sensores: Sensores ambientales (Humedad, Temperatura, pH)</i> - <i>Camaras: Cámaras detección de movimiento, Cámaras hiper espectrales.</i> - <i>Robots: UAV, Drones, Robots.</i> - <i>Otros Dispositivos: SIL(Lampara Solara Incecticida), Smart Traps, Smartphones</i>
Procesamiento de Imágenes	<ul style="list-style-type: none"> - <i>Clustering: K-means, Super pixeles</i> - <i>Segmentación: Thersholding</i>

-
- *Clasificadores*: Lineal Kernel, ELM, Filtrado Kalman, K-fold, Cutout
 - *Histogramas*: PHOG (Piramide de Histogramas de Gradientes de Orientación), SADH (Histograma de Suma y Diferencia),
 - *Modelos Extracción*: GMCL (Biblioteca Calculo Matricial Generativo), ASPE (Extracción dimensión segmentación avanzada)
 - *Modelo de color*: RGB-HSV, SCD (Descriptor de color escalable)

Inteligencia Artificial

- *Deep learning*: CNN(Red Neuronal Convolutacional) DBN (Deep Belief Network), DCNN (Deep CNN Multicapa), ANN (Artificial NN), MLP-ANN (ANN Perceptron Multicapa), GAN (Red Generativa Adversarial), RCNN (Redes residuales), RideNN
 - *CNN*: Fast-MPN, MobileNet, DenseNet121, UNet, EfficientNet, ImageNet, AlexNet, NTS-Net, ContextNet, MixConvNet, Q-CNN (CNN Cuantizada), MCFN (Multi context Fusion Network), MPFN (Fusion de probabilidad Gaussiana de múltiples flujos), MCNS (Equema Neuronal Convolutacional Modificado), FBFB (Red lógica difusa)
-

-
- *RNN*: RestNetV2, RestNet34, RestNet50, RCNN-LSTM (Long-short Term Memory), RGAN (Residual GAN), InceptionRestNetV2, MDFC-RestNet (Compensación de características Multidimensional)
 - *Machine Learning*: SVM (Support Vector Machine), VGG19, VGG16, YOLOV3, YOLOV4, YOLOV5, GoogleNet Inception, InceptionV2, InceptionV3, CNNIR-OWELM (Optimal Weighted Extreme Learning Machine)
 - *Aprendizaje Automático*: Modelo Keras, TensorFlow, XGBoost, KNN (K-Nearest Net)
 - *Aprendizaje Adaptativo*: Adadelata, SGD
 - *Transference Learning*
 - *Computer Vision*: Grad CAM, OpenCV
-

Nota. Esta tabla presenta un resumen de los modelos y técnicas implementadas en las soluciones con IoT más destacadas de la revisión

Desafíos y Limitaciones

La integración de la Inteligencia Artificial, con el Internet de las Cosas para la prevención y detección tanto de plagas como de enfermedades en los cultivos agrícolas representa una tendencia relativamente nueva, como lo sugiere el análisis temporal realizado, pues se evidencia que, en los últimos 6 años, se presenta un aumento significativo en la adopción de esta tecnología, lo que enmarca un crecimiento sustancial en la investigación y desarrollo de soluciones en este campo. Sin embargo, se observa una transición de diversos modelos que inicialmente se han simulado y evaluado en términos de desempeño hacia la fase de validación

en implementaciones reales. Lo que refleja un desafío notable en la adaptación teórica a las situaciones agrícolas complejas, relacionados a factores ambientales, variabilidad en la naturaleza de las plagas y necesidades de escalar las bases de datos de aprendizaje.

Ahora bien, en términos de precisión, uno de los desafíos fundamentales radica en la necesidad de adaptar las soluciones a la singularidad de cada cultivo, esto debido a que cada uno presentar una serie de características específicas, comportamiento y crecimiento diferente, desde su entorno ambiental hasta sus necesidades de gestión, lo que implica que no exista una solución única que se ajuste a todos los contextos agrícolas. En este sentido será importante poder validar la interacción de diversas tecnologías para aplicaciones de contextos específicos, que respondan a la necesidad de desarrollar soluciones más robustas que integren lo mejor de varias tecnologías disponibles que soporte el fortalecimiento del desempeño de las soluciones en términos de precisión que potencien su viabilidad para su implementación en entornos de producción real.

En lo que respecta a los costos de implementación y desarrollo, si bien es cierto hay avances a nivel de simulación y ciertos prototipos de implementación, surge una limitación crucial que requiere ser abordada, puesto que en la adopción efectiva de soluciones IoT en este campo de investigación, se requiere una inversión significativa en múltiples frentes, esto incluye sensores de alta precisión, dispositivos de comunicación robustos, hardware y software especializado, así como la infraestructura necesaria para respaldar estas tecnologías. Por lo tanto, uno de los desafíos más apremiantes en este campo es encontrar enfoques que optimicen los recursos disponibles y permita garantizar no solo un desempeño sostenible de las soluciones sino también encontrar puntos de equilibrio favorables para los agricultores donde la inversión en tecnología genere un retorno significativo en términos de productividad, mitigación de riesgos y sostenibilidad.

En lo que respecta al consumo energético y las energías renovables, si bien, se ha avanzado notablemente, aún no es suficiente y queda mucho por hacer. En este sentido las soluciones IoT para la agricultura requiere que operen de manera continua y, por tanto, se debe garantizar que estos sistemas se encuentren energizados de manera constante. Esto plantea la necesidad de abordar cuestiones relacionadas con el almacenamiento de energía, que debe ofrecer un alto rendimiento y fiabilidad para mantener el funcionamiento ininterrumpido de las soluciones IoT. Por lo tanto, la elección de la fuente de energía en un proyecto con dispositivos IoT debe ser cuidadosamente evaluada y adaptada al entorno particular de implementación. En este sentido, las energías renovables, como la energía solar, han surgido como opciones prometedoras para alimentar estos sistemas de manera sostenible, sin embargo, para lograr un uso efectivo de estas energías, se debe contar con equipos y personal especializado para su mantenimiento continuo.

La mayor parte de los trabajos de investigación, realizan sus primeras implementaciones en áreas de corto y mediano alcance, donde las tecnologías de comunicación inalámbricas son más efectivas y confiables. Sin embargo, se presenta un desafío cuando se busca implementar estas soluciones en áreas geográficas muy extensas y con topografía diversa, ya que se vuelve crucial contar con una conexión confiable y de alta calidad que soporte distancias considerables y además logre superar los obstáculos del terreno.

Por tanto, es necesario evaluar cuidadosamente las tecnologías de comunicación idóneas para cada área de implementación, que logren mitigar diferentes factores como los efectos de interferencia de señal, el desvanecimiento y de línea de vista, especialmente cuando se trata de áreas extensas y diversas. La elección adecuada de tecnologías y protocolos de comunicación puede ayudar a mitigar estos desafíos, permitiendo una conectividad sólida u sin problemas en

entornos diversos, ya que este aspecto es crucial para garantizar el funcionamiento efectivo y la fiabilidad de las soluciones IoT en agricultura, independiente de la ubicación geográfica o las condiciones topográficas de implementación.

La Ciberseguridad en el contexto de las tecnologías con IoT para la agricultura es esencial debido al creciente número de dispositivos conectados y con ello la gran cantidad de datos e información sensible de los usuarios y los entornos de implementación. Es por esto, por lo que la Ciberseguridad se convierte en un desafío importante, que debe ser abordado con medidas de seguridad que permitan robustecer el sistema ante las vulnerabilidades, como la implementación de factores AAA (Authentication, Autorization, Acounting), encriptación y actualizaciones regulares. Además, es pertinente poner en contexto a todo el personal involucrado, para garantizar la integridad y confiabilidad de las soluciones.

El almacenamiento y análisis de datos desempeñan un papel fundamental en las soluciones de IoT para la agricultura, pero también plantean desafíos a la gestión de grandes volúmenes de información de los procesos agrícolas. En la actualidad se están implementando sistemas basados en la nube para abordar esta creciente demanda; sin embargo, es pertinente considerar la escalabilidad de los datos durante el desarrollo de la solución. Esto implica prever cuanto espacio de almacenamiento y capacidad de procesamiento será necesario para garantizar un rendimiento eficiente en las tareas de carga, descarga y análisis de datos. Esto con el objetivo de evitar posibles sobrecargas en los sistemas y así garantizar que funcionen de manera óptima.

Por otra parte, el desarrollo e implementación de soluciones basadas en IoT para la gestión agrícola de plagas y enfermedades, enfrenta varios desafíos en términos de regulación y estándares. De esta manera, se generan algunas incertidumbres legales debido a la falta de regularización uniforme en este campo en evolución constante, obstaculizando la adopción

generalizada de estas tecnologías. Además, la interoperabilidad entre sistemas IoT de diferentes proveedores es un tema crucial ya que la falta de estándares comunes dificulta la integración y comunicación efectiva entre dispositivos y plataformas de monitoreo. En este sentido, encontrar un equilibrio entre la regularización de estándares y la innovación es esencial, ya que la tecnología evoluciona rápidamente. Asimismo, una regularización adecuada es fundamental para garantizar la seguridad, la confiabilidad y la ética de los datos que intervienen en la implementación de sistemas con IoT en la agricultura.

Finalmente, la complejidad tecnológica de estos sistemas basados en IoT, implica contar con habilidades técnicas específicas, lo que significa que la capacitación efectiva es esencial para dar soporte idóneo de los equipamientos que hacen parte de la implementación. Aunque las diferencias educativas y generacionales entre los agricultores puedan dificultar este proceso, por lo tanto, se requiere un enfoque adaptado a diferentes niveles de experiencia tecnológica y esfuerzos considerables en programas de capacitación y materiales educativos que garanticen el aprovechamiento tecnológico de los usuarios. Esta pedagogía es esencial para una adopción exitosa y sostenible de las soluciones IoT en la agricultura.

Conclusiones

Se logró identificar que el impacto que presentan las tecnologías basadas en IoT, como las redes de sensores WSN, el procesamiento de imágenes y la inteligencia artificial, en la agricultura sostenible, es innegable y prometedor, pues estas tecnologías han logrado impulsar una revolución en la manera de gestionar y producir alimentos en el agro, brindando soluciones cada vez más efectivas para la prevención y detección de enfermedades y plagas en los cultivos.

A partir de la tendencia temporal y la actualización tecnológica que se observa en esta revisión, la Inteligencia Artificial no solo se presenta como la tendencia tecnológica más influyente, sino también como un eje articulador de diversas tecnologías que potencia el desempeño de cada una de ellas, en un contexto de aprendizaje continuo y de optimización de recursos. Logrando de esta manera, elevar la agricultura a un nivel superior, al procesar datos en tiempo real y tomar decisiones precisas que mejoran la eficiencia y la sostenibilidad en el agro.

Se pudo observar a partir de la revisión realizada cómo el Procesamiento de Imágenes emerge en los últimos tiempos como una tendencia articulada con algoritmos de Inteligencia Artificial. Estas tecnologías, que ha evolucionado con un enfoque adaptativo, siguen desempeñando un papel importante en las soluciones que se continúan desarrollando para la prevención y detección de amenazas en las hojas de las plantas.

Es importante mencionar, que a medida que la Inteligencia Artificial ha avanzado, el Procesamiento de Imágenes ha encontrado nuevas aplicaciones y formas de integrarse con otras tecnologías, lo que ha permitido un enfoque más preciso y eficiente en la agricultura. En este sentido, esta tecnología se convierte en un componente esencial en la implementación de soluciones con Inteligencia Artificial, respaldando la prevención de amenazas en los cultivos, contribuyendo a una agricultura más sostenible y productiva.

Es de destacar la notable influencia de las soluciones basadas tecnologías de Redes de Sensores Inalámbricos que, en conjunto con el IoT, han posibilitado un monitoreo altamente preciso y en tiempo real del entorno agrícola, a partir de la medición de factores ambientales, optimizando el uso de recursos hídricos y energéticos, lo que ha llevado a una considerable reducción de los riesgos asociados a enfermedades y plagas, mediante una gestión eficiente del consumo de agua. Además, esta tecnología ha elevado notablemente la precisión en la detección de amenazas en los cultivos y ha impulsado la automatización de la gestión de cultivos lo que se traduce en una toma de decisiones más efectiva en el ámbito de la agricultura de precisión.

Es de destacar que los sistemas Ciber-Físicos también se proyectan como una alternativa fuerte en el ámbito del IoT para el desarrollo de soluciones en la agricultura sostenible, demostrando una evolución de las tecnologías de la información y las comunicaciones.

De esta manera, para que una tecnología emergente logre proyectar un impacto duradero y un crecimiento a lo largo del tiempo, debe satisfacer con un factor esencial, referente a su capacidad de adaptación y evolución constante en respuesta a las cambiantes demandas del campo de investigación; esta característica se convierte en un criterio determinante que la convierta en un recurso valioso en estas tecnologías para abordar los desafíos agrícolas actuales y futuros.

En conjunto, se logra evidencia cómo estas tecnologías no solo presentan una destacable mejora en la productividad agrícola, sino que también están en una constante contribución a la conservación de los recursos naturales, al mitigar considerablemente el uso de productos químicos y promoviendo prácticas agrícolas más respetuosas y responsables con el medio ambiente. Si se gestionan adecuadamente y se abordan los desafíos identificados, estas

tecnologías tienen el potencial de desempeñar un papel crucial en la promoción de la agricultura sostenible que garantice además la inocuidad alimentaria en un mundo en constante evolución.

Finalmente, se evidencia que las soluciones más sólidas y efectivas son aquellas que integran lo mejor de diversas tecnologías para fortalecer la precisión en la implementación en producción agrícola. Este enfoque integral además promueve un impacto sostenible en la agricultura de precisión, transformando la gestión de los cultivos, con la optimización del uso de los recursos, reducción de desperdicio y quizá lo más importante minimizando la exposición a productos químicos en el consumo. De esta manera, estas tecnologías no sólo mejoran la productividad, sino que también contribuyen a la preservación de los recursos naturales y la promoción de prácticas agrícolas más sostenibles.

En el emocionante mundo de la Integración de la Inteligencia Artificial y el Internet de las Cosas en la agricultura, hemos dado pasos gigantes, pero lo más emocionante aún está por venir. A medida que enfrentamos desafíos tecnológicos, económicos y regulatorios, recordemos que cada obstáculo es una oportunidad de aprendizaje y crecimiento. Nuestra misión de prevenir y detectar plagas y enfermedades en los cultivos es fundamental para garantizar un futuro sostenible y seguro para nuestra alimentación y nuestro planeta.

Referencias Bibliográficas

- Aasha Nandhini, S., Hemalatha, R., Radha, S., & Indumathi, K. (2018). Web Enabled Plant Disease Detection System for Agricultural Applications Using WMSN. *Wireless Personal Communications*, 102(2), 725-740. Scopus. <https://doi.org/10.1007/s11277-017-5092-4>
- Abu, N. S., Bukhari, W. M., Ong, C. H., Sukhaimie, M. N., Wibowo, S., & Kassim, A. M. (2022). Automated Agricultural Management Systems Using Smart-Based Technology. *International Journal of Emerging Technology and Advanced Engineering*, 12(5), 123-131. Scopus. https://doi.org/10.46338/ijetae0522_14
- Agarwal, M., Sinha, A., Gupta, S. K., Mishra, D., & Mishra, R. (2020). Potato Crop Disease Classification Using Convolutional Neural Network. *Smart Innovation, Systems and Technologies*, 141, 391-400. Scopus. https://doi.org/10.1007/978-981-13-8406-6_37
- Agricultura, O. de las N. U. para la A. y la. (2019). *La contaminación del suelo: Una realidad oculta*. Food & Agriculture Org.
- Ahmad, M., Abdullah, M., Moon, H., & Han, D. (2021). Plant Disease Detection in Imbalanced Datasets Using Efficient Convolutional Neural Networks With Stepwise Transfer Learning. *IEEE Access*, 9, 140565-140580. <https://doi.org/10.1109/ACCESS.2021.3119655>
- Akther, J., Harun-Or-Roshid, M., Nayan, A.-A., & Kibria, M. G. (2021). Transfer learning on VGG16 for the Classification of Potato Leaves Infected by Blight Diseases. 2021 *Emerging Technology in Computing, Communication and Electronics (ETCCE)*, 1-5. <https://doi.org/10.1109/ETCCE54784.2021.9689792>

- Alatawi, A. A., Alomani, S. M., Alhawiti, N. I., & Ayaz, M. (2022). Plant Disease Detection using AI based VGG-16 Model. *International Journal of Advanced Computer Science and Applications*, 13(4), 718-727. Scopus.
<https://doi.org/10.14569/IJACSA.2022.0130484>
- Albanese, A., d'Acunto, D., & Brunelli, D. (2020). Pest Detection for Precision Agriculture Based on IoT Machine Learning. *Lecture Notes in Electrical Engineering*, 627, 65-72. Scopus. https://doi.org/10.1007/978-3-030-37277-4_8
- Angin, P., Anisi, M. H., Göksel, F., Gürsoy, C., & Büyükgülçü, A. (2020). Agrilora: A digital twin framework for smart agriculture. *Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications*, 11(4), 77-96. Scopus.
<https://doi.org/10.22667/JOWUA.2020.12.31.077>
- Bajpai, G., Gupta, A., & Chauhan, N. (2019). Real Time Implementation of Convolutional Neural Network to Detect Plant Diseases Using Internet of Things. *Communications in Computer and Information Science*, 1066, 510-522. Scopus. https://doi.org/10.1007/978-981-32-9767-8_42
- Bala Murugan, M. S., Rajagopal, M. K., & Roy, D. (2021). *IoT Based Smart Agriculture and Plant Disease Prediction*. 2115(1). Scopus. <https://doi.org/10.1088/1742-6596/2115/1/012017>
- Balaji, V. R., Kalvinathan, V., Dheepanchakkravarthy, A., & Muthuvel, P. (2021). *IoT Enabled Smart Irrigation System*. 2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation, ICAECA 2021. Scopus.
<https://doi.org/10.1109/ICAECA52838.2021.9675690>

- Barburiceanu, S., Meza, S., Orza, B., Malutan, R., & Terebes, R. (2021). Convolutional Neural Networks for Texture Feature Extraction. Applications to Leaf Disease Classification in Precision Agriculture. *IEEE Access*, 9, 160085-160103.
<https://doi.org/10.1109/ACCESS.2021.3131002>
- Basori, A. H., Mansur, A. B. F., & Riskiawan, H. Y. (2020). SMARF: Smart Farming Framework Based on Big Data, IoT and Deep Learning Model for Plant Disease Detection and Prevention. *Communications in Computer and Information Science*, 1174 CCIS, 44-56. Scopus. https://doi.org/10.1007/978-3-030-38752-5_4
- Biggs, P., Garrity, J., LaSalle, C., & Polomska, A. (2016). *Harnessing-IoT-Global-Development*. <https://www.itu.int/en/action/broadband/Documents/Harnessing-IoT-Global-Development.pdf>
- Bischoff, V., & Farias, K. (2020). *VitForecast: An IoT approach to predict diseases in vineyard*. ACM International Conference Proceeding Series. Scopus.
<https://doi.org/10.1145/3411564.3411584>
- Blessy Annie Flora, J., Radha, S., Hemalatha, R., & Aasha Nandhini, S. (2021). Plant disease detection for banana using long range wide area network. *International Journal of Security and Networks*, 16(2), 129-134. Scopus.
<https://doi.org/10.1504/IJSN.2021.116778>
- Brechelt, D. A. (2004a). *El Manejo Ecológico de Plagas y Enfermedades*. 36.
- Brechelt, D. A. (2004b). *El Manejo Ecológico de Plagas y Enfermedades*. 37.
- Brewster, C., Roussaki, I., Kalatzis, N., Doolin, K., & Ellis, K. (2017). IoT in Agriculture: Designing a Europe-Wide Large-Scale Pilot. *IEEE Communications Magazine*, 55(9), 26-33. <https://doi.org/10.1109/MCOM.2017.1600528>

- Chandana, P., Pradeep Ghantasala, G. S., Rethna Virgil Jeny, J., Sekaran, K., Deepika, N., Nam, Y., & Kadry, S. (2020). An effective identification of crop diseases using faster region based convolutional neural network and expert systems. *International Journal of Electrical and Computer Engineering*, 10(6), 6531-6540. Scopus.
<https://doi.org/10.11591/IJECE.V10I6.PP6531-6540>
- Chatterjee, A., Abhijeet, & Basu, S. (2019). *Green sense: A smart assistant for agriculture management using IoT and deep learning*. 495-499. Scopus.
- Chen, C.-C., Ba, J. Y., Li, T. J., Chan, C. C. K., Wang, K. C., & Liu, Z. (2021). EfficientNet: A low-bandwidth IoT image sensor framework for cassava leaf disease classification. *Sensors and Materials*, 33(11), 4031-4044. Scopus.
<https://doi.org/10.18494/SAM.2021.3526>
- Chen, C.-J., Huang, Y.-Y., Li, Y.-S., Chang, C.-Y., & Huang, Y.-M. (2020). An AIoT Based Smart Agricultural System for Pests Detection. *IEEE Access*, 8, 180750-180761.
<https://doi.org/10.1109/ACCESS.2020.3024891>
- Chen, C.-J., Huang, Y.-Y., Li, Y.-S., Chen, Y.-C., Chang, C.-Y., & Huang, Y.-M. (2021). Identification of Fruit Tree Pests With Deep Learning on Embedded Drone to Achieve Accurate Pesticide Spraying. *IEEE Access*, 9, 21986-21997.
<https://doi.org/10.1109/ACCESS.2021.3056082>
- Chen, C.-J., Li, Y.-S., Tai, C.-Y., Chen, Y.-C., & Huang, Y.-M. (2022). Pest incidence forecasting based on Internet of Things and Long Short-Term Memory Network. *Applied Soft Computing*, 124. Scopus. <https://doi.org/10.1016/j.asoc.2022.108895>

- Chen, W.-L., Lin, Y.-B., Ng, F.-L., Liu, C.-Y., & Lin, Y.-W. (2020). RiceTalk: Rice Blast Detection Using Internet of Things and Artificial Intelligence Technologies. *IEEE Internet of Things Journal*, 7(2), 1001-1010. <https://doi.org/10.1109/JIOT.2019.2947624>
- Chiwamba, S. H., Phiri, J., Nkunika, P. O. Y., Sikasote, C., Kabemba, M. M., & Moonga, M. N. (2019). Automated fall armyworm (*Spodoptera frugiperda*, J.E. Smith) pheromone trap based on machine learning. *Journal of Computer Science*, 15(12), 1759-1779. Scopus. <https://doi.org/10.3844/JCSSP.2019.1759.1779>
- Chouhan, S. S., Singh, U. P., & Jain, S. (2021). Automated Plant Leaf Disease Detection and Classification Using Fuzzy Based Function Network. *Wireless Personal Communications*, 121(3), 1757-1779. Scopus. <https://doi.org/10.1007/s11277-021-08734-3>
- Chunduri, K., & Menaka, R. (2019). Agricultural monitoring and controlling system using wireless sensor network. *Advances in Intelligent Systems and Computing*, 898, 47-56. Scopus. https://doi.org/10.1007/978-981-13-3393-4_6
- Coletta, A., Bartolini, N., Maselli, G., Kehs, A., McCloskey, P., & Hughes, D. P. (2022). Optimal Deployment in Crowdsensing for Plant Disease Diagnosis in Developing Countries. *IEEE Internet of Things Journal*, 9(9), 6359-6373. <https://doi.org/10.1109/JIOT.2020.3002332>
- Dai, Q., Cheng, X., Qiao, Y., & Zhang, Y. (2020). Agricultural Pest Super-Resolution and Identification With Attention Enhanced Residual and Dense Fusion Generative and Adversarial Network. *IEEE Access*, 8, 81943-81959. <https://doi.org/10.1109/ACCESS.2020.2991552>

- De La Concepcion, A. R., Stefanelli, R., & Trincherro, D. (2014). *A wireless sensor network platform optimized for assisted sustainable agriculture*. 159-165. Scopus.
<https://doi.org/10.1109/GHTC.2014.6970276>
- de Vita, F., Nocera, G., Bruneo, D., Tomaselli, V., Giacalone, D., & Das, S. K. (2020). Quantitative Analysis of Deep Leaf: A Plant Disease Detector on the Smart Edge. *2020 IEEE International Conference on Smart Computing (SMARTCOMP)*, 49-56.
<https://doi.org/10.1109/SMARTCOMP50058.2020.00027>
- Delnevo, G., Girau, R., Ceccarini, C., & Prandi, C. (2022). A Deep Learning and Social IoT Approach for Plants Disease Prediction Toward a Sustainable Agriculture. *IEEE Internet of Things Journal*, 9(10), 7243-7250. <https://doi.org/10.1109/JIOT.2021.3097379>
- Devine, G. J., Eza, D., Ogusuku, E., & Furlong, M. J. (2008). Uso de insecticidas: Contexto y consecuencias ecológicas. *Revista Peruana de Medicina Experimental y Salud Publica*, 25(1), 74-100.
- Esmail Karar, M., Abdel-Aty, A.-H., Algarni, F., Fadzil Hassan, M., Abdou, M. A., & Reyad, O. (2022). Smart IoT-based system for detecting RPW larvae in date palms using mixed depthwise convolutional networks. *Alexandria Engineering Journal*, 61(7), 5309-5319. Scopus. <https://doi.org/10.1016/j.aej.2021.10.050>
- Fatima, N., Siddiqui, S. A., & Ahmad, A. (2021). IoT-based Smart Greenhouse with Disease Prediction using Deep Learning. *International Journal of Advanced Computer Science and Applications*, 12(7), 113-121. Scopus.
<https://doi.org/10.14569/IJACSA.2021.0120713>

Fernandez, M. (2009). *Fertilizantes y contaminantes, un círculo vicioso*.

https://portal.uah.es/portal/page/portal/epd2_asignaturas/asig36357/informacion_academica/art.fertilizantes.PDF

Francis, F., Vishnu, P. L., Jha, M., & Rajaram, B. (2018). IOT-based automated aeroponics system. *Lecture Notes in Electrical Engineering*, 492, 337-345. Scopus.

https://doi.org/10.1007/978-981-10-8575-8_32

Gao, D., Sun, Q., Hu, B., & Zhang, S. (2020). A framework for agricultural pest and disease monitoring based on internet-of-things and unmanned aerial vehicles. *Sensors (Switzerland)*, 20(5). Scopus.

<https://doi.org/10.3390/s20051487>

Gao, R., Li, Q., Sun, X., Gu, J., & Peng, C. (2020). Intelligent diagnosis of greenhouse cucumber diseases based on multi-structure parameter ensemble learning. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 36(16), 158-

165. Scopus. <https://doi.org/10.11975/j.issn.1002-6819.2020.16.020>

Garg, G., Gupta, S., Mishra, P., Vidyarthi, A., Singh, A., & Ali, A. (2021). CROPCARE: An Intelligent Real-Time Sustainable IoT System for Crop Disease Detection Using Mobile Vision. *IEEE Internet of Things Journal*, 10(4), 2840-2851. Scopus.

<https://doi.org/10.1109/JIOT.2021.3109019>

Garg, S., Pundir, P., Jindal, H., Saini, H., & Garg, S. (2021). Towards a Multimodal System for Precision Agriculture using IoT and Machine Learning. *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1-7.

<https://doi.org/10.1109/ICCCNT51525.2021.9579646>

- Geetha Lekshmy, V., Vishnu, P. A., & Harikrishnan, P. S. (2022). Adaptive IoT System for Precision Agriculture. *Lecture Notes in Networks and Systems*, 336, 39-49. Scopus. https://doi.org/10.1007/978-981-16-6723-7_4
- Ghofrani, A., Toroghi, R. M., & Behnegar, H. (2021). Plant Disease Recognition Using Optimized Deep Convolutional Neural Networks. *Communications in Computer and Information Science*, 1322 CCIS, 18-30. Scopus. https://doi.org/10.1007/978-3-030-71804-6_2
- Gliessman, S. R. (2002). *Agroecología: Procesos ecológicos en agricultura sostenible*. CATIE.
- Gokhale, P., Bhat, O., & Bhat, S. (2018). *Introduction to IOT*. 5, 41-44. <https://doi.org/10.17148/IARJSET.2018.517>
- Gómez, J. E., Castaño, S., Mercado, T., Fernandez, A., & Garcia, J. (2017). Sistema de internet de las cosas (IoT) para el monitoreo de cultivos protegidos. *Ingeniería e Innovación*, 5(1), Article 1. <https://doi.org/10.21897/23460466.1101>
- Guerrero, C. J. (2021). *Reconocimiento de lesiones necróticas para la detección temprana de la plaga thrips (kakothrips robustus uzel) en los cultivos del guisante o arveja mediante técnicas deep learning*. <http://repositorio.utn.edu.ec/handle/123456789/11654>
- Harun, S., Arefin Hossain, Md. I., Jahan, F., & Tanvin, T. (2021). An IoT based System with Edge Intelligence for Rice Leaf Disease Detection using Machine Learning. *2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)*, 1-6. <https://doi.org/10.1109/IEMTRONICS52119.2021.9422499>
- Hossain, S. M. M., Deb, K., Dhar, P. K., & Koshiba, T. (2021). Plant leaf disease recognition using depth-wise separable convolution-based models. *Symmetry*, 13(3). Scopus. <https://doi.org/10.3390/sym13030511>

- Hsiao, S.-J., & Sung, W.-T. (2021). A study on using a wireless sensor network to design a plant monitoring system. *Intelligent Automation and Soft Computing*, 27(2), 359-377. Scopus.
<https://doi.org/10.32604/iasc.2021.014905>
- Hu, W.-J., Fan, J., Du, Y.-X., Li, B.-S., Xiong, N., & Bekkering, E. (2020). MDFC–ResNet: An Agricultural IoT System to Accurately Recognize Crop Diseases. *IEEE Access*, 8, 115287-115298. <https://doi.org/10.1109/ACCESS.2020.3001237>
- ICA, & Grupo técnico Procaucho. (2012). *Manejo integrado de plagas y enfermedades en el cultivo de caucho (Hevea Brasiliensis)-Medidas para la temporada invernal*.
<https://www.ica.gov.co/getattachment/47f3dbff-348d-4f63-968b-4cd196db8e4f/-nbsp;Manejo-integrado-de-plagas-y-enfermedades-en.aspx>
- Indira, D. N. V. S. L. S., Harshita, M., Pranav, D. S., & Sai, J. P. M. (2018). TILLAGE DRIP: An efficient seed selection and conservative irrigation with crop defective alert by IOT. *Smart Innovation, Systems and Technologies*, 78, 53-62. Scopus.
https://doi.org/10.1007/978-981-10-5547-8_6
- Inter-Organization Programme for the Sound Management of Chemicals, World Health Organization, & Food and Agriculture Organization of the United Nations (Eds.). (2014). *The international code of conduct on pesticide management*. Inter-Organization Programme for the Sound Management of Chemicals : World Health Organization : Food and Agriculture Organization of the United Nations.
- Jakjoud, F., Hatim, A., & Bouaaddi, A. (2019). *Deep learning application for plant diseases detection*. ACM International Conference Proceeding Series. Scopus.
<https://doi.org/10.1145/3372938.3372983>

- Jiang, P., Chen, Y., Liu, B., He, D., & Liang, C. (2019). Real-Time Detection of Apple Leaf Diseases Using Deep Learning Approach Based on Improved Convolutional Neural Networks. *IEEE Access*, 7, 59069-59080.
<https://doi.org/10.1109/ACCESS.2019.2914929>
- Jiménez, R. M. (2017). Las enfermedades de las plantas: Impactos, amenazas y control. *Boletín de la Real Academia de Córdoba XCVI (166)*, 111-130 (2017).
<http://helvia.uco.es/xmlui/handle/10396/17828>
- Kailasam, S., Achanta, S. D. M., Rama Koteswara Rao, P., Vatambeti, R., & Kayam, S. (2022). An IoT-based agriculture maintenance using pervasive computing with machine learning technique. *International Journal of Intelligent Computing and Cybernetics*, 15(2), 184-197. Scopus. <https://doi.org/10.1108/IJICC-06-2021-0101>
- Kaissari, S., Attaoui, A. E., Benba, A., Jilbab, A., Bourouhou, A., & Kaissari, A. (2021). Plantech: Early detection of plant disease based on hwsn using deep learning. *International Journal on Engineering Applications*, 9(3), 162-172. Scopus.
<https://doi.org/10.15866/irea.v9i3.20720>
- Kakamoukas, G., Sariciannidis, P., Livanos, G., Zervakis, M., Ramnalis, D., Polychronos, V., Karamitsou, T., Folinis, A., & Tsitsiokas, N. (2019). *A Multi-collective, IoT-enabled, Adaptive Smart Farming Architecture*. IST 2019 - IEEE International Conference on Imaging Systems and Techniques, Proceedings. Scopus.
<https://doi.org/10.1109/IST48021.2019.9010236>
- Kale, A. P., & Sonavane, S. P. (2019). IoT based Smart Farming: Feature subset selection for optimized high-dimensional data using improved GA based approach for ELM.

- Computers and Electronics in Agriculture*, 161, 225-232. Scopus.
<https://doi.org/10.1016/j.compag.2018.04.027>
- Karar, M. E., Reyad, O., Abdel-Aty, A.-H., Owyed, S., & Hassan, M. F. (2021). Intelligent IoT-Aided early sound detection of red palm Weevils. *Computers, Materials and Continua*, 69(3), 4095-4111. Scopus. <https://doi.org/10.32604/cmc.2021.019059>
- Karnati, R., Rao, H. J., Om Prakash, P. G., & Maram, B. (2022). Deep computation model to the estimation of sulphur dioxide for plant health monitoring in IoT. *International Journal of Intelligent Systems*, 37(1), 944-971. Scopus. <https://doi.org/10.1002/int.22653>
- Karthickmanoj, R., Padmapriya, J., & Sasilatha, T. (2021). A novel pixel replacement-based segmentation and double feature extraction techniques for efficient classification of plant leaf diseases. *Materials Today: Proceedings*, 47, 2048-2052. Scopus.
<https://doi.org/10.1016/j.matpr.2021.04.416>
- Khan, F. A., Ibrahim, A. A., & Zeki, A. M. (2020). Environmental monitoring and disease detection of plants in smart greenhouse using internet of things. *Journal of Physics Communications*, 4(5). Scopus. <https://doi.org/10.1088/2399-6528/ab90c1>
- Khanna, A., & Kaur, S. (2019). Evolution of Internet of Things (IoT) and its significant impact in the field of Precision Agriculture. *Computers and Electronics in Agriculture*, 157, 218-231. <https://doi.org/10.1016/j.compag.2018.12.039>
- Khattab, A., Habib, S. E. D., Ismail, H., Zayan, S., Fahmy, Y., & Khairy, M. M. (2019). An IoT-based cognitive monitoring system for early plant disease forecast. *Computers and Electronics in Agriculture*, 166. Scopus. <https://doi.org/10.1016/j.compag.2019.105028>
- Kim, S., Lee, M., & Shin, C. (2018). IoT-based strawberry disease prediction system for smart farming. *Sensors (Switzerland)*, 18(11). Scopus. <https://doi.org/10.3390/s18114051>

- King, A. B. S. (1984). *Las plagas invertebradas de cultivos anuales alimenticios en America Central*. Bib. Orton IICA / CATIE.
- Kishan Das Menon, H., Mishra, D., & Deepa, D. (2020). Automation and integration of growth monitoring in plants (with disease prediction) and crop prediction. *Materials Today: Proceedings*, 43, 3922-3927. Scopus. <https://doi.org/10.1016/j.matpr.2021.01.973>
- Kolli, J., Vamsi, D. M., & Manikandan, V. M. (2021). Plant Disease Detection using Convolutional Neural Network. *2021 IEEE Bombay Section Signature Conference (IBSSC)*, 1-6. <https://doi.org/10.1109/IBSSC53889.2021.9673493>
- Kong, J., Jin, X., Tao, Z., Wang, X., & Lin, S. (2020). Fine-grained recognition of diseases and pests based on multi-stream Gaussian probability fusion network. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 36(13), 148-157. Scopus. <https://doi.org/10.11975/j.issn.1002-6819.2020.13.018>
- Koubaa, A., Aldawood, A., Saeed, B., Hadid, A., Ahmed, M., Saad, A., Alkhouja, H., Ammar, A., & Alkanhal, M. (2020). Smart palm: An IoT framework for red palm weevil early detection. *Agronomy*, 10(7). Scopus. <https://doi.org/10.3390/agronomy10070987>
- Kumar, J. D., Thottungal, R., & Vijayanandhc, R. (2021). Effective monitoring by drone using advanced deep machine learning strategies with iot. *Journal of Environmental Protection and Ecology*, 22(3), 1246-1258. Scopus.
- Kundu, N., Rani, G., Dhaka, V. S., Gupta, K., Nayak, S. C., Verma, S., Ijaz, M. F., & Woźniak, M. (2021). Iot and interpretable machine learning based framework for disease prediction in pearl millet. *Sensors*, 21(16). Scopus. <https://doi.org/10.3390/s21165386>
- Latif, M. S., Kazmi, R., Khan, N., Majeed, R., Ikram, S., & Ali-Shahid, M. M. (2022). Pest Prediction in Rice using IoT and Feed Forward Neural Network. *KSII Transactions on*

Internet and Information Systems, 16(1), 133-152. Scopus.

<https://doi.org/10.3837/tiis.2022.01.008>

Latorre, B. (2004). *Enfermedades de las plantas cultivadas*. Ediciones UC.

Lazarescu, M. T. (2013). Design of a WSN Platform for Long-Term Environmental Monitoring for IoT Applications. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 3(1), 45-54. <https://doi.org/10.1109/JETCAS.2013.2243032>

Lee, K.-C., Wang, Y.-H., Wei, W.-C., Chiang, M.-H., Dai, T.-E., Pan, C.-C., Chen, T.-Y., Luo, S.-K., Li, P.-K., Chen, J.-K., Liaw, S.-K., Lin, C.-F., Wu, C.-C., & Chieh, J.-J. (2021). An optical smartphone-based inspection platform for identification of diseased orchids. *Biosensors*, 11(10). Scopus. <https://doi.org/10.3390/bios11100363>

Liu, Z., Bashir, R. N., Iqbal, S., Shahid, M. M. A., Tausif, M., & Umer, Q. (2022). Internet of Things (IoT) and Machine Learning Model of Plant Disease Prediction—Blister Blight for Tea Plant. *IEEE Access*, 10, 44934-44944. <https://doi.org/10.1109/ACCESS.2022.3169147>

Loganathan, G. B., Mahdi, Q. S., Saleh, I. H., & Othman, M. M. (2022). AGRIBOT: Energetic Agricultural Field Monitoring Robot Based on IoT Enabled Artificial Intelligence Logic. *Communications in Computer and Information Science*, 1548 CCIS, 16-30. Scopus. https://doi.org/10.1007/978-3-030-97255-4_2

Madhav, M. U., Jyothi, D. N., & Kalyani, P. (2021). *Prediction of pesticides and identification of diseases in fruits using Support Vector Machine (SVM) and IoT*. 2407. Scopus. <https://doi.org/10.1063/5.0074595>

Madhulatha, G., & Ramadevi, O. (2020). Recognition of Plant Diseases using Convolutional Neural Network. *2020 Fourth International Conference on I-SMAC (IoT in Social,*

- Mobile, Analytics and Cloud) (I-SMAC)*, 738-743. <https://doi.org/10.1109/I-SMAC49090.2020.9243422>
- Manick, & Srivastava, J. (2022). Cassava Leaf Disease Detection Using Deep Learning. 2022 *IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)*, 1-7. <https://doi.org/10.1109/IEMTRONICS55184.2022.9795751>
- Manrique-Silupu, J., Campos, J. C., Paiva, E., & Ipanaqué, W. (2021). Thrips incidence prediction in organic banana crop with Machine learning. *Heliyon*, 7(12). Scopus. <https://doi.org/10.1016/j.heliyon.2021.e08575>
- Martín, C., Llopis, L., Rubio, B., Díaz, M., & Díaz, F. (2021). *Revisión de tecnologías habilitadoras para el control biológico y de plagas en el sector hortofrutícola*. 744-751. <https://ruc.udc.es/dspace/handle/2183/28375>
- Maryum, A., Akram, M. U., & Salam, A. A. (2021). Cassava Leaf Disease Classification using Deep Neural Networks. 2021 *IEEE 18th International Conference on Smart Communities: Improving Quality of Life Using ICT, IoT and AI (HONET)*, 32-37. <https://doi.org/10.1109/HONET53078.2021.9615488>
- Mellit, A., Benghanem, M., Herrak, O., & Messalaoui, A. (2021). Design of a novel remote monitoring system for smart greenhouses using the internet of things and deep convolutional neural networks. *Energies*, 14(16). Scopus. <https://doi.org/10.3390/en14165045>
- Menon, A. G., & Prabhakar, M. (2021). *Smart Agriculture Monitoring Rover for Small-Scale Farms in Rural Areas using IoT*. Proceedings of the 2021 IEEE International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems, ICSES 2021. Scopus. <https://doi.org/10.1109/ICSES52305.2021.9633976>

- Mewada, H., & Patoliaya, J. (2021). Iot based automated plant disease classification using support vector machine. *International Journal of Electronics and Telecommunications*, 67(3), 517-522. Scopus. <https://doi.org/10.24425/ijet.2021.137841>
- Mishra, M., Choudhury, P., & Pati, B. (2021). Modified ride-NN optimizer for the IoT based plant disease detection. *Journal of Ambient Intelligence and Humanized Computing*, 12(1), 691-703. Scopus. <https://doi.org/10.1007/s12652-020-02051-6>
- Molina, C. A. (2020). *Estudio de una red inalámbrica de sensores IOT para detección y control en tiempo real de los diferentes parámetros característicos de amarillamiento y secamiento en la palma africana*. <http://repositorio.ucsg.edu.ec/handle/3317/15600>
- Murugamani, C., Shitharth, S., Hemalatha, S., Kshirsagar, P. R., Riyazuddin, K., Naveed, Q. N., Islam, S., Mazher Ali, S. P., & Batu, A. (2022). Machine Learning Technique for Precision Agriculture Applications in 5G-Based Internet of Things. *Wireless Communications and Mobile Computing*, 2022. Scopus. <https://doi.org/10.1155/2022/6534238>
- Musa, A., Hamada, M., Aliyu, F. M., & Hassan, M. (2021). An Intelligent Plant Disease Detection System for Smart Hydroponic Using Convolutional Neural Network. *2021 IEEE 14th International Symposium on Embedded Multicore/Many-core Systems-on-Chip (MCSoc)*, 345-351. <https://doi.org/10.1109/MCSoc51149.2021.00058>
- Musa, A., Hassan, M., Hamada, M., & Aliyu, F. (2022). Low-Power Deep Learning Model for Plant Disease Detection for Smart-Hydroponics Using Knowledge Distillation Techniques. *Journal of Low Power Electronics and Applications*, 12(2). Scopus. <https://doi.org/10.3390/jlpea12020024>

- Nadeem, R., Jaffar, A., & Saleem, R. (2021). IoT and Machine Learning Based Stem Borer Pest Prediction. *Intelligent Automation & Soft Computing*, 31(3), 1377-1392.
<https://doi.org/10.32604/iasc.2022.020680>
- Nagasubramanian, G., Sakthivel, R. K., Patan, R., Sankayya, M., Daneshmand, M., & Gandomi, A. H. (2021). Ensemble Classification and IoT-Based Pattern Recognition for Crop Disease Monitoring System. *IEEE Internet of Things Journal*, 8(16), 12847-12854.
<https://doi.org/10.1109/JIOT.2021.3072908>
- Nalini, S., Krishnaraj, N., Jayasankar, T., Vinothkumar, K., Britto, A. S. F., Subramaniam, K., & Bharatiraja, C. (2021). Paddy Leaf Disease Detection Using an Optimized Deep Neural Network. *Computers, Materials and Continua*, 68(1), 1117-1128. Scopus.
<https://doi.org/10.32604/cmc.2021.012431>
- Nancy, P., Pallathadka, H., Naved, M., Kaliyaperumal, K., Arumugam, K., & Garchar, V. (2022). Deep Learning and Machine Learning Based Efficient Framework for Image Based Plant Disease Classification and Detection. *2022 International Conference on Advanced Computing Technologies and Applications (ICACTA)*, 1-6.
<https://doi.org/10.1109/ICACTA54488.2022.9753623>
- Narimani, M., Hajjahmad, A., Moghimi, A., Alimardani, R., Rafiee, S., & Mirzabe, A. H. (2021). *Developing an aeroponic smart experimental greenhouse for controlling irrigation and plant disease detection using deep learning and IoT*. 4, 2699-2710. Scopus. <https://doi.org/10.13031/aim.202101252>
- Nasir, I. M., Bibi, A., Shah, J. H., Khan, M. A., Sharif, M., Iqbal, K., Nam, Y., & Kadry, S. (2020). Deep learning-based classification of fruit diseases: An application for precision

- agriculture. *Computers, Materials and Continua*, 66(2), 1949-1962. Scopus.
<https://doi.org/10.32604/cmc.2020.012945>
- Naveenkumar, M., Srithar, S., Rajesh Kumar, B., Alagumuthukrishnan, S., & Baskaran, P. (2021). InceptionResNetV2 for Plant Leaf Disease Classification. *2021 Fifth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, 1161-1167. <https://doi.org/10.1109/I-SMAC52330.2021.9641025>
- Nawaz, M. A., Khan, T., Rasool, R. M., Kausar, M., Usman, A., Bukht, T. F. N., Ahmad, R., & Ahmad, J. (2020). Plant disease detection using internet of thing (IoT). *International Journal of Advanced Computer Science and Applications*, 11(1), 505-509. Scopus.
<https://doi.org/10.14569/ijacsa.2020.0110162>
- Nocera, F., Di Noia, T., Mongiello, M., & Di Sciascio, E. (2017). *Semantic IoT middleware-enabled mobile complex event processing for integrated pest management*. 610-617. Scopus.
- Pan, A., & Wang, N. (2021). *Design and Implementation of Crop Automatic Diagnosis and Treatment System Based on Internet of Things*. 1883(1). Scopus.
<https://doi.org/10.1088/1742-6596/1883/1/012062>
- Pandiyan, S., Ashwin, M., Manikandan, R., Karthick Raghunath, K. M., & Anantha Raman, G. R. (2020). Heterogeneous Internet of things organization Predictive Analysis Platform for Apple Leaf Diseases Recognition. *Computer Communications*, 154, 99-110. Scopus.
<https://doi.org/10.1016/j.comcom.2020.02.054>
- Pang, H., Zheng, Z., Zhen, T., & Sharma, A. (2021). Smart farming: An approach for disease detection implementing iot and image processing. *International Journal of Agricultural*

and Environmental Information Systems, 12(1), 55-67. Scopus.

<https://doi.org/10.4018/IJAEIS.20210101.oa4>

Patil, R. R., & Kumar, S. (2022). Rice-Fusion: A Multimodality Data Fusion Framework for Rice Disease Diagnosis. *IEEE Access*, 10, 5207-5222.

<https://doi.org/10.1109/ACCESS.2022.3140815>

Patle, K. S., Saini, R., Kumar, A., Surya, S. G., Palaparthi, V. S., & Salama, K. N. (2021). IoT Enabled, Leaf Wetness Sensor on the Flexible Substrates for In-Situ Plant Disease Management. *IEEE Sensors Journal*, 21(17), 19481-19491.

<https://doi.org/10.1109/JSEN.2021.3089722>

Paulchamy, B., Archana, M., Bhuvanewari, R., Karthick, B., & Karthik, S. (2021).

Implementation of Proficient Agriculture Using IoT with Machine Learning and Mobile Application. 1860-1870. Scopus. <https://doi.org/10.1109/ICESC51422.2021.9532664>

Pavel, M. I., Rumi, R. I., Fairouz, F., Jahan, S., & Hossain, M. A. (2021). Deep Residual Learning Approach for Plant Disease Recognition. *EAI/Springer Innovations in Communication and Computing*, 511-521. Scopus. https://doi.org/10.1007/978-3-030-49795-8_49

Pérez, J. P., Fernández-Caramés, T. M., Fraga-Lamas, P., & Castedo, L. (2017). Vinesens: An eco-smart decision-support viticulture system. *Sensors (Switzerland)*, 17(3). Scopus.

<https://doi.org/10.3390/s17030465>

Pérez, J. P., Fernández-Caramés, T. M., Fraga-Lamas, P., & Castedo, L. (2018). *An IoT monitoring system for precision viticulture*. 2018-January, 662-669. Scopus.

<https://doi.org/10.1109/iThings-GreenCom-CPSSCom-SmartData.2017.104>

- Perez, N., & Vázquez, L. L. (2001). *Pérez, N. Y L. L. Vázquez. Manejo ecológico de plagas. En: Transformando el campo cubano. Avances de la Agricultura Sostenible. Ed. ACTAF. La Habana. Pp. 191-223. 2001 (pp. 191-223).*
- Ponnusamy, V., Natarajan, S., Ramasamy, N., Clement, C., Rajalingam, P., & Mitsunori, M. (2021). An iot- enabled augmented reality framework for plant disease detection. *Revue d'Intelligence Artificielle*, 35(3), 185-192. Scopus. <https://doi.org/10.18280/ria.350301>
- Potamitis, I., Eliopoulos, P., & Rigakis, I. (2017). Automated remote insect surveillance at a global scale and the internet of things. *Robotics*, 6(3). Scopus. <https://doi.org/10.3390/robotics6030019>
- Pothuganti, K., Sridevi, B., & Seshabattar, P. (2021). IoT and Deep Learning based Smart Greenhouse Disease Prediction. *2021 International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT)*, 793-799. <https://doi.org/10.1109/RTEICT52294.2021.9573794>
- Prabu, A. V., Kumar, G. S., Rajasoundaran, S., Malla, P. P., Routray, S., & Mukherjee, A. (2022). Internet of things-based deeply proficient monitoring and protection system for crop field. *Expert Systems*, 39(5). Scopus. <https://doi.org/10.1111/exsy.12876>
- Pranav, H. P., Senthilmurugan, M., K, P. R., & Chinnaiyan, R. (2021). IoT and Machine Learning based Peer to Peer Platform for Crop Growth and Disease Monitoring System using Blockchain. *2021 International Conference on Computer Communication and Informatics (ICCCI)*, 1-5. <https://doi.org/10.1109/ICCCI50826.2021.9402435>
- Prieto, D. O. (2019). *La tecnificación como herramienta para incrementar la productividad agropecuaria en Colombia* [Funcación Universidad de America].

<http://repository.uamerica.edu.co/bitstream/20.500.11839/7246/1/2142125-2019-1-EF.pdf>

Producción sostenible. (2018, octubre 26). Argentina.gob.ar.

<https://www.argentina.gob.ar/ambiente/desarrollo-sostenible/produccion-sostenible>

Rajeshwari, T., Harsha Vardhini, P. A., Manoj Kumar Reddy, K., Priya, K. K., & Sreeja, K.

(2021). Smart Agriculture Implementation using IoT and Leaf Disease Detection using Logistic Regression. *2021 4th International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE)*, 619-623.

<https://doi.org/10.1109/RDCAPE52977.2021.9633608>

Ram, B., Rashid, M., Lakhwani, K., & Kumar, S. S. (2020). Health detection of wheat crop using pattern recognition and image processing. *International Journal of Healthcare Information Systems and Informatics*, 15(2), 50-60. Scopus.

<https://doi.org/10.4018/IJHISI.2020040104>

Ramana, K., Aluvala, R., Kumar, M. R., Nagaraja, G., Krishna, A. V., & Nagendra, P. (2022).

Leaf Disease Classification in Smart Agriculture using Deep Neural Network Architecture and IoT. *Journal of Circuits, Systems and Computers*. Scopus.

<https://doi.org/10.1142/S0218126622400047>

Ratnaparkhi, S., Khan, S., Arya, C., Khapre, S., Singh, P., Diwakar, M., & Shankar, A. (2020).

Smart agriculture sensors in IOT: A review. *Materials Today: Proceedings*.

<https://doi.org/10.1016/j.matpr.2020.11.138>

Reyes, Y., Vergara, I., Torres, O., Lagos, M. D., & Jimenez, E. E. G. (2016). Contaminación por metales pesados: Implicaciones en salud, ambiente y seguridad alimentaria. *Ingeniería Investigación y Desarrollo: I2+D*, 16(2), 66-77.

- Rishiikeshwer, B. S., Shriram, T. A., Raju, J. S., Hari, M., Santhi, B., & Brindha, G. R. (2020). Farmer-friendly mobile application for automated leaf disease detection of real-time augmented data set using convolution neural networks. *Journal of Computer Science*, *16*(2), 158-166. Scopus. <https://doi.org/10.3844/JCSSP.2020.158.166>
- Roel, A., & Terra, J. (2006). *Muestreo de suelos y factores limitantes del rendimiento* (pp. 65-80).
- Roihan, A., Hasanudin, M., & Sunandar, E. (2020). *Evaluation Methods of Bird Repellent Devices in Optimizing Crop Production in Agriculture*. *1477*(3). Scopus. <https://doi.org/10.1088/1742-6596/1477/3/032012>
- Roy, S., Mazumdar, N., Pamula, R., & Tarkas, D. (2021). Efficient Pest Bird-Controlling Algorithm in Unmanned Agriculture System. *Lecture Notes in Electrical Engineering*, *694*, 489-502. Scopus. https://doi.org/10.1007/978-981-15-7804-5_37
- Rueda, J. S., & Talavera, J. M. T. (2017). Similitudes y diferencias entre Redes de Sensores Inalámbricas e Internet de las Cosas: Hacia una postura clarificadora. *Revista Colombiana de Computación*, *18*(2), Article 2. <https://doi.org/10.29375/25392115.3218>
- Rustia, D. J. A., & Lin, T.-T. (2017). An IoT-based wireless imaging and sensor node system for remote greenhouse pest monitoring. *Chemical Engineering Transactions*, *58*, 601-606. Scopus. <https://doi.org/10.3303/CET1758101>
- Salazar, J., & Silvestre, S. (2016). *Internet de las cosas*. European Virtual Learning Platform for Electrical and Information Engineering. <https://upcommons.upc.edu/handle/2117/100921>
- Saleem, R. M., Kazmi, R., Bajwa, I. S., Ashraf, A., Ramzan, S., & Anwar, W. (2021). IOT-Based Cotton Whitefly Prediction Using Deep Learning. *Scientific Programming*, *2021*. Scopus. <https://doi.org/10.1155/2021/8824601>

- Salehin, I., Noman, S. M., Ul-Islam, B., Lopa, I. J., Angon, P. B., Habiba, U., & Moon, N. N. (2021). IFSG: Intelligence agriculture crop-pest detection system using IoT automation system. *Indonesian Journal of Electrical Engineering and Computer Science*, 24(2), 1091-1099. Scopus. <https://doi.org/10.11591/ijeecs.v24.i2.pp1091-1099>
- Salim, S. A., Amin, Md. R., Rahman, Md. S., Arafat, Md. Y., & Khan, R. (2021). An IoT-based Smart Agriculture System with Locust Prevention and Data Prediction. *2021 8th International Conference on Information Technology, Computer and Electrical Engineering (ICITACEE)*, 201-206. <https://doi.org/10.1109/ICITACEE53184.2021.9617550>
- Sanghavi, K., Sanghavi, M., & Rajurkar, A. M. (2021). Early stage detection of Downey and Powdery Mildew grape disease using atmospheric parameters through sensor nodes. *Artificial Intelligence in Agriculture*, 5, 223-232. Scopus. <https://doi.org/10.1016/j.aiia.2021.10.001>
- Sarangi, S., Umadikar, J., & Kar, S. (2016). Automation of Agriculture Support Systems using Wisekar: Case study of a crop-disease advisory service. *Computers and Electronics in Agriculture*, 122, 200-210. Scopus. <https://doi.org/10.1016/j.compag.2016.01.009>
- Shaikh, S., Tripathy, A. K., Gill, G., Gupta, A., & Hegde, R. (2018). Monitoring Chili Crop and Gray Mould Disease Analysis Through Wireless Sensor Network. *Advances in Intelligent Systems and Computing*, 736, 924-931. Scopus. https://doi.org/10.1007/978-3-319-76348-4_88
- Sharma, R. P., Ramesh, D., Pal, P., Tripathi, S., & Kumar, C. (2022). IoT-Enabled IEEE 802.15.4 WSN Monitoring Infrastructure-Driven Fuzzy-Logic-Based Crop Pest

Prediction. *IEEE Internet of Things Journal*, 9(4), 3037-3045.

<https://doi.org/10.1109/JIOT.2021.3094198>

Shi, D., Gao, D., Xue, W., Zhang, S., & Zhang, F. (2019). Research on agricultural disease and pest monitoring technology based on Internet of Things and big data. *Journal of Nanjing Agricultural University*, 42(5), 967-974. Scopus. <https://doi.org/10.7685/jnau.201812026>

Shukla, R., Dubey, G., Malik, P., Sindhwani, N., Anand, R., Dahiya, A., & Yadav, V. (2021). Detecting crop health using machine learning techniques in smart agriculture system. *Journal of Scientific and Industrial Research*, 80(8), 699-706. Scopus.

Silveira, M. I., Aldana, M. L., Piri, J., Valenzuela, A. I., Jasa-Silveira, G., & Rodríguez, G. (2018). PLAGUICIDAS AGRICOLAS: UN MARCO DE REFERENCIA PARA EVALUAR RIESGOS A LA SALUD EN COMUNIDADES RURALES EN EL ESTADO DE SONORA, MÉXICO. *Revista internacional de contaminación ambiental*, 34(1), 7-21. <https://doi.org/10.20937/rica.2018.34.01.01>

Sindhu, P., & Indirani, G. (2022). Equilibrium Optimizer with Deep Convolutional Neural Network-based SqueezeNet Model for Grape Leaf Disease Classification in IoT Environment. *International Journal of Engineering Trends and Technology*, 70(5), 94-102. Scopus. <https://doi.org/10.14445/22315381/IJETT-V70I5P212>

Song, Y., Xie, X., Liu, Z., & Zou, X. (2020). Crop Pests and Diseases Recognition Method Based on Multi-level EESP Model. *Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery*, 51(8), 196-202. Scopus. <https://doi.org/10.6041/j.issn.1000-1298.2020.08.022>

Sowmyalakshmi, R., Jayasankar, T., Ayyem Pillai, V., Subramaniyan, K., Pustokhina, I. V., Pustokhin, D. A., & Shankar, K. (2021). An optimal classification model for rice plant

- disease detection. *Computers, Materials and Continua*, 68(2), 1751-1767. Scopus.
<https://doi.org/10.32604/cmc.2021.016825>
- Suresh, & Seetharaman, K. (2023). Real-time automatic detection and classification of groundnut leaf disease using hybrid machine learning techniques. *Multimedia Tools and Applications*, 82(2), 1935-1963. Scopus. <https://doi.org/10.1007/s11042-022-12893-1>
- Sweetwilliams, F. O., Matthews, V. O., Adetiba, E., Babalola, D. T., & Akande, V. (2019). *Detection of Sigatoka Disease in Plantain Using IoT and Machine Learning Techniques*. 1378(2). Scopus. <https://doi.org/10.1088/1742-6596/1378/2/022004>
- Tan, W., Zhao, C., Wu, H., & Gao, R. (2015). A deep learning network for recognizing fruit pathologic images based on flexible momentum. *Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery*, 46(1), 20-25. Scopus.
<https://doi.org/10.6041/j.issn.1000-1298.2015.01.004>
- Thangadurai, N., Vinay Kumar, S. B., Gayathri, K. M., & Dhanashekar, R. (2020). Detection of disease in sugarcane leaf using IOT. *International Journal of Scientific and Technology Research*, 9(2), 1790-1795. Scopus.
- Trilles, S., González-Pérez, A., & Huerta, J. (2018). A comprehensive IoT node proposal using open hardware. A smart farming use case to monitor vineyards. *Electronics (Switzerland)*, 7(12). Scopus. <https://doi.org/10.3390/electronics7120419>
- Trilles, S., González-Pérez, A., & Huerta, J. (2019). Adapting models to warn fungal diseases in vineyards using in-field Internet of Things (IoT) nodes. *Sustainability (Switzerland)*, 11(2). Scopus. <https://doi.org/10.3390/su11020416>
- Trilles, S., Torres-Sospedra, J., Belmonte, Ó., Zarazaga-Soria, F. J., González-Pérez, A., & Huerta, J. (2020). Development of an open sensorized platform in a smart agriculture

- context: A vineyard support system for monitoring mildew disease. *Sustainable Computing: Informatics and Systems*, 28. Scopus.
<https://doi.org/10.1016/j.suscom.2019.01.011>
- Varandas, L., Faria, J., Gaspar, P. D., & Aguiar, M. L. (2020). Low-cost IoT remote sensor mesh for large-scale orchard monitorization. *Journal of Sensor and Actuator Networks*, 9(3). Scopus. <https://doi.org/10.3390/JSAN9030044>
- Verma, S., Tripathi, S., Singh, A., Ojha, M., & Saxena, R. R. (2021). *Insect Detection and Identification using YOLO Algorithms on Soybean Crop. 2021-December*, 272-277. Scopus. <https://doi.org/10.1109/TENCON54134.2021.9707354>
- Vijayalakshmi, S., Balakrishnan, G., & Lakshmi, S. N. (2021). Early Prediction of Plant Disease Using AI Enabled IOT. *Lecture Notes in Networks and Systems*, 290, 303-309. Scopus. https://doi.org/10.1007/978-981-16-4486-3_33
- Vimala, S., Gladiss Merlin, N. R., Ramanathan, L., & Cristin, R. (2021). Optimal routing and deep regression neural network for rice leaf disease prediction in IoT. *International Journal of Computational Methods*, 18(7). Scopus.
<https://doi.org/10.1142/S0219876221500146>
- Walia, R., Sharma, S., & Shrivastava, S. (2021). A Methodology for Early Detection of Plant Diseases Using Real Time Object Detection Algorithm. *Communications in Computer and Information Science*, 1470 CCIS, 122-139. Scopus. https://doi.org/10.1007/978-3-030-88259-4_9
- Wang, L., Jia, L., Wang, J., & Zhou, Q. (2021). *The Early-Warning and Inspection System for Intelligent Greenhouse Based on Internet of Things*. 1757(1). Scopus.
<https://doi.org/10.1088/1742-6596/1757/1/012151>

- Wang, X., & Liu, J. (2021). Multiscale Parallel Algorithm for Early Detection of Tomato Gray Mold in a Complex Natural Environment. *Frontiers in Plant Science*, 12. Scopus.
<https://doi.org/10.3389/fpls.2021.620273>
- Wang, X., Liu, J., & Zhu, X. (2021). Early real-time detection algorithm of tomato diseases and pests in the natural environment. *Plant Methods*, 17(1). Scopus.
<https://doi.org/10.1186/s13007-021-00745-2>
- Wang, X., Zhang, C., Zhang, S., & Zhu, Y. (2018). Forecasting of cotton diseases and pests based on adaptive discriminant deep belief network. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 34(14), 157-164. Scopus. <https://doi.org/10.11975/j.issn.1002-6819.2018.14.020>
- Weber, R. (2010). *Internet of Things – New security and privacy challenges—ScienceDirect*.
<https://www.sciencedirect.com/science/article/abs/pii/S0267364909001939?via%3Dihub>
- Wu, Y., Feng, X., & Chen, G. (2022). Plant Leaf Diseases Fine-Grained Categorization Using Convolutional Neural Networks. *IEEE Access*, 10, 41087-41096.
<https://doi.org/10.1109/ACCESS.2022.3167513>
- Xenakis, A., Papastergiou, G., Gerogiannis, V. C., & Stamoulis, G. (2020). Applying a Convolutional Neural Network in an IoT Robotic System for Plant Disease Diagnosis. *2020 11th International Conference on Information, Intelligence, Systems and Applications (IISA)*, 1-8. <https://doi.org/10.1109/IISA50023.2020.9284356>
- Xiao, D., Fu, J., Deng, X., Feng, J., Yin, J., & Ke, X. (2015). Design and test of remote monitoring equipment for bactrocera dorsalis trapping based on internet of things. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural*

- Engineering*, 31(7), 166-172. Scopus. <https://doi.org/10.3969/j.issn.1002-6819.2015.07.024>
- Yang, F., Shu, L., Yang, Y., Han, G., Pearson, S., & Li, K. (2021). Optimal Deployment of Solar Insecticidal Lamps Over Constrained Locations in Mixed-Crop Farmlands. *IEEE Internet of Things Journal*, 8(16), 13095-13114. <https://doi.org/10.1109/JIOT.2021.3064043>
- Yang, Z., Li, Z., Jin, Z., & Chen, Y. (2014). A Systematic Literature Review of Requirements Modeling and Analysis for Self-adaptive Systems. En C. Salinesi & I. Van De Weerd (Eds.), *Requirements Engineering: Foundation for Software Quality* (Vol. 8396, pp. 55-71). Springer International Publishing. https://doi.org/10.1007/978-3-319-05843-6_5
- Yue, Y., Cheng, X., Zhang, D., Wu, Y., Zhao, Y., Chen, Y., Fan, G., & Zhang, Y. (2018). Deep recursive super resolution network with Laplacian Pyramid for better agricultural pest surveillance and detection. *Computers and Electronics in Agriculture*, 150, 26-32. Scopus. <https://doi.org/10.1016/j.compag.2018.04.004>
- Zakzouk, S., Ehab, M., Atef, S., Yousri, R., Tawfik, R. M., & Darweesh, M. S. (2021). Rice Leaf Diseases Detector Based on AlexNet. *2021 9th International Japan-Africa Conference on Electronics, Communications, and Computations (JAC-ECC)*, 170-174. <https://doi.org/10.1109/JAC-ECC54461.2021.9691435>
- Zhang, J., Rao, Y., Man, C., Jiang, Z., & Li, S. (2021). Identification of cucumber leaf diseases using deep learning and small sample size for agricultural Internet of Things. *International Journal of Distributed Sensor Networks*, 17(4). Scopus. <https://doi.org/10.1177/15501477211007407>

- Zhang, S., Huang, W., & Wang, H. (2020). Crop disease monitoring and recognizing system by soft computing and image processing models. *Multimedia Tools and Applications*, 79(41-42), 30905-30916. Scopus. <https://doi.org/10.1007/s11042-020-09577-z>
- Zhang, S., Wang, H., Huang, W., & You, Z. (2018). Plant diseased leaf segmentation and recognition by fusion of superpixel, K-means and PHOG. *Optik*, 157, 866-872. <https://doi.org/10.1016/j.ijleo.2017.11.190>
- Zhang, S., Zhang, C., & Ding, J. (2017). Disease and insect pest forecasting model of greenhouse winter jujube based on modified deep belief network. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 33(19), 202-208. Scopus. <https://doi.org/10.11975/j.issn.1002-6819.2017.19.026>
- Zhao, D., Chen, H., Shou, G., Gu, Y., & Tong, M. (2016). Intelligent greenhouse control system based on wireless sensor network. *International Agricultural Engineering Journal*, 25(1), 43-55. Scopus.
- Zhao, Q., Zang, H., Zhang, J., Wang, M., Zheng, G., & Li, G. (2021). A pest sexual attraction monitoring system based on IoT and image processing. 2005(1). Scopus. <https://doi.org/10.1088/1742-6596/2005/1/012050>
- Zhao, Y., Liu, L., Xie, C., Wang, R., Wang, F., Bu, Y., & Zhang, S. (2020). An effective automatic system deployed in agricultural Internet of Things using Multi-Context Fusion Network towards crop disease recognition in the wild. *Applied Soft Computing Journal*, 89. Scopus. <https://doi.org/10.1016/j.asoc.2020.106128>
- Zinonos, Z., Gkelios, S., Khalifeh, A. F., Hadjimitsis, D. G., Boutalis, Y. S., & Chatzichristofis, S. A. (2022). Grape Leaf Diseases Identification System Using Convolutional Neural

Networks and LoRa Technology. *IEEE Access*, 10, 122-133.

<https://doi.org/10.1109/ACCESS.2021.3138050>